الإحصاء

باستخدام SPSS

- الطبعة الأولى 2007
- جميع الحقوق محفوظة
- الناشر: شعاع للنشر والعلوم

حارة الرباط 2 - المنطقة 12 - حي السبيل 2
تلفاكس : 00963 (21) 2643545
هاتف : 00963 (21) 2643546
سورية ـ حلب
ص.ب 7875

لمزيد من المعلومات ولشراء كتب الدار مباشرة على الإنترنت
يرجى زيارة موقعنا http://www.raypub.com
البريد الإلكتروني للقراء: quality@raypub.com
info@raypub.com
البريد الإلكتروني للزبائن: sales@raypub.com
البريد الإلكتروني لدور النشر: orders@raypub.com

الإحصاء

باستخدام SPSS

ترجمة وإعداد

لجنة التأليف والترجمة

المقدمة

يشعر معظم الطلاب بالخوف من علم الإحصاء وذلك لأن معظمهم يفتقد للخلفية الرياضية التي تسمح بفهم المعادلات الرياضية المعقدة المستخدمة في هذا العلم. ومع التطور الكبير لأنظمة الحاسب وأنظمة التشغيل أصبح برنامج SPSS من أفضل البرامج الإحصائية المتوفرة تجارياً والتي تسمح بتنفيذ الإجرائيات الإحصائية دون الخوض بتفاصيل العمليات الرياضية الخاصة بها. ولكن استخدام هذا البرنامج دون معرفة إحصائية جيدة يعتبر أمراً خطيراً، فالبرنامج هو أداة للتنفيذ فقط.

يحاول هذا الكتاب الإجابة على أسئلة من نمط: كيف يمكن أن نفهم آلية عمل هذا الاختبار الإحصائي دون التعمق بالخلفية الرياضية له؟ وما هو عمل هذا الزر في برنامج SPSS؟ وماذا يعني هذا الخرج؟. ويحوي برنامج SPSS مجموعة معقدة من الخيارات، وسنحاول في هذا الكتاب معرفة عمل هذه الخيارات بالضبط وكيفية استخدامها. كما يحوي البرنامج مجموعة من الخيارات تسمح بضبط الاختبار المطلوب ليوافق متطلبات محددة. ومع أننا سنقدم التوصيات المناسبة فإننا نأمل بتوفير القاعدة النظرية التي تسمح للقارئ باتخاذ القرارات حول الخيارات المناسبة لعمليات التحليل التي سيقوم بها لاحقاً.

ويمكن أن تتم قراءة هذا الكتاب عند عدة مستويات، فالفصول 1 و 2 و 3 و 4 و 7 و 13 مخصصة للمبتدئين، أما الفصول 5 و 8 و 9 و 10 و 11 و 12 فهي ذات مستوى متوسط، أما الفصول 6 و 14 و 15 و 16 فتعالج مواضيع متقدمة نوعاً ما.

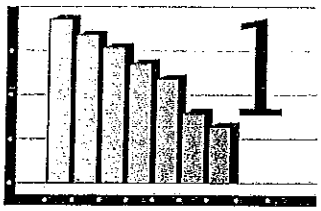

كل ما تود معرفته عن الإحصاء

1.1 بماذا يخبرنا هذا الفصل

ينتقل معظم الأشخاص الذين سيستخدمون هذا الكتاب مباشرة لقراءة الفصول التي تصف الاختبار الإحصائي الذي اكتشفوا فجأة أن عليهم استخدامه. ولكي تكون تلك الفصول مفهومة ومتماسكة فقد يكون من المفيد معرفة بعض الأمور الهامة عن الإحصاء. ويعتبر هذا الفصل محاولة لتقديم لمحة مختصرة عن بعض المبادئ الإحصائية الهامة مثل كيفية استخدام النماذج الإحصائية للإجابة على بعض التساؤلات العلمية.

2.1 بناء النماذج الإحصائية

في العلوم الاجتماعية، عادة ما نهتم باكتشاف شيء ما عن ظاهرة معينة نفترض وجودها فعلياً (ظاهرة من العالم الحقيقي). ويمكن أن تكون ظواهر العالم الحقيقي أي شيء بدءاً من سلوك معدلات الفائدة في الأسواق الاقتصادية وصولاً إلى سلوك الطلاب في مرحلة التخرج عند نهاية الامتحانات. ومهما كانت الظاهرة التي نريد شرحها، فإننا نحاول شرحها بجمع البيانات من العالم الحقيقي، واستخدام هذه البيانات لاستخلاص النتائج عن الظاهرة موضوع الدراسة. وعملنا كإحصائيين هو التعامل مع البيانات المتوفرة واستخدامها بطريقة ذات مغزى، وغالباً ما يتضمن ذلك بناء النماذج الإحصائية للظاهرة التي تتم دراستها.

إن أفضل تبرير للسبب الداعي لبناء النماذج الإحصائية لبيانات العالم الحقيقي هو التشابه أو القياس (Analogy). لنتخيل أن مهندساً يريد بناء جسر فوق نهر معين. قد نقول عن هذا المهندس أنه أحمق إذا قام ببناء أي جسر قديم، وذلك لأنه من المحتمل أن ينهار. عوضاً عن ذلك سيقوم المهندس بجمع البيانات من العالم الحقيقي، حيث سينظر إلى الجسور في العالم الحقيقي ويتعرف على مواد بنائها والبنى الإنشائية المستخدمة فيها (وقد يجمع بيانات أيضاً عن مدى تضرر أو تشوه تلك الجسور). ثم يستخدم تلك البيانات لإنشاء نموذج (Model) عن الجسر. يكون النموذج عادة نسخة مصغرة عن الجسر في العالم الحقيقي، وذلك لأنه من غير العملي، دون الإشارة للتكاليف، بناء الجسر الفعلي

ذاته. قد يختلف النموذج المصغر عن الجسر الفعلي بعدة طرق، فهو أولاً أصغر، ولكن المهندس سيحاول بناء نموذج يناسب بشكل ممتاز نقاط الاهتمام اعتماداً على البيانات المتوفرة. بعد الانتهاء من بناء النموذج، يمكن استخدامه للتنبؤ بأشياء من العالم الحقيقي، فعلى سبيل المثال قد يختبر المهندس تحمل الجسر للرياح القوية وذلك بوضع النموذج في نفق هوائي. ويبدو من البديهي والمهم جداً أن يكون النموذج تمثيلاً دقيقاً للعالم الحقيقي. ويقوم علماء الاجتماع بنفس العمل الذي يقوم به المهندسون تقريباً، حيث نقوم ببناء النماذج لعمليات العالم الحقيقي في محاولة للتنبؤ بآلية عمل هذه العمليات تحت ظروف معينة. وبما أنه لا يمكننا الوصول مباشرة إلى العمليات، فإننا نقوم بجمع البيانات التي تمثل العمليات ثم نستخدم هذه البيانات لبناء النماذج الإحصائية (نقلص العملية إلى نموذج إحصائي). نستخدم بعد ذلك هذا النموذج الإحصائي للحصول على تنبؤات عن الظاهرة في العالم الحقيقي. وكالمهندس تماماً، نريد أن تكون النماذج التي نبنيها دقيقة قدر الإمكان بحيث نكون على ثقة من أن التوقعات التي نعطيها دقيقة أيضاً. ولكن بخلاف المهندس، لا يمكننا الوصول إلى الحالة في العالم الحقيقي ولهذا فإننا لا نستطيع إلا استنتاج بعض الأمور عن العمليات النفسية أو الاجتماعية أو الاقتصادية اعتماداً على النماذج التي نبنيها. إذا أردنا أن تكون استنتاجاتنا دقيقة فإن على النموذج الإحصائي الذي نبنيه أن يمثل البيانات المجمّعة (البيانات المشاهدة Observed data) بدقة قدر الإمكان. وتُعرف درجة تمثيل النموذج الإحصائي للبيانات المجمعة بتوافق النموذج (Fit) وستصادف هذا المصطلح بشكل متكرر.

يوضح (الشكل 1.1) أنواع النماذج التي يمكن للمهندس بناءها لتمثيل الجسر في العالم الحقيقي الذي يريد إنشاءه. يعتبر النموذج الأول (a) تمثيلاً ممتازاً لحالة العالم الحقيقي ولذلك يقال عنه توافق جيد (Good fit) (هناك بعض الفروق الصغيرة ولكن النموذج هو نسخة مطابقة بشكل ممتاز عن الجسر الحقيقي). إذا استخدم المهندس هذا النموذج للتنبؤ عن العالم الحقيقي فإنه يمكن أن يكون واثقاً بأن هذه التنبؤات ستكون دقيقة جداً، وذلك لأن النموذج يشابه الواقع إلى حد كبير. لذلك إذا انهار النموذج عند تعرضه لرياح قوية فإن من المحتمل جداً أن ينهار الجسر الحقيقي أيضاً. يملك النموذج الثاني (b) بعض نقاط التشابه مع العالم الحقيقي، إذ يتضمن بعض المزايا الإنشائية الأساسية ولكن هناك اختلافات كبيرة مع الجسر في العالم الحقيقي (غياب أحد الأبراج الداعمة). يمكن أن نطلق على هذا النموذج صفة التوافق المتوسط (Moderate fit) (هناك بعض الاختلافات بين النموذج والبيانات ولكن التشابه مازال كبيراً). إذا استخدم المهندس هذا النموذج للتنبؤ عن العالم الحقيقي فإن التنبؤات قد تكون غير دقيقة ومن المحتمل أن تكون كارثية (فعلى سبيل المثال، إذا انهار الجسر تحت تأثير الرياح القوية فقد يكون ذلك بسبب غياب البرج الداعم الثاني). لذلك لا يمكننا الثقة بشكل كامل في استخدام نتائج هذا النموذج في التوقعات. أما النموذج الأخير (c) فهو مختلف تماماً عن حالة العالم الحقيقي، إذ لا يشابه الجسر الحقيقي من الناحية الإنشائية، ولذلك يمكن تسميته بالتوافق الرديء (Poor fit) (يمكن بالأصح تسميته بالتوافق السيئ). ولذلك فإن أي تنبؤات تعتمد على هذا النموذج ستكون غير دقيقة أبداً. بتوسيع هذا التشابه ليشمل العلوم الاجتماعية

يمكننا القول أنه من المهم عند إعداد نموذج إحصائي ليلائم مجموعة من البيانات أن يطابق هذا النموذج البيانات بشكل جيد. إذا كان النموذج ضعيف التوافق مع البيانات المشاهدة فإن التنبؤات التي يمكننا القيام بها ستكون رديئة أيضاً.

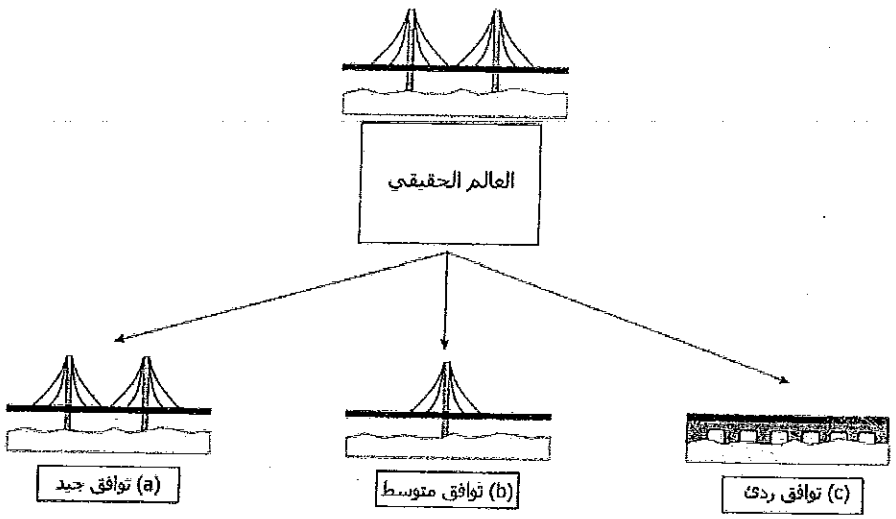

الشكل 1.1 توافق النماذج مع بيانات العالم الحقيقي

3.1 المجتمعات والعينات

نهتم كباحثين بإيجاد النتائج التي يمكن أن تنطبق على مجتمع كامل من الناس أو الأشياء. فعلى سبيل المثال، يريد العالم النفسي اكتشاف العمليات التي تحدث عند جميع البشر، ويهتم عالم الأحياء بالعمليات التي تحدث في جميع الخلايا، ويريد الباحث الاقتصادي بناء النماذج التي تنطبق على جميع الموظفين وهلم جرا. يمكن أن يكون المجتمع (population) عاماً جداً (جميع الكائنات البشرية) أو ضيقاً جداً (ذكور القطط الرمادية التي تدعى بوب)، ولكن في كلتا الحالتين نادراً ما يتاح للعالم الوصول إلى جميع عناصر المجتمع الذي يريد دراسته. إذ لا يستطيع العالم النفسي جمع البيانات من كل كائن بشري، ولا يمكن لعالم الأحياء مراقبة كل قط رمادي ذكر يدعى بوب. ولذلك نقوم بجمع البيانات من مجموعة جزئية صغيرة من المجتمع (تدعى عينة Sample) ونستخدم هذه البيانات لاستنتاج الأشياء عن المجتمع ككل. لا يستطيع المهندس بناء نموذج بالحجم الطبيعي عن الجسر الذي يريد بناءه، ولذلك فهو يقوم ببناء نموذج مصغر ويختبره تحت مختلف الظروف. ومن النتائج التي يحصل عليها من اختبار النموذج المصغر يستنتج المهندس الأشياء عن استجابة الجسر الحقيقي. قد تختلف استجابة النموذج المصغر عن الجسر الفعلي، وكلما كان النموذج أكبر كان احتمال سلوكه بنفس طريقة الجسر الفعلي أكبر. يمكن توسيع هذا التشبيه ليشمل علماء الاجتماع. لا يمكننا الوصول أبداً إلى المجتمع بكامله (الجسر بالحجم الفعلي) ولذلك نجمع عينات أصغر (النموذج

المصغر) ونستخدم السلوك ضمن العينة لاستنتاج أشياء عن السلوك في المجتمع. وكلما كانت العينة أكبر زاد احتمال تمثيلها للمجتمع بكامله. إذا أخذنا عدة عينات عشوائية من المجتمع، فإن كل عينة منها ستعطي نتائج مختلفة قليلاً عن بقية العينات. وعلى كل حال فإن النتائج من العينات الكبيرة يجب أن تكون متشابهة إلى حد ما.

4.1 النماذج الإحصائية البسيطة

1.4.1 المتوسط، مجموع المربعات، التباين والانحراف المعياري

يعتبر المتوسط (mean) من أبسط النماذج المستخدمة في الإحصاء. وقد يستغرب بعضكم من التفكير بالمتوسط كنموذج، ولكنه في الحقيقة كذلك لأنه يقدم ملخصاً للبيانات. إن المتوسط هو قيمة افتراضية يمكن حسابها لأية مجموعة من البيانات، وليس من الضروري أن تكون موجودة فعلياً في مجموعة البيانات المشاهدة. فعلى سبيل المثال، إذا أخذنا خمسة من مدرسي الإحصاء، وحسبنا عدد أصدقاء كل منهم، فقد نحصل على القيم التالية: 1 و2 و3 و3 و4. إذا حسبنا قيمة المتوسط لعدد الأصدقاء وذلك بجمع القيم التي حصلنا عليها ثم قسمنا الناتج على عدد القيم المقاسة 5 فإننا نحصل على 2.6 = 5 / (4 + 3 + 3 + 2 + 1). ولكننا نعلم أنه من المستحيل وجود 2.6 صديقاً، لذلك فإن قيمة المتوسط التي حصلنا عليها هي قيمة افتراضية. وهكذا فإن المتوسط هو نموذج تم إنشاؤه لتلخيص البيانات. يمكننا الآن تحديد فيما إذا كان هذا النموذج دقيقاً وذلك بالنظر لمدى اختلاف البيانات الفعلية عن النموذج الذي قمنا بإنشائه. وإحدى الطرق المستخدمة لتلك الغاية هي النظر إلى الفرق بين البيانات المشاهدة والنموذج المعتبر. يوضح (الشكل 2.1) عدد الأصدقاء لكل من مدرسي الإحصاء وكذلك قيمة المتوسط التي قمنا بحسابها سابقاً. يمكن النظر للخط الأفقي الممثل لقيمة المتوسط على أنه النموذج، أما الدوائر فتمثل البيانات المشاهدة. يحوي الشكل مجموعة من الخطوط الشاقولية أيضاً تصل كلاً من القيم المشاهدة بخط قيمة المتوسط. تمثل هذه الخطوط الشاقولية الحَيَدان (deviance) بين القيم المشاهدة والنموذج ويمكن اعتبارها ممثلة للخطأ في النموذج. يمكننا حساب المطال لهذه الحيدانات وذلك بطرح قيمة المتوسط $(\bar{x})$ من كل من القيم المشاهدة (x_i) حيث تتراوح قيم i بين 1 و 5. على سبيل المثال، للمدرس رقم 1 صديق واحد فقط أي $x_1 = 1$ وبذلك يكون الفرق هو:

$$x_1 - \bar{x} = 1 - 2.6 = -1.6$$

ربما لاحظت أن قيمة الحيدان هي قيمة سالبة في حالة المدرس الأول، وهي تعني أن النموذج الذي استخدمناه يبالغ في تقدير شعبية هذا المدرس، فالنموذج يتوقع أن يكون لهذا المدرس 2.6 صديقاً بينما لديه في الواقع صديق واحد فقط.

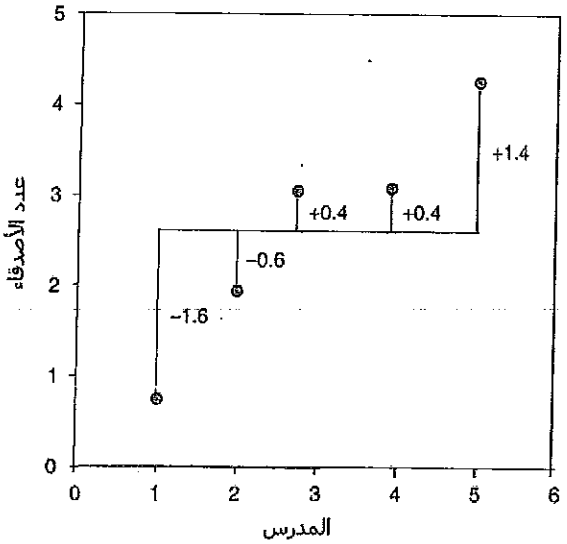

الشكل 2.1 يوضح المخطط الفرق بين القيم المشاهدة لعدد الأصدقاء لكل من مدرسي الإحصاء، وكذلك العدد المتوسط للأصدقاء

والآن كيف يمكننا استخدام هذه الحيدانات لتقدير دقة النموذج؟ هناك إمكانية جمع الحيدانات مع بعضها البعض (وهذا يعطي تقديراً للخطأ الكلي). إذا قمنا بذلك فإننا نحصل على:

مجموع الحيدانات = الخطأ الكلي

$$\text{الخطأ الكلي} = \Sigma(x_i - \bar{x}) = (-1.6) + (-0.6) + (0.4) + (0.4) + (1.4) = 0$$

في الواقع، تخبرنا النتيجة بأن الخطأ الكلي بين النموذج والبيانات المشاهدة معدوم، أي أن المتوسط يمثل البيانات بشكل مثالي. ولكننا نعلم أن هذا غير صحيح، فهناك أخطاء ولكن بعضها سالب وبعضها الآخر موجب، ولذلك فهي تقوم ببساطة بإلغاء بعضها البعض ونحصل على النتيجة السابقة. من الواضح أنه علينا تجنب مشكلة الجهة التي يقع فيها الخطأ، وإحدى الطرق الرياضية لإنجاز ذلك هي تربيع قيمة كل من الأخطاء، وذلك بضرب قيمة كل من الأخطاء بنفسها. وبدلاً من حساب مجموع الأخطاء نقوم بحساب مجموع مربعات الأخطاء. في هذا المثال:

$$\text{مجموع مربعات الأخطاء (SS)} = \Sigma(x_i - \bar{x})(x_i - \bar{x})$$

$$= (-1.6)^2 + (-0.6)^2 + (0.4)^2 + (0.4)^2 + (1.4)^2$$

$$= 2.56 + 0.36 + 0.16 + 0.16 + 1.96$$

$$= 5.20$$

إن مجموع مربعات الأخطاء SS (sum of squared errors) هو مقياس جيد لدقة النموذج. من البديهي أن مجموع مربعات الأخطاء يعتمد على كمية البيانات التي يتم جمعها، فكلما ازداد عدد نقاط البيانات ارتفعت قيمة SS. للتغلب على هذه المشكلة نقوم بحساب معدل الخطأ وذلك بتقسيم SS على عدد المشاهدات N. إذا كنا مهتمين بمعدل الخطأ للعينة فقط فيمكننا التقسيم على العدد N. ولكننا عادة نهتم باستخدام الخطأ في العينة لتقدير الخطأ في المجتمع ولذلك نقوم بتقسيم مجموع مربعات الأخطاء SS على عدد أقل بواحد من عدد المشاهدات (والسبب في ذلك موضح في الفصل الثامن، المربع 2.8: درجات الحرية). يعرف المقياس الجديد بالتباين (variance) وسنتعامل معه بشكل واسع لاحقاً:

$$\text{التباين}(s^2) = \frac{SS}{N-1} = \frac{\Sigma(x_i - \bar{x})^2}{N-1} = \frac{5.20}{4} = 1.3$$

لذلك فإن التباين هو متوسط الخطأ بين المتوسط والمشاهدات المنجزة (وبالتالي هو مقياس لمدى توافق النموذج مع البيانات الفعلية). هناك مشكلة واحدة مع التباين كمقياس هي أنه يعطي النتيجة بالوحدات المربعة (لأننا نقوم بتربيع كل من الأخطاء أثناء الحسابات). في مثالنا الحالي علينا أن نقول أن معدل الخطأ في البيانات (أي التباين) هو 1.3 صديقاً مربعاً. إن الحديث عن 1.3 صديق لا معنى له فماذا نقول إذاً عن 1.3 صديقاً مربعاً !. لهذا السبب نقوم غالباً بأخذ الجذر التربيعي للتباين (مما يضمن أن وحدة القياس لمعدل الخطأ مكافئة لوحدة القياس الأصلية). يدعى هذا المقياس بالانحراف المعياري (standard deviation) ونحصل عليه بأخذ الجذر التربيعي للتباين. في هذا المثال يكون الانحراف المعياري:

$$\text{الانحراف المعياري } s = \sqrt{\frac{\Sigma(x_i - \bar{x})^2}{N-1}} = \sqrt{1.3} = 1.14$$

إذاً الانحراف المعياري هو مقياس لمدى تمثيل المتوسط للبيانات الفعلية. تدل القيم الصغيرة للانحراف المعياري (مقارنة بقيمة المتوسط) على أن نقاط البيانات قريبة من المتوسط. بينما تدل القيم الكبيرة للانحراف المعياري (مقارنة بقيمة المتوسط) على أن نقاط البيانات بعيدة عن المتوسط (أي أن المتوسط لا يعتبر تمثيلاً دقيقاً للبيانات). إذا كانت قيمة الانحراف المعياري تساوي 0 فهذا يعني أن جميع النتائج متطابقة. يبين (الشكل 3.1) التقييم الكلي (على مقياس مكون من 5 نقاط) لاثنين من المدرسين بعد 5 محاضرات مختلفة لكل منهما. إن معدل التقييم لكل من المدرسَين هو 2.6 من 5 خلال جميع محاضراته. تبلغ قيمة الانحراف المعياري لتقييم المدرس الأول 0.55 (وهي قيمة صغيرة نسبياً مقارنة بقيمة المتوسط 2.6). يجب أن يكون واضحاً من خلال الشكل أن التقييمات لهذا المدرس قريبة من التقييم المتوسط. هناك تراوح صغير، ولكن بشكل عام فإن شعبية هذا المدرس لم تتغير. ولذلك فإن المتوسط هو تمثيل دقيق لتقييمات المدرس الأول، ويوفر توافقاً جيداً مع البيانات. بالنسبة للمدرس الثاني، تبلغ قيمة الانحراف المعياري 1.82 (وهي قيمة كبيرة مقارنة بقيمة المتوسط). ومن الواضح أن تقييمات المدرس الثاني مبعثرة بعيداً عن قيمة المتوسط، فهو تلقى تقييماً

مرتفعاً جداً في بعض المحاضرات، وتقييمات أخرى مروعة. لذلك فإن المتوسط ليس تمثيلاً دقيقاً لأدائه بسبب وجود تغايرية كبيرة في شعبية محاضراته. إن المتوسط هو توافق رديء للبيانات في هذه الحالة. ينبغي أن يكون هذا المثال التوضيحي مفيداً في توضيح أسباب استخدام الانحراف المعياري كمقياس لمدى تمثيل المتوسط للبيانات.

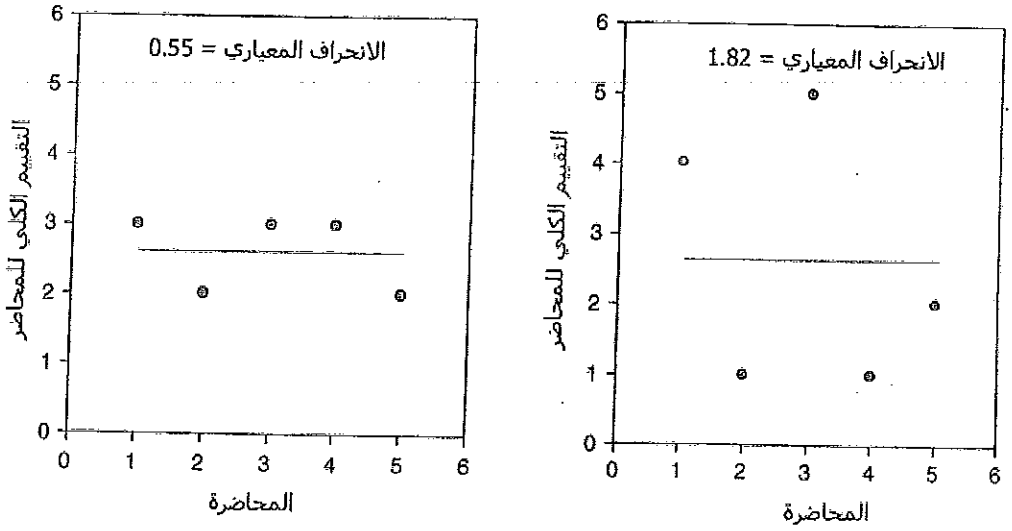

الشكل 3.1 يوضح المخططان البيانات التي تملك نفس المتوسط ولكنها تختلف بقيمة الانحراف المعياري

قد تبدو مناقشة المتوسطات ومجموع مربعات الأخطاء والتباين مسألة جانبية بعيدة عن نقطة الإنطلاق، ولكن ربما يكون المتوسط واحداً من أبسط النماذج الإحصائية التي يمكن استخدامها لتوافق البيانات. ماذا نعني بذلك؟ حسناً، إن كل شيء في الإحصاء يتلخص بشكل أساسي بمعادلة واحدة:

$$Outcome_i = (Model)_i + error_i$$

وهذا يعني أنه يمكن التنبؤ بالبيانات التي نراقبها من خلال النموذج الذي اخترناه لتمثيلها وإضافة مقدار معين من الخطأ. عندما تحدثنا عن المتوسط كنموذج إحصائي بسيط فإن كل ما قصدناه هو أنه يمكننا استبدال الكلمة Model بالكلمة "متوسط" في المعادلة السابقة. إذا عدنا إلى مثالنا المتضمن عدد الأصدقاء لكل من مدرسي الإحصاء، ونظرنا إلى المدرس رقم 1 الذي يملك صديقاً واحداً فقط، ولاحظنا أن المتوسط لجميع المدرسين كان 2.6 فإن المعادلة السابقة تصبح:

$$Outcome_{lecturer1} = \overline{X} + \varepsilon_{lecturer1}$$

$$1 = 2.6 + \varepsilon_{lecturer1}$$

ومن هذه المعادلة نستنتج أن قيمة الخطأ هي 1.6- = 2.6 - 1. إذا عوضنا هذه القيمة في المعادلة فإننا نحصل على 1.6 - 2.6 = 1 أو 1 = 1. قد يبدو أننا نلاحظ ما هو بديهي، ولكن حفظ هذه المعادلة العامة سيجعلك تكتشف أن معظم الأشياء تنتج في النهاية عن هذه الفكرة البسيطة.

وبشكل مشابه، فإن التباين والانحراف المعياري يوضحان مبدأ أساسياً آخر هو كيفية قياس مدى جودة التوافق للنموذج. إذا كنا نبحث عن مدى توافق النموذج مع البيانات (في هذه الحالة النموذج هو المتوسط) فإن علينا النظر بشكل عام إلى الانحراف عن النموذج، ننظر إلى مجموع مربعات الخطأ، وبالمصطلحات العامة يمكننا كتابة ذلك بالشكل:

الانحراف = مجموع مربعات (القيم المشاهدة — النموذج)

$$\text{Deviation} = \Sigma(\text{observed} - \text{model})^2$$

وبطريقة أخرى، نحن نقيّم النماذج بمقارنة البيانات التي نراقبها مع النموذج الذي نستخدمه لتمثيل تلك البيانات، ونقوم بتربيع تلك الفروق. ومرة أخرى، سنعود لهذه الفكرة الأساسية مرات عديدة عبر هذا الكتاب.

5.1 التوزيعات التكرارية

عندما تنتهي من جمع بعض البيانات فإنه يمكنك القيام بعمل مفيد جداً هو رسم مخطط يبين عدد مرات حدوث كل نقطة من البيانات. يدعى هذا المخطط بالتوزيع التكراري (frequency distribution) أو المخطط التكراري (histogram) وهو ببساطة مخطط يضع قيم المشاهدات على المحور الأفقي مع أعمدة تمثل عدد مرات حدوث كل قيمة في مجموعة البيانات. يمكن أن يكون التوزيع التكراري مفيداً جداً في تقييم الخصائص لتوزيع النقاط. وبنظرة واحدة إلى النقطة التي تملك العمود الأطول يمكننا معرفة المنوال (mode) مباشرة، وهو ببساطة النقطة الأكثر حدوثاً في مجموعة البيانات.

تتنوع أشكال وأحجام التوزيعات التكرارية. ولذلك فإن من المهم جداً معرفة الوصف العام لأكثر التوزيعات استخداماً. في عالم مثالي، تتوزع البيانات بشكل متناظر حول قيمة مركزية لجميع النقاط. إذا رسمنا خطاً شاقولياً يمر من مركز التوزيع التكراري فإن شكل التوزيع يجب تكون متماثلاً على طرفي هذا الخط. وفي هذه الحالة نقول إنه توزيع طبيعي (normal distribution)، ويتميز بمنحني يشبه شكل الجرس، ربما تعرفت إليه سابقاً. يَفترض هذا الشكل توزع غالبية النقاط حول مركز التوزيع (لذلك فإن أطول الأعمدة تتوضع حول القيمة المركزية). كما يفترض أنه كلما ابتعدنا عن المركز أصبحت الأعمدة أقصر، وهذا يعني أنه عند بدء انحراف النقاط عن المركز يبدأ تكرارها بالانخفاض. وعند انتقالنا بعيداً عن المركز تصبح النقاط قليلة التكرار (تصبح الأعمدة أقصر). يوضح (الشكل 4.1) مثالاً عن التوزيع الطبيعي.

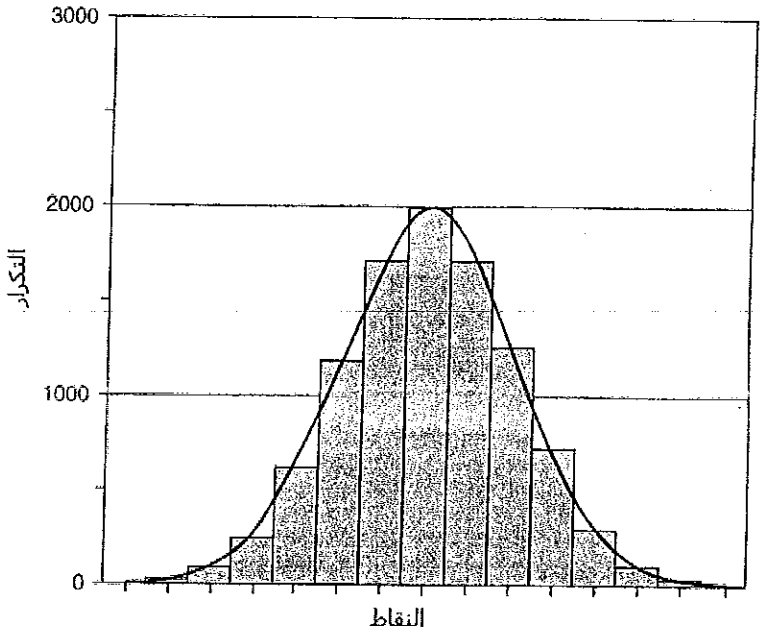

الشكل 4.1 توزيع طبيعي (يوضح المنحني الشكل المثالي)

1.5.1 خصائص التوزيع التكراري

يمكن لأي توزيع أن ينحرف عن التوزيع الطبيعي بإحدى الطريقتين الأساسيتين التاليتين:

- انعدام التناظر (ويدعى الميلان skewness)
- التدبب (ويدعى درجة التحدب kurtosis)

إن التوزيعات المائلة غير متناظرة، وتتراكم النقاط الأكثر تكراراً (الأعمدة الأطول في المخطط) في أحد طرفي المحور الأفقي. لذلك فإن الشكل النموذجي هو تراكم النقاط المتكررة في أحد طرفي المحور الأفقي وانخفاض طول الأعمدة عند الانتقال إلى الطرف الآخر. يمكن أن يكون التوزيع المائل إيجابي الميلان (positively skewed) (تتراكم النقاط الأكثر تكراراً عند النهاية الدنيا ويتناقص التكرار عند الانتقال إلى النهاية العليا) أو سلبي الميلان (negatively skewed) (تتراكم النقاط الأكثر تكراراً عند النهاية العليا ويتناقص التكرار عند الانتقال إلى النهاية الدنيا). يبين (الشكل 5.1) أمثلة عن هذه التوزيعات.

تتغير التوزيعات أيضاً بدرجة التحدب. وتعبر درجة التحدب عن درجة تراكم النقاط في طرفي التوزيع. وتظهر هذه الميزة بمدى تسطّح أو تدبب التوزيع. عندما تتوزع معظم النقاط في طرفي التوزيع فإننا نقول عن التوزيع أنه مسطّح (platykurtic) (كما يقال عنه توزيع مثقل الأطراف (heavy-tailed distribution)). وبالمقابل عندما يكون التوزيع نحيفاً نسبياً في الأطراف ومدبباً في المركز فإننا نقول عنه مدبب (leptokurtic). يبين (الشكل 6.1) أمثلة عن هذه التوزيعات.

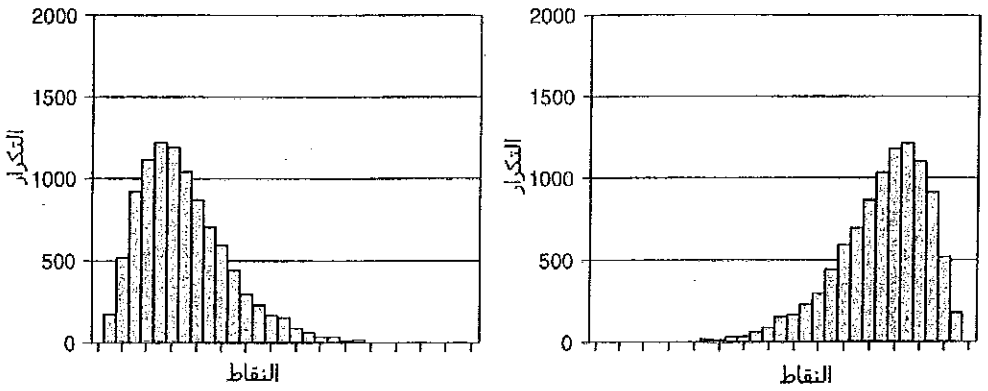

الشكل 5.1 توزيع سلبي الميلان (إلى اليمين) وتوزيع إيجابي الميلان (إلى اليسار)

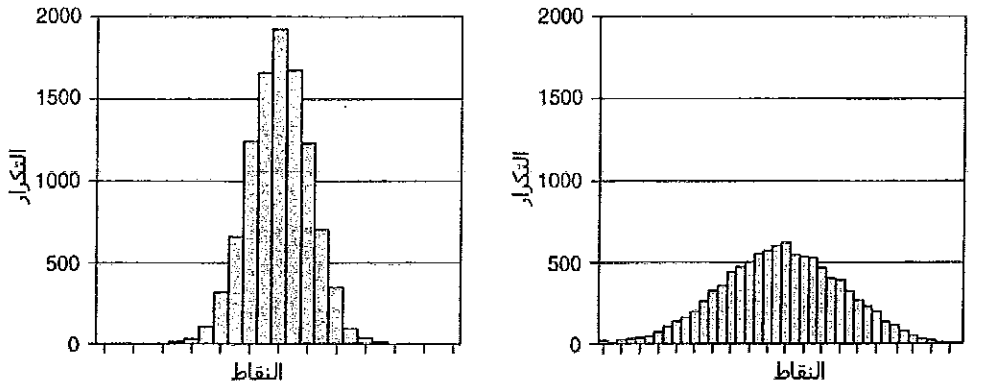

الشكل 6.1 توزيع مسطّح (إلى اليمين) وتوزيع مدبب (إلى اليسار)

وبشكل مثالي فإننا نرغب أن تتوزع بياناتنا بشكل طبيعي (أي أن لا تكون مائلة أو مسطّحة أو مدببة).

في التوزيع الطبيعي تكون قيم عدم التناظر (الميلان) و التدبب (درجة التحدب) مساوية للصفر (فالتوزيع ليس مدبباً جداً وليس مسطحاً تماماً، كما أنه متناظر بشكل تام). إذا كان للتوزيع قيماً تختلف عن الصفر لأي من الميلان أو التدبب فهذا يدل على انحرافه عن التوزيع الطبيعي (انظر الفصل الثالث).

2.5.1 الانحراف المعياري وشكل التوزيع

يدلنا التباين والانحراف المعياري على مدى دقة استخدام المتوسط كنموذج لتمثيل مجموعة البيانات، كما يخبراننا عن شكل التوزيع للنقاط. إذا كان المتوسط يمثل البيانات بشكل جيد فإن معظم النقاط

ستتراكم قريباً من المتوسط ويكون الانحراف المعياري الناتج صغيراً مقارنة بقيمة المتوسط. وعندما يكون المتوسط ممثلاً رديئاً للبيانات فإن النقاط ستنتشر حول المتوسط (انظر الشكل 3.1 مرة أخرى) وتكون قيمة الانحراف المعياري كبيرة نسبياً. يعرض (الشكل 7.1) توزيعين لهما نفس المتوسط (50) مع قيم مختلفة للانحراف المعياري. قيمة الانحراف المعياري لأحدهما كبيرة مقارنة مع قيمة المتوسط (SD = 25) وهذا يعطي توزيعاً مسطّحاً أي أنه منتشر بشكل موسّع. بينما قيمة الانحراف المعياري للآخر صغيرة مقارنة مع قيمة المتوسط (SD = 15) مما يعطي توزيعاً أكثر تدبباً تكون فيه النقاط القريبة من المتوسط أكثر تكراراً، بينما النقاط البعيدة عن المتوسط تصبح أقل تكراراً. الرسالة الرئيسية التي يجب استيعابها هي أنه كلما كانت قيمة الانحراف المعياري أكبر صار التوزيع أكثر تسطحاً.

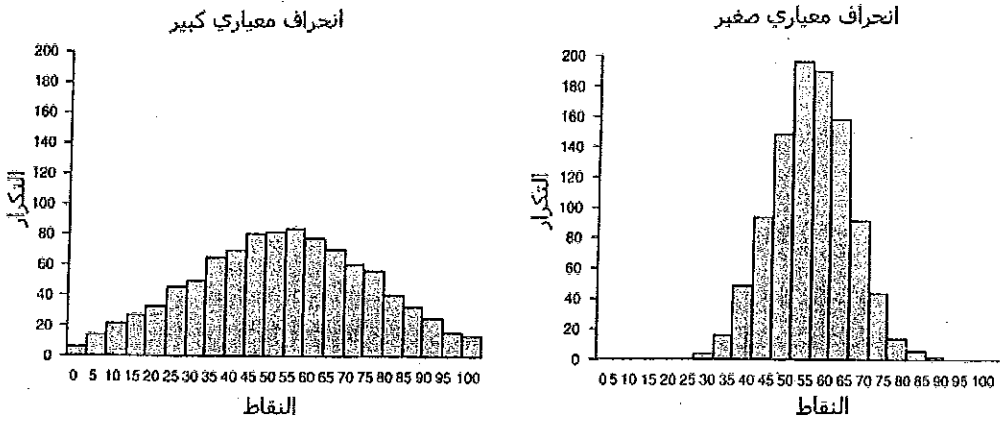

الشكل 7.1 توزيعان لهما نفس قيمة المتوسط مع قيمة صغيرة وأخرى كبيرة للانحراف المعياري

3.5.1 ما هو التوزيع الطبيعي المعياري؟

يمكن النظر إلى التوزيعات التكرارية بطريقة أخرى وذلك من خلال مفهوم الاحتمالات، فهي تعطينا فكرة عن احتمال حدوث نتيجة أو نقطة معطاة. يقع جرف Beachy Head الكبير على شاطئ Sussex، ويشتهر بجذبه للناس الراغبين بالانتحار. يبين (الشكل 8.1) توزيعاً تكرارياً لبعض البيانات الكاملة عن عدد الأشخاص المنتحرين من مختلف الأعمار عند Beachy Head في سنة ما. بلغ العدد الإجمالي لحالات الانتحار 171 حالة ويمكننا أن نرى أن معظم المنتحرين تتراوح أعمارهم بين 26 و 30 عاماً (العمود الأطول). يوضح المخطط أيضاً أن عدداً قليلاً من الأشخاص الذين كانت أعمارهم أكثر من 70 عاماً قد انتحروا عند Beachy Head.

لقد ذكرنا في بداية الفقرة أنه يمكننا التفكير بالتوزيع التكراري بمصطلحات الاحتمال. ولتوضيح ذلك، تخيل أن شخصاً سألك "ما احتمال أن ينتحر شخص عمره 70 عاماً عند Beachy Head ؟"، ماذا سيكون جوابك؟ إذا نظرت إلى التوزيع التكراري فمن المرجح أن يكون جوابك "ليس محتملاً

جداً" لأنك ترى أن شخصين فقط من أصل 171 كانت أعمارهم حوالي 70 عاماً قد انتحرا. وماذا لو سألك "ما احتمال أن ينتحر شخص عمره 30 عاماً ؟". مرة أخرى، إذا نظرت إلى المخطط فإن جوابك ربما سيكون "محتمل جداً" وذلك لأن عدد الأشخاص الذين كانوا بين عداد المنتحرين البالغ 171 وكانت أعمارهم قريبة من 30 عاماً هو 32 شخصاً (هناك أكثر من شخص بين كل 5 منتحرين).

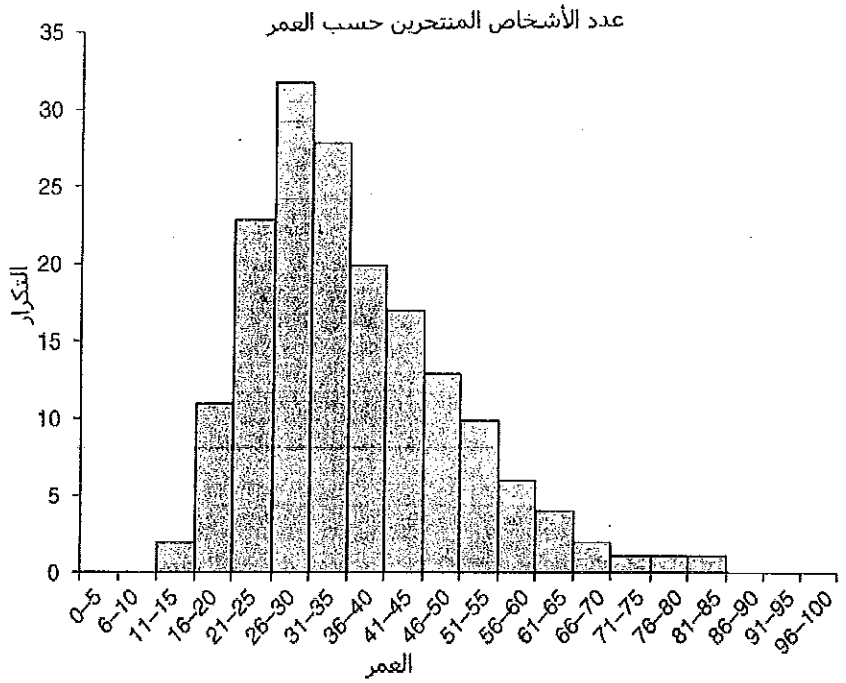

الشكل 8.1 توزيع تكراري يبين عدد الأشخاص المنتحرين عن Beachy Head في سنة ما حسب العمر

وهكذا اعتماداً على التكرارات للنقاط المختلفة بدأ يتضح أننا نستطيع استخدام هذه المعلومة لتقدير احتمال حدوث نتيجة معينة. إذاً يمكننا أن نسأل بناءً على بياناتنا ما هو احتمال أن يكون عمر أحد ضحايا الانتحار بين 16 و20 عاماً ؟ الاحتمال هو قيمة محصورة بين 0 (ليس هناك فرصة لوقوع حدث معين) و1 (الحدث سيقع بشكل أكيد).

لقد تكلمنا بمصطلحات غامضة نوعاً ما عن كيفية استخدام التوزيعات التكرارية للحصول على فكرة تقريبية عن احتمال حدوث نتيجة معينة. ولكن يمكننا أن نكون أكثر دقة. فمن أجل توزيع تكراري للنقاط، يمكننا نظرياً أن نحسب احتمال الحصول على نتيجة ذات حجم معين. صحيح أن ذلك يعتبر عملاً شاقاً ومعقداً ولكننا نستطيع إنجازه. ولتوفير هذا الجهد، فقد قام الإحصائيون بتحديد مجموعة من التوزيعات الشائعة. ومن أجل كل توزيع فقد استنتج الإحصائيون صيغة

رياضية تحدد النسخ المثالية من هذه التوزيعات (وهي محددة المواصفات من ناحية الخط المنحني). تُعرف هذه التوزيعات المثالية باسم التوزيعات الاحتمالية (probability distributions)، ومن هذه التوزيعات يمكن حساب احتمال الحصول على نتيجة معينة بناءً على التكرارات التي تحدث عندها نتيجة معينة في توزيع ما مع هذه الأشكال الشائعة. ومن هذه التوزيعات "الشائعة" يمكن أن نذكر التوزيع الطبيعي، الذي ذكرناه سابقاً. لقد قام الإحصائيون بحساب احتمال حدوث نتائج معينة في التوزيع الطبيعي حيث قيمة المتوسط 0 والانحراف المعياري 1. لذلك إذا كانت لدينا أية بيانات تأخذ شكلاً مشابهاً للتوزيع الطبيعي، وكانت قيمة المتوسط 0 والانحراف المعياري 1 فإنه يمكننا استخدام جدول الاحتمال للتوزيع الطبيعي لمعرفة احتمال حدوث نتيجة معينة في البيانات (يحوي الملحق A1 ذلك الجدول).

المشكلة الواضحة هي عدم امتلاك جميع البيانات التي نجمعها لمتوسط قيمته 0 وانحراف معياري 1. فقد نحصل مثلاً على مجموعة من البيانات تكون قيمة المتوسط فيها 567 وقيمة الانحراف المعياري 52.98. لحسن الحظ أنه يمكننا تحويل أية مجموعة من البيانات إلى مجموعة أخرى ذات متوسط يبلغ 0 وانحراف معياري 1. يجب أولاً إجراء تمركز للبيانات عند القيمة 0 وذلك بأن نأخذ كل قيمة من البيانات ونطرح منها قيمة المتوسط. بعد ذلك نقسم النقاط الناتجة على الانحراف المعياري للتأكد من أن قيمة الانحراف المعياري للبيانات أصبحت 1. تُدعى النقاط الناتجة بالعلامات المعيارية أو العلامات z (z-scores)، وتكون معادلتها بحسب التحويلات التي قدمناها هي:

$$z = \frac{X - \overline{X}}{s}$$

يحوي الملحق A1 قيم الاحتمال التي تم حسابها للتوزيع الطبيعي المعياري. ولكن ما أهمية ذلك الجدول؟ حسناً، إذا نظرنا إلى البيانات الخاصة بالانتحار مرة أخرى، فإنه يمكننا الإجابة على السؤال التالي "ما احتمال أن يكون عمر أحد الذين انتحروا عند Beachy Head 70 عاماً أو أكثر؟". نقوم أولاً بتحويل القيمة 70 إلى علامة z. إذا كانت القيمة المتوسطة لبيانات الانتحار هي 36 مع انحراف معياري يبلغ 13، وبذلك فإن القيمة 70 تصبح 2.62 = 13 / (36 – 70). نبحث بعد ذلك عن هذه القيمة في العمود المسمى القسم الأصغر (المساحة التي تقع فوق القيمة 2.62) فنجد قيمة الاحتمال 0.00440، وهذا يعني أن احتمال انتحار شخص يبلغ من العمر 70 عاماً أو أكثر هو 0.44%. إذا نظرنا إلى العمود المسمى القسم الأكبر فإننا نجد احتمال أن يكون عمر المنتحر أقل من 70 عاماً. قيمة الاحتمال هي 0.9956 أي أن احتمال أن يكون عمر المنتحر أقل من 70 عاماً هو 99.56%.

لقد رأينا من خلال هذه الأمثلة أن التوزيع الطبيعي و العلامات z يسمحان لنا بإجراء الخطوة الأولى للاستفادة من البيانات الموجودة بشكل مجموعة من النقاط وذلك بحساب احتمال وقوع حدث معين. وبذلك يمكننا معرفة فيما إذا كانت مجموعة من النتائج بحجم معين ستحدث أم لا في توزيع من نوع محدد. وسنرى مدى فائدة ذلك لاحقاً، ولكن من الأفضل في هذه المرحلة الإشارة

إلى أن بعض العلامات z ذات أهمية خاصة، وذلك لأن قيمها تزيل نسباً مئوية معينة من التوزيع. القيمة الهامة الأولى للعلامة z هي 1.96 وذلك لأن هذه القيمة تزيل قيمة 2.5% من قمة التوزيع، والنقطة المقابلة لها في الطرف الآخر (1.96-) تزيل 2.5% من أسفل التوزيع. وعند أخذ القيمتين معاً فإنهما تزيلان 5% من النقاط، أو بطريقة أخرى يمكننا القول أن 95% من العلامات z تقع بين 1.96- و 1.96. النقطة الهامة الثانية ومقابلتها هما 2.58± وهما تزيلان 1% من النقاط، أو بعبارة أخرى تقع 99% من العلامات z بين 2.58- و2.58. أما النقطة الهامة الثالثة ومقابلتها فهما 3.29± وهما تزيلان 0.1% من النقاط، أو بعبارة أخرى تقع 99.9% من العلامات z بين 3.29- و3.29. تذكر جيداً هذه القيم لأنها ستظهر مراراً وتكراراً.

6.1 هل العينة ممثلة للمجتمع؟

1.6.1 الخطأ المعياري

رأينا سابقاً أن الانحراف المعياري والتوزيعات التكرارية تعطينا بعض المعلومات عن كيفية تمثيل المتوسط للبيانات، ولكننا أشرنا أيضاً إلى أننا نجمع عادة البيانات من عينات وليسُ من المجتمع بكامله. وذكرنا أيضاً أنه إذا أخذنا عدة عينات من مجتمع ما، فإن هذه العينات ستختلف عن بعضها نوعاً ما. ولذلك فمن الضروري معرفة مدى تمثيل عينة ما للمجتمع. وهنا يأتي دور الخطأ المعياري (standard error). ويرتبك بعض الطلاب في معرفة الفرق بين الانحراف المعياري والخطأ المعياري (وذلك لأنه نادراً ما يتم توضيح الفرق بينهما). على كل حال، سنحاول في هذه الفقرة شرح مفهوم الخطأ المعياري لأنه مفهوم أساسي ينبغي إدراكه.

رأينا سابقاً أن علماء الاجتماع يستخدمون العينات كوسيلة لتقدير السلوك في مجتمع ما. تخيل أننا نهتم بتقييم جميع المدرسين (المدرسون في هذه الحالة هم المجتمع). يمكننا أخذ عينة من هذا المجتمع. وعندما يقوم شخص ما بأخذ عينة من مجتمع ما، فهو يأخذ واحدة من مجموعة متاحة من العينات. إذا أخذنا عدة عينات من نفس المجتمع، فإن لكل عينة متوسط خاص بها، وستكون بعض قيم المتوسطات لهذه العينات مختلفة (لن يكون لجميع العينات نفس قيمة المتوسط).

يوضح (الشكل 9.1) عملية أخذ العينات من مجتمع ما. تخيل أنه يمكننا الحصول على تقييم لجميع المدرسين على الكوكب وأن قيمة المتوسط هي 3 (هذه القيمة هي المتوسط للمجتمع population mean). ولكننا عملياً لا نستطيع جمع التقييمات لجميع المدرسين، لذلك نأخذ عينة ما. يمكننا حساب المتوسط لكل عينة من هذه العينات وندعوه متوسط العينة (sample mean). لنفترض أننا أخذنا 9 عينات مختلفة (كما في الشكل)، نلاحظ أن بعض هذه العينات تملك متوسطاً مساوياً لمتوسط المجتمع، ولكن لبعضها الآخر متوسط مختلف. فقيمة المتوسط للعينة الأولى من المدرسين كانت 3، بينما كانت في العينة الثانية 2 فقط. يوضح ذلك تغاير أخذ العينات (sampling variation) أي أن العينات تكون مختلفة عن بعضها لأنها تحوي عناصر مختلفة من

المجتمع. فالعينة التي تحوي (بالصدفة) بعض المدرسين الممتازين سيكون تقييمها مرتفعاً وبالتالي فإن قيمة المتوسط تكون أعلى من عينة أخرى تحوي (بالصدفة) بعض المدرسين الأقل كفاءة. يمكننا الآن رسم قيم المتوسط للعينات كتوزيع تكراري أو مخطط تكراري[1] كما في الشكل. يبين هذا التوزيع أن هناك 3 عينات تبلغ قيمة المتوسط فيها 3، وعينتان تبلغ قيمة المتوسط 2 في كل منهما، وعينتان تبلغ قيمة المتوسط 4 في كل منهما، وعينة واحدة تبلغ قيمة المتوسط فيها 1، وعينة أخرى كانت قيمة المتوسط فيها 5. وتبدو النتيجة النهائية كتوزيع متناظر متقن يدعى بتوزيع أخذ العينات (sampling distribution). توزيع أخذ العينات هو ببساطة توزيع تكراري لقيم المتوسط للعينات المأخوذة من نفس المجتمع. ونظرياً، يجب أن نأخذ مئات أو آلاف العينات لإنشاء توزيع أخذ العينات، ولكننا استخدمنا في المثال السابق 9 عينات فقط للمحافظة على بساطة الشكل! يخبرنا توزيع أخذ العينات عن سلوك العينات المأخوذة من المجتمع، ونلاحظ أنه متمركز عند قيمة المتوسط للمجتمع (في هذا المثال 3). وهذا يعني أنه إذا أخذنا المعدل لجميع متوسطات العينات فإننا نحصل على متوسط المجتمع. والآن إذا كان معدل متوسطات العينات مساوياً لقيمة متوسط المجتمع، وكنا نعلم مدى دقة ذلك المعدل فإننا سنعرف شيئاً عن مدى تمثيل عينة معطاة للمجتمع بأكمله. كيف يمكننا إذاً تحديد دقة متوسط المجتمع؟

لنعد الآن لمناقشة الانحراف المعياري. لقد استخدمنا الانحراف المعياري كمقياس لمدى تمثيل المتوسط للبيانات المشاهدة. فعندما تكون قيمة الانحراف المعياري صغيرة تكون معظم نقاط البيانات قريبة من المتوسط، وعندما تكون قيمته كبيرة تكون نقاط البيانات منتشرة بعيداً عن قيمة المتوسط. إذا أردنا حساب الانحراف المعياري بين قيم المتوسط للعينات فإن ذلك يعطينا مقياساً لمقدار التغيرية بين قيم المتوسط للعينات المختلفة. يدعى الانحراف المعياري لقيم المتوسط للعينات بالخطأ المعياري للمتوسط SE (standard error of the mean). وبذلك يمكن حساب الخطأ المعياري بأخذ الفرق بين المتوسط لكل عينة والمتوسط الكلي، ثم تربيع هذه الفروق وجمعها معاً وتقسيم الناتج على عدد العينات.

لا يمكننا في الحقيقة جمع مئات العينات لذلك فإننا نعتمد على تقديرات تقريبية للخطأ المعياري (من حسن حظنا أن عدداً من الإحصائيين الأذكياء قد أوجدوا طرقاً لاستنتاج الخطأ المعياري من الانحراف المعياري للعينة). ومن حسن حظنا أننا غير مجبرين على فهم كيفية عمل هذه التقديرات التقريبية. يمكننا أن نثق بأن هؤلاء الناس أذكياء وأنهم يعرفون عم يتحدثون. يمكن حساب الخطأ المعياري بتقسيم الانحراف المعياري للعينة (s) على الجذر التربيعي لحجم العينة[2] (N):

$$\sigma_{\bar{x}} = \frac{s}{\sqrt{N}}$$

---

1 مخطط تم فيه رسم متوسط العينة مقابل عدد العينات التي تملك هذا المتوسط. انظر الفصل 2 لمزيد من التفاصيل.

2 في الحقيقة، يجب تقسيم الانحراف المعياري للمجتمع (σ) على الجذر التربيعي لحجم العينة، ولكن من أجل العينات الكبيرة فإن هذا التقريب مقبول.

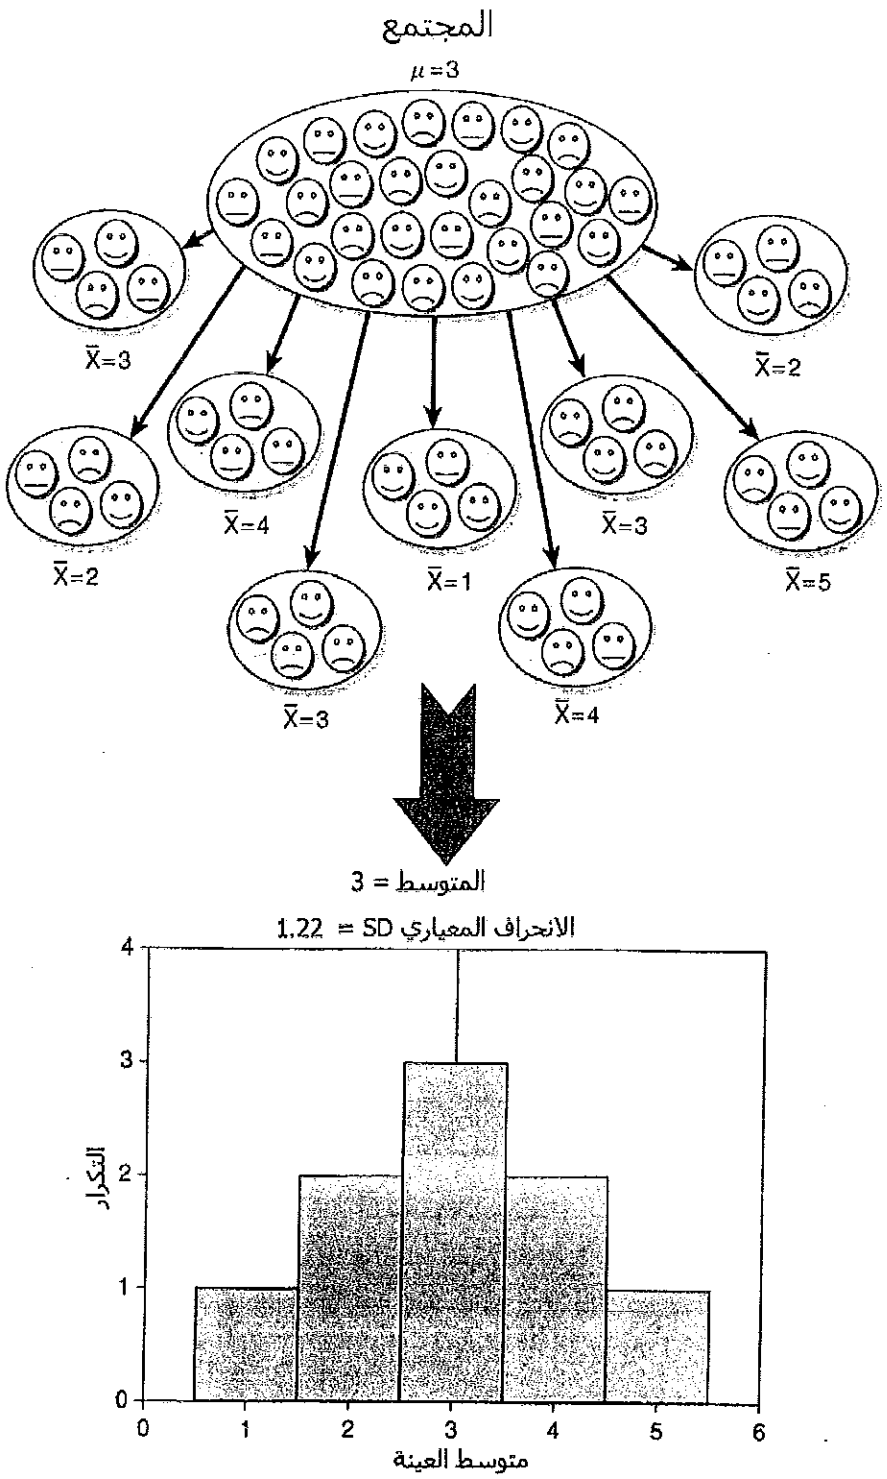

الشكل 9.1 توضيح مفهوم الخطأ المعياري (انظر النص لمعرفة التفاصيل)

تلميح: الخلاصة هي أن الخطأ المعياري هو الانحراف المعياري لقيم المتوسط للعينات. ولذلك فهو مقياس لمدى تمثيل عينة ما للمجتمع. وعندما يكون الخطأ المعياري كبيراً (مقارنة مع متوسط العينة) فهذا يعني وجود تغيرية كبيرة بين قيم المتوسط للعينات المختلفة وبالتالي فإن العينة قد لا تكون ممثلة للمجتمع. أما عندما يكون الخطأ المعياري صغيراً فهو يدل على أن معظم قيم المتوسط للعينات مشابهة لمتوسط المجتمع، والعينة ستمثل المجتمع بشكل دقيق.

2.6.1 مجالات الثقة

تذكر أننا نهتم عادةً باستخدام متوسط العينة كتقدير أو تخمين للقيمة الحقيقية للمتوسط (متوسط المجتمع). ولقد رأينا في الفقرة السابقة أن العينات المختلفة تزيد من اختلاف قيم المتوسط، وأنه يمكننا استخدام الخطأ المعياري لتكوين فكرة عن مدى اختلاف قيم المتوسط للعينات. هناك طريقة أخرى لتقييم دقة متوسط العينة كتقدير لمتوسط المجتمع، وهي حساب الحدود التي نعتقد أن قيمة المتوسط الحقيقية ستقع ضمنها. تدعى هذه الحدود بمجالات الثقة (confidence intervals). الفكرة الأساسية لمجالات الثقة هي بناء مجال من القيم نظن أن قيمة متوسط المجتمع تقع ضمنه.

لنأخذ المثال التالي: قام الباحثون Domjan, Blesbois & Williams (1998) بدراسة إطلاق السائل المنوي عند طائر السُماني الياباني. والفكرة الأساسية هي أنه إذا سُمح لذكر السماني بالتزاوج مع أنثى السماني في بيئة محددة (غرفة اختبار مثلاً) فإن هذه البيئة ستعمل كمُشعر بالتزاوج وسيؤثر ذلك بدوره على تحرير السائل المنوي. إذا نظرنا على الكمية المتوسطة للسائل المنوي المحرر في غرفة الاختبار فهناك قيمة متوسط حقيقي (المتوسط في المجتمع) ولنفترض أن هذه القيمة كانت 15 مليون حيوان منوي. في المثال العملي قد نجد أن الكمية المتوسطة للسائل المنوي المحرر كانت 17 مليون. وبما أننا لا نعرف القيمة الحقيقية للمتوسط، فإننا لا نعلم فيما إذا كان متوسط العينة (17 مليون) هو تقدير جيد أم لا. بدلاً من ذلك يمكننا تقدير مجال بحيث تكون قيمة متوسط العينة هي النقطة الوسطى فيه، مع تعيين الحدين الأدنى والأعلى أيضاً. وبذلك يمكننا القول أن قيمة المتوسط الحقيقي لكمية السائل المنوي المحرر تقع بين القيمتين 12 مليون و 22 مليون حيوان منوي (لاحظ أن قيمة متوسط العينة 17 مليون تقع في منتصف هذا المجال). نلاحظ في هذه الحالة أن القيمة الحقيقية (15 مليون) تقع ضمن المجال المفترض. ولكن لو أننا اخترنا مجالاً أصغر وتوقعنا أن تكون القيمة الحقيقة للمتوسط في المجال بين 16 مليون و18 مليون (ومرة أخرى لاحظ أن قيمة متوسط العينة تقع في منتصف المجال)، فإن هذا المجال لن يحوي القيمة الحقيقية لمتوسط المجتمع. لنركز الآن على مسألة السائل المنوي للسُماني الياباني، ولنكرر التجربة 50 مرة باستخدام عينات مختلفة. وفي كل مرة نجري فيها التجربة نقوم بإنشاء مجال حول قيمة المتوسط للعينة كما شرحنا سابقاً. يوضح (الشكل 10.1) هذا السيناريو، تمثل الدوائر قيمة المتوسط لكل عينة، بينما تمثل الخطوط الممتدة على طرفي الدائرة المجال لهذا المتوسط. وتم تمثيل القيمة الحقيقية للمتوسط (متوسط المجتمع) والبالغة 15 مليون

بخط شاقولي. إن أول ما يمكننا ملاحظته هو أن معظم قيم المتوسط للعينات مختلفة عن المتوسط الحقيقي (وهذا يعود لتغاير أخذ العينات كما أوضحنا في الفقرة السابقة). وثانياً، أن معظم المجالات تحوي القيمة الحقيقية للمتوسط بين حديها (حيث يتقاطع الخط الشاقولي الممثل للقيمة 15 مليون مع أحد طرفي المجال)، ولكن هناك بعض المجالات التي لا تتقاطع معها.

لقد تجنبنا حتى الآن الحديث عن كيفية حساب مجالات الثقة. إن الأمر الحاسم في مجالات الثقة هو أنه يجب بناؤها بطريقة تسمح لتلك المجالات بإعطائنا شيئاً مفيداً. ولذلك نقوم بحسابها بحيث تملك بعض الخصائص، وعلى وجه التحديد أن تكون قادرة على إعلامنا باحتوائها على القيمة الحقيقية التي نحاول تقديرها (قيمة المتوسط في هذا المثال).

نبحث عادة عن مجالات ثقة 95%، وأحياناً 99%، ولكنها تملك جميعاً تفسيراً متشابهاً: يتم بناء حدي المجال بحيث تكون القيمة الحقيقية لمتوسط المجتمع بين هذين الحدين بنسبة مئوية معينة (95% أو 99%). لذلك عندما نرى مجال ثقة 95% لقيمة المتوسط فإنه يمكننا تفسير ذلك بالشكل التالي: إذا جمعنا 100 عينة وحسبنا قيمة المتوسط لكل منها، ثم حددنا مجال الثقة لذلك المتوسط (كما فعلنا في الشكل 10.1) فمن أجل 95 من هذه العينات ستحوي مجالات الثقة التي حددناها القيمة الحقيقية للمتوسط في المجتمع.

لحساب مجال الثقة، علينا معرفة الحدود التي تقع ضمنها 95% من قيم المتوسط للعينات. وكيف يمكننا حساب هذه الحدود؟ تذكر أننا قلنا في الفقرة 3.5.1 أن القيمة 1.96 هي قيمة هامة للعلامة z (نقطة من التوزيع الطبيعي بقيمة متوسطة 0 وانحراف معياري 1) وذلك لأن 95% من العلامات z تقع بين الحدين 1.96- و 1.96. وهذا يعني أنه إذا كانت قيم المتوسط للعينات تملك المتوسط 0 والخطأ المعياري 1 فإن حدود مجال الثقة ستكون 1.96- و1.96. ربما تذكر أيضاً أننا نقوم بتحويل نقاط البيانات إلى علامات z باستخدام المعادلة التالية:

$$z = \frac{X - \overline{X}}{s}$$

إذا علمنا أن الحدود ستكون 1.96- و 1.96 للعلامات z، فما هي القيم الموافقة في نقاط البيانات لدينا؟ لاستنتاج ذلك نستبدل قيمة z في معادلة التحويل فنحصل على المعادلتين التاليتين

$$1.96 = \frac{X - \overline{X}}{s}$$

$$-1.96 = \frac{X - \overline{X}}{s}$$

وما نريد معرفته من هاتين المعادلتين هو قيم X، ولذلك نعيد ترتيب المعادلتين بالشكل التالي:

$$1.96 \times s = X - \overline{X} \Rightarrow (1.96 \times s) + \overline{X} = X$$

$$-1.96 \times s = X - \overline{X} \Rightarrow (-1.96 \times s) + \overline{X} = X$$

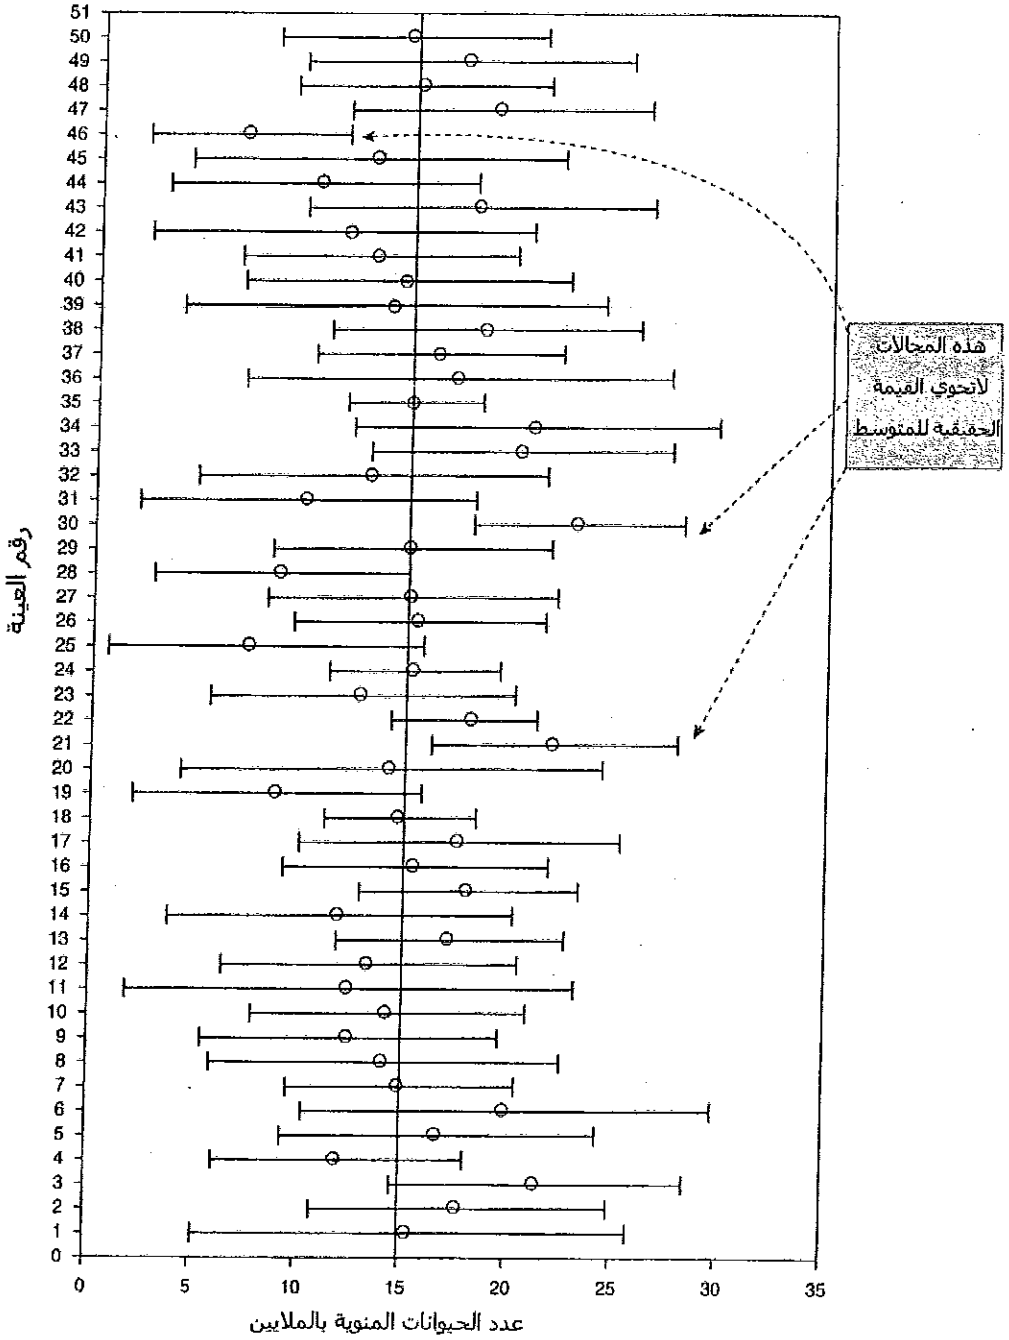

الشكل 10.1 توضيح لمجالات الثقة لعدد الحيوانات المنوية لطائر السُّماني الياباني (المحور الأفقي) من أجل 50 عينة مختلفة (المحور الشاقولي)

لذلك يمكننا حساب مجال الثقة بسهولة عند معرفة قيمة كل من الانحراف المعياري (قيمة s في المعادلات السابقة) والمتوسط ($\bar{X}$). على كل حال، نحن نستخدم الخطأ المعياري (SE) وليس

الانحراف المعياري وذلك لأننا نهتم بالتغيرية في قيم المتوسط للعينات وليس بالتغيرية في البيانات المشاهدة ضمن العينة. وبذلك تكون حدود مجال الثقة كما يلي:

$$\text{الحد الأدنى لمجال الثقة} = \overline{X} - (1.96 \times SE)$$

$$\text{الحد الأعلى لمجال الثقة} = \overline{X} + (1.96 \times SE)$$

وهكذا فإن المتوسط سيقع دائماً في مركز مجال الثقة. إذا كان المتوسط يمثل المتوسط الحقيقي بدقة، فإن مجال الثقة لذلك المتوسط سيكون صغيراً، وذلك لأن 95% من مجالات الثقة ستحوي القيمة الحقيقية للمتوسط. يمكننا أن نفترض أن مجال الثقة يحوي القيمة الحقيقية للمتوسط، ولذلك إذا كان المجال صغيراً فهذا يعني أن متوسط العينة قريب جداً من المتوسط الحقيقي. وبالعكس، إذا كان مجال الثقة عريضاً جداً فإن متوسط العينة قد يكون مختلفاً جداً عن المتوسط الحقيقي، مما يدل على أنه تمثيل رديء للمجموعة. وتذكر أننا سنعود عدة مرات للحديث عن مجالات الثقة في هذا الكتاب.

7.1 النماذج الخطية

المتوسط هو مثال عن النموذج الإحصائي، ولكن قد تتساءل ما هي الأنواع الأخرى للنماذج الإحصائية التي يمكن بناؤها. حسناً، إذا كانت الحقيقة معروفة فإن النموذج الوحيد الذي يتم استخدامه هو النموذج الخطي (linear model). قد لا يبدو واضحاً لبعض علماء الاجتماع أن العبارة السابقة صحيحة. وتبرير ذلك هو وجود مجموعة متنوعة من الأسماء المعطاة للإجرائيات الإحصائية والتي تعتمد على النموذج الخطي. إن تحليل التباين ANOVA (analysis of variance) والتراجع (regression) هما نظامان متماثلان (Cohen, 1968) مع أن أسماءهما مختلفة، ويُستخدمان بشكل واسع في بيئات مختلفة.

إن كلمة خطّي (linear) تعني حرفياً "متعلق بخط"، ولكن في المصطلحات الإحصائية فإن الخط المعني هو خط مستقيم. ولذلك فإن النموذج الخطي هو نموذج يرتكز على خط مستقيم، وهذا يعني أننا نحاول دائماً تلخيص البيانات المشاهدة بعلاقتها مع خط مستقيم. فعلى سبيل المثال، في الفصول التي تصف التراجع، سيغدو واضحاً بأنه يمكن لمتحولين أن يكونا مرتبطين عكسياً (وهذا يعني أنه مع ازدياد قيم المتحول الأول تنخفض قيم المتحول الثاني). في تلك الحالة يمكن تلخيص العلاقة بين المتحولين بخط مستقيم.

لنفترض أننا أحصينا عدد الفصول في هذا الكتاب التي قرأها شخص ما، ثم قسنا مقدار الغنى الفكري. يمكننا تمثيل هذه البيانات الافتراضية بشكل مخطط مبعثر حيث تمثل كل نقطة العلامة التي يعطيها شخص لكل من المتحولين. يعرض (الشكل 11.1) مثل ذلك المخطط، كما يعرض نفسَ المخطط ولكن مع خط مستقيم يلخص النمط لتلك البيانات. أما النسخة الثالثة من المخطط فتحوي خطاً منحنياً لتلخيص النمط العام للبيانات. وهكذا فإن (الشكل 11.1) يوضح كيفية استخدام أنواع مختلفة من النماذج لتمثيل البيانات ذاتها. في هذه الحالة يمكننا استخدام خط مستقيم

لتمثيل البيانات، ونرى أنه كلما ازداد عدد الفصول التي يقرأها الشخص ينخفض الغنى الفكري. يمكننا أيضاً أن نستخدم خطاً منحنياً لتلخيص البيانات وهذا يوضح أنه عند الانتهاء من قراءة معظم الفصول أو جميعها فإن الغنى الفكري يزداد قليلاً (تعليل منطقي لأنه عند الانتهاء من قراءة الكتاب يصبح فجأة لكل شيء معنى!). ليس من الضروري أن يكون أيّ من هذين النموذجين صحيحاً، ولكن أحدهما سيكون صحيحاً عندما يتوافق مع نقاط البيانات بشكل أفضل من الآخر، ولهذا فإنه عند استخدام نموذج إحصائي فمن المهم جداً تقييم مدى توافقه مع البيانات.

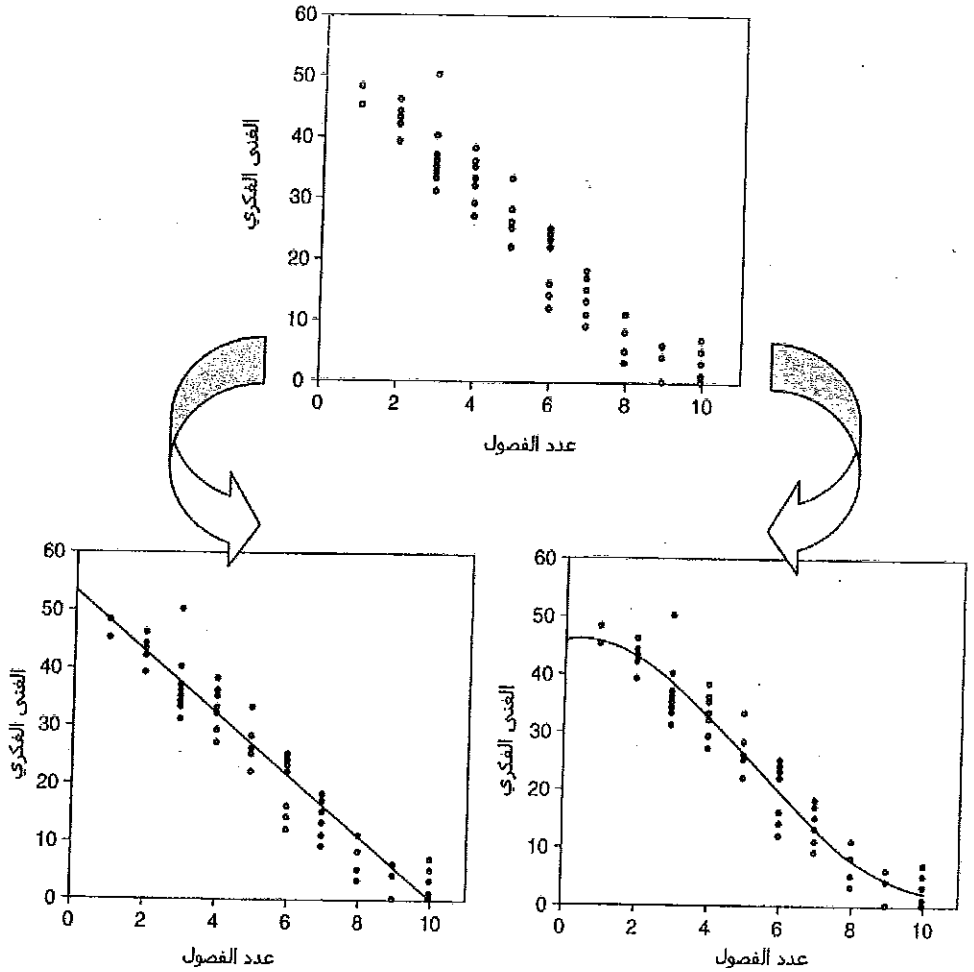

الشكل 11.1 مخطط مبعثر لبعض البيانات في ثلاث حالات: بدون نموذج يوافق البيانات (في الأعلى)، مع نموذج خطي (إلى اليسار)، مع نموذج لاخطي (إلى اليمين).

تعتمد معظم الإحصائيات المستخدمة في العلوم الاجتماعية على النماذج الخطية، التي تعني أننا نحاول ملاءمة نماذج الخط المستقيم مع البيانات المجمّعة. وهذا ممتع لأن معظم الدراسات العلمية

المنشورة متوافقة مع نتائج مهمة إحصائياً. وبناءً على ذلك فإن معظم علماء الاجتماع لا يعلّمون سوى المهارات المعتمدة على النموذج الخطي، والنتائج المنشورة ستكون تلك التي استخدمت النماذج الخطية بنجاح. أما البيانات التي توافق نموذجاً غير خطي فيبدو أنها تُهمَل بطريقة خاطئة (لأن النموذج غير الصحيح المطبق على البيانات سيقود لنتائج غير مهمة). ولهذا السبب يقوم الباحثون عادة برسم بياناتهم أولاً، فالمخططات تعطي فكرة عامة عن النماذج التي ينبغي تطبيقها على البيانات. لذلك فمن الممكن أن نرى أن بعض مجالات العلوم تتقدم بطريقة منحرفة، فإذا وجدت أن البيانات التي جمعتها تبدو غير خطية، لماذا لا تحاول تصحيح الميزان وتحاول البحث عن تقنيات إحصائية مختلفة (وهذا قول سهل للمؤلف خاصة عندما لا يتضمن الكتاب مثل تلك التقنيات!).

8.1 كيف يمكننا القول أن النموذج يمثل العالم الحقيقي؟

رأينا سابقاً كيف يمكننا استخدام العينات لتقدير ما الذي يحدث في المجتمع الأكبر الذي لا يمكننا الوصول إليه. كما رأينا أنه من المهم إثبات فيما إذا كان النموذج يوافق البيانات بشكل جيد أو رديء، وفيما إذا كان ممثلاً للمجتمع أم لا. لقد شرحنا كل ذلك باستخدام المتوسط كمثال عن النماذج الإحصائية، ولكن ماذا يحدث عندما يكون النموذج أكثر تعقيداً؟ يهتم العلماء عادة بمسائل أكثر تعقيداً مثل "هل من علاقة بين مقدار الكلام غير المفهوم الذي ينطقه الناس وكمية هلام الفودكا التي يتناولونها؟" أو "هل متوسط كمية الشوكولا التي تناولتها خلال تأليف كتب الإحصاء كانت أكبر منها في الحالات الأخرى؟". في هذه الحالات نستخدم نماذج أكثر تعقيداً، إذ أننا نبحث عملياً عن اكتشاف آثار معينة في المجتمع وتقدير هذه الآثار. تشرح هذه الفقرة بعض الطرق التي يمكن استخدامها لتقدير الآثار وتقرير فيما إذا كانت ذات دلالة أم لا. وتتكون هذه الطريقة بشكل أساسي من 4 مراحل (انظر المربع 1.1):

1. وضع فرضية تشكل توقعاً لوجود تأثير من نوع معين في المجتمع.
2. جمع بعض البيانات المفيدة.
3. تطبيق نموذج إحصائي على البيانات، حيث يختبر هذا النموذج التوقعات الأصلية.
4. تقييم هذا النموذج لمعرفة فيما إذا كان يدعم التوقعات الأولية أم لا.

يهتم العلماء عادة باختبار الفرضيات، إذ يختبرون الأسئلة العلمية التي يطرحونها. ضمن هذه الأسئلة، يضع الباحث عادة توقعاً. يُدعى هذا التوقع بالفرضية التجريبية (experimental hypothesis) (إنه التوقع بأن لعملية الاختبار أثراً معيناً أو أن بعض المتحولات مرتبطة ببعضها البعض). الإمكانية المعاكسة هي أن التوقع خاطئ وأن الأثر المتوقع لن يكون موجوداً، وهي تدعى فرضية العدم (null hypothesis). وفيما يلي مثالان عن ذلك:

1. الهمبرغر يجعلك سميناً: الفرضية التجريبية هي أن تناول المزيد من الهمبرغر سيجعلك تصبح أكثر بدانة. أما فرضية العدم فهي أن الناس متساوون في البدانة بغض النظر عن كمية الهمبرغر التي تناولوها.
2. الجبنة تسبب الكوابيس: الفرضية التجريبية هي أن الذين يأكلون الجبنة قبل النوم يتعرضون لكوابيس أكثر من أولئك الذي لا يأكلونها قبل النوم. أما فرضية العدم فهي أن الذين يأكلون الجبنة قبل النوم يتعرضون لنفس عدد الكوابيس تقريباً التي يتعرض لها من لا يأكل الجبنة قبل النوم.

المربع 1.1 الغش في البحث

تعمل الطريقة المكونة من 4 خطوات الموضحة في هذا الفصل بشكل جيد إذا تم إتباع الخطوات دون غش. لنفترض أننا نريد المراهنة على من سيربح كأس العالم بكرة القدم. قد نرغب بالمراهنة على الفريق الألماني، ولذلك نقوم بالخطوات التالية:

1. نحدد مبلغ المراهنة، ونختار الفريق (الألماني) والأفضليات المتوفرة في محلات المراهنة.
2. ننتظر نهاية البطولة لمعرفة الفريق الفائز.
3. نجمع مبالغ الربح في حال فوز الفريق الألماني.

ولإبقاء الجميع سعداء، ينبغي أن تكون هذه العملية عادلة. تقدم محلات المراهنة الأفضليات بحيث لا تدفع مبالغ كبيرة من المال (مما يبقيهم سعداء)، ولكن عليهم أن يدفعوا بعض المال للزبائن (لإبقاء زبائنهم سعداء). يمكن لمحلات المراهنة أن تقدم أية أفضليات قبل انتهاء البطولة، ولكن لا يمكنها تغيير الأفضليات بعد انتهاء البطولة (أو قبل بدء المباراة النهائية). وبشكل مشابه يمكننا اختيار أي فريق قبل البطولة، ولكن لا يمكننا تغيير الاختيار في منتصف المشوار أو بعد المباراة النهائية.

الوضع مشابه في حالة البحث، فنحن نستطيع اختيار الفرضية (فريق كرة القدم) التي نريدها قبل جمع البيانات، ولكن لا يمكننا تغيير رأينا في منتصف المشوار خلال جمع البيانات (أو بعد الانتهاء من جمع البيانات). وعلينا أيضاً تحديد مستوى الاحتمال (أو أفضليات المراهنة) قبل جمع البيانات. إذا فعلنا ذلك فإن الطريقة رباعية الخطوات ستعمل بشكل جيد. ولكن الباحثين يغشون أحياناً. فهم لا يكتبون فرضياتهم قبل القيام باختباراتهم، وأحياناً يقومون بتغييرها عند جمع البيانات، أو أسوأ من ذلك إذ يقررون وضع الفرضيات بعد الانتهاء من جمع البيانات. وباستثناء بعض الإجرائيات المعقدة التي تدعى اختبارات الخطأ المنطقي post hoc فإن ذلك غش. بشكل مشابه، يمكن أن يكون الباحثون مذنبين باختيار مستوى الأهمية الذين يرغبون باستخدامه بعد جمع البيانات وتحليلها، كما تفعل محلات المراهنة بتغيير أفضلياتها بعد انتهاء البطولة.

في كل مرة تقوم فيها بتغيير الفرضيات أو تفاصيل التحليل، تبدو كأنك تزيد الفرصة لإيجاد نتيجة مهمة، ولكنك في الحقيقة أنت تعمل باتجاه نشر نتائج لن يتمكن الباحثون الآخرون من إعادة إنتاجها (وهو أمر محرج جداً). إذا اتبعت القواعد بعناية وأجريت الاختبار الهام عند مستوى 5% فأنت تعلم على الأقل أنه على المدى الطويل ستكون نتيجة واحدة على الأكثر بين كل 20 هي محرجة.

يتعامل الجزء الأكبر من هذا الكتاب مع الإحصاء الاستدلالي الذي يخبرنا فيما لو كانت الفرضية التجريبية محتملة الصحة، ويساعد بالتالي على تأكيد توقعاتنا أو نفيها. وعند التخمين نقوم بملاءمة نموذج إحصائي لبياناتنا والتحقق من مدى توافقه مع البيانات (بمقدار التباين الذي يعلله). إذا لاءم النموذجُ البيانات بشكل جيد فإننا نفترض أن تقديرنا الأولي صحيح وعندها نقبل الفرضية التجريبية. بالطبع، لا يمكننا أن نكون متأكدين تماماً من أن الفرضية صحيحة، ولذلك نستخدم الاحتمالات. وبصورة أدق، فإننا نحسب احتمال أن تكون النتائج التي حصلنا عليها قد حدثت بالصدفة، وكلما انخفض هذا الاحتمال ازدادت ثقتنا بأن الفرضية التجريبية صحيحة عملياً وبأنه يمكننا نبذ فرضية العدم.

لتوضيح هذه الفكرة فقد قام Fisher (1925) بوصف تجربة مصممة لاختبار إدعاء امرأة ما بأنها قادرة، بعد أخذ رشفة من الفنجان، على تحديد فيما إذا كان الحليب أو الشاي قد وُضع في الفنجان أولاً. اعتقد Fisher بأن عليه أن يعطي المرأة بعض الفناجين التي تم فيها صب الحليب أولاً، وبعض الفناجين التي تم فيها صب الشاي أولاً، ومراقبة فيما إذا كانت قادرة على تحديد الفناجين بشكل صحيح. تعلم المرأة بأن هناك عدداً متساوياً من الفناجين التي تم فيها صب الحليب أولاً وتلك التي تم فيها صب الشاي أولاً، ولكنها لا تعرف الترتيب التي تم وضعها فيه. إذا أخذنا الحالة الأبسط التي يكون فيها فنجانان فقط فإن احتمال أن تعطي المرأة تخميناً صحيحاً هو 50%. إذا كان تخمين المرأة صحيحاً فهذا لا يعني أننا على ثقة بأنها تستطيع إخبارنا على الفرق بين الفناجين التي تم فيها صب الحليب أولاً وتلك التي تم فيها صب الشاي أولاً، وذلك لأن معظمنا قادر على إنجاز هذه المهمة بالتخمين فقط. لنأخذ الآن حالة معقدة حيث نضع 6 فناجين. هناك 20 طريقة لترتيب الفناجين، ويجب على المرأة أن تخمن الترتيب الصحيح في مرة واحدة من أصل الاحتمالات 20 الممكنة (أي أن الاحتمال هو 5% فقط). إذا أعطت المرأة الترتيب الصحيح فقد نكون في تلك الحالة على ثقة بأنها قادرة على تمييز الفناجين.

ليس عبثاً اختيارنا لحالة 6 فناجين، لأن Fisher اقترح بأنه يمكننا أن نقبل النتيجة كحقيقة عندما نكون متأكدين بنسبة 95% من أن النتيجة صادقة (وليست وليدة الصدفة). الطريقة المعاكسة للنظر إلى هذه المسألة هي القول بأنه إذا كان هناك احتمال 5% فقط لحدوث شيء ما بالصدفة، فإننا نقبل بأنه نتيجة الحقيقة، ونقول بأنه نتيجة ذات دلالة إحصائية (انظر المربع 2.1 لمزيد من التفاصيل عما تعنيه عبارة ذات دلالة إحصائية). يشكّل المعيار 95% من الثقة أساس علم الإحصاء الحديث، بالرغم من عدم وجود تبرير قوي له باستثناء ما قاله Fisher، وهو ذكي لدرجة تجعلنا نثق بحكمه (انظر الشكل 12.1). ومع ذلك فإننا نجد أحياناً بعض النتائج التجريبية ذات الدلالة باحتمال 93% فقط. ولكن مجلات البحث العلمي تميل باتجاه نشر النتائج الإيجابية (التي تدعم الفرضية التجريبية).

الشكل 12.1 السيد Ronald Fisher يتأمل نتائج وضعه p=0.05

1.8.1 إحصائيات الاختبار

كيف يمكننا أن نعرف أن النموذج الذي اخترناه هو تمثيل جيد لما يحدث في العالم الحقيقي؟ عندما نقوم بجمع البيانات، فإن البيانات التي نحصل عليها تكون متباينة (لقد رأينا في الفقرة 1.4.1. كيفية قياس هذا التباين). وهناك نوعان من التباين (انظر الفصل 7):

- **التغاير المنهجي (Systematic variation):** ينتج هذا التغاير عن مؤثر حقيقي (كأن يؤثر القائم بالاختبار على جميع المشاركين في عينة ما، ولا يؤثر على بقية العينات، أو التغاير الطبيعي بين مجموعات المتحولات). يمكننا أن نفكر بأن النموذج المستخدم لملاءمة البيانات يبرر مثل هذا التغاير.
- **التغاير اللامنهجي (Unsystematic variation):** لا ينتج هذا التغاير عن المؤثر الذي نهتم بدراسته (فقد ينتج عن الاختلافات الطبيعية بين البشر في العينات المختلفة كالاختلاف في الذكاء أو الدوافع). يمكننا أن نفكر بأن النموذج المستخدم لملاءمة البيانات لا يمكنه تبرير هذا التغاير.

إذا كنا نحاول معرفة فيما إذا كان النموذج هو تمثيل معقول لما يمكن أن يحدث في المجتمع، فإننا نقوم غالباً بحساب إحصائية الاختبار. وإحصائية الاختبار هي ببساطة إحصائية ذات خصائص معروفة، حيث نعلم مدى تكرار حدوث القيم المختلفة فيها. بمعرفة ذلك يمكننا حساب احتمال الحصول على قيمة معينة. بشكل مشابه استخدم Field and Hole (2003) العمر الذي يموت فيه الناس. تعطينا البيانات القديمة توزيع العمر عند الوفاة. فعلى سبيل المثال، نعلم أن متوسط الأعمار للرجال عند الوفاة هو 75 عاماً، وأن التوزيع مرتفع بمعنى أن معظم الناس يموتون في سن يزيد على

50 عاماً. لذلك فإن التكرارات لسن الوفاة في أعمار الشيخوخة مرتفعة جداً ولكنها أخفض بكثير في سن الشباب. من هذه البيانات يمكن حساب الاحتمال لموت شخص ما في سن معينة. فإذا سألنا شخصاً ما عن عمره وأجابنا 53 سنة، فيمكننا حساب احتمال موته قبل عيد ميلاده التالي (لا ننصحكم بالقيام بذلك، كي لا تعرضوا أنفسكم للخطر!). وإذا صادفنا شخصاً يبلغ 110 سنوات، فيمكننا حساب احتمال بقائه على قيد الحياة حتى هذه السن (سيكون الاحتمال ضئيلاً جداً لأن معظم الناس يموتون قبل الوصول إلى هذا العمر). الطريقة التي نستخدم بها إحصائيات الاختبار شبيهة بذلك نوعاً ما، حيث نعلم توزيعها وهذا يسمح لنا (بعد حساب إحصائية الاختبار) باكتشاف احتمال إيجاد أكبر قيمة بين القيم الموجودة. لذلك إذا حسبنا إحصائية اختبار وكانت قيمتها 110 يمكننا بعد ذلك حساب احتمال الحصول على قيمة كبيرة معادلة لها تقريباً.

كيف نحسب إذاً إحصائيات الاختبار تلك؟ يعتمد هذا على الإحصائية المستخدمة (وكما ستكتشف لاحقاً في هذا الكتاب، فإن هناك العديد منها: t و F و χ^2 وغيرها). تمثل معظم هذه الإحصائيات نفس الشيء بشكل أساسي:

$$\text{إحصائية الاختبار} = \frac{\text{التباين المبرر بالنموذج}}{\text{التباين غير المبرر بالنموذج}}$$

يتغير الشكل الدقيق لهذه المعادلة من اختبار إلى آخر، ولكننا نقارن دائماً مقدار التباين الذي يبرره النموذج الذي اخترناه لملاءمة البيانات مع مقدار التباين الذي لا يستطيع النموذج تبريره (انظر الفصلين 5 و 7 خاصة لمزيد من الشرح التفصيلي). والسبب الذي يبرر الفائدة الكبرى لهذه النسبة هو حدسي علمياً. فإذا كان النموذج جيداً فإننا نتوقع منه أن يكون قادراً على تبرير تباين أكبر مما لا يستطيع تبريره. وفي هذه الحالة فإن إحصائية الاختبار ستكون أكبر من 1 (ولكن ليس من الضروري أن تكون ذات دلالة).

بمعرفة ذلك فإننا نعلم مدى تكرار الحدوث لقيم مختلفة من إحصائيات الاختبار المختلفة بالصدفة، وبعد أن نحسب إحصائية اختبار معينة يمكننا حساب احتمال الحصول على هذه القيمة. وكما رأينا في الفقرة السابقة، فإن قيم الاحتمالات تخبرنا عن إمكانية أن يكون النموذج صحيحاً وليس ناتجاً عن الصدفة فقط. وكلما ازداد مقدار التغاير الذي يبرره النموذج (مقارنةً بالتغاير الذي لا يستطيع تبريره) ازدادت قيمة إحصائية الاختبار، وقل احتمال أن يكون حدوثها بالصدفة (مثل الرجل الذي يبلغ من العمر 110 أعوام). ولذلك، كلما أصبحت إحصائيات الاختبار أكبر، أصبح احتمال حدوثها أصغر. وعندما يقل هذا الاحتمال عن حاجز 0.05 (معيار Fisher)، فإننا نقبل ذلك لنكون على ثقة أكبر لافتراض أن إحصائية الاختبار كبيرة بهذا القدر لأن النموذج يبرر جزءاً كافياً من التغاير ليعكس ما يحدث فعلياً في العالم الحقيقي (المجتمع). أو بطريقة أخرى، نحن نقبل فرضية الاختبار التي وضعناها ونرفض فرضية العدم. وعلى كل حال تشرح الفقرة في المربع 2.1 بعض المفاهيم الخاطئة الشائعة حول هذه العملية.

٣٤

المربع 2.1 ما يمكن وما لا يمكن استنتاجه من إحصائية اختبار ذات دلا

1. **أهمية أثر ما:** لقد رأينا أن الفكرة الأساسية التي تكمن وراء اختبار الفرضية تتطلب منا فرضية الاختبار وفرضية العدم، ثم ملاءمة نموذج إحصائي للبيانات، وتقييم ذلك النموذج باستخدام إحصائية اختبار. إذا كان احتمال حصولنا على قيمة أقل من 0.05 لإحصائية الاختبار فإننا نقبل عموماً فرضية الاختبار كحقيقة، أي أن هناك أثراً في المجتمع. وعادةً نقول "هناك أثر ذو دلالة لـ ...". ولكن لا تخدعنك كلمة "ذو دلالة"، لأنه حتى لو كان احتمال أن ينتج الأثر عن الصدفة صغيراً (أقل من 0.05) فهذا لا يعني بالضرورة أن ذلك الأثر هام. يمكن للآثار الصغيرة جداً وغير الهامة أن تتحول إلى آثار ذات دلالة لأن عدداً هائلاً من الناس قد استخدمها في التجربة.
2. **النتائج غير المهمة:** بعد أن تحسب إحصائية الاختبار، تقوم بحساب احتمال أن تحدث إحصائية الاختبار صدفةً. إذا كانت قيمة الاحتمال أكبر من 0.05 فإنك ترفض فرضية الاختبار. ولكن هذا لا يعني أن فرضية العدم صحيحة. تذكّر أن فرضية العدم تعني عدم وجود أثر في المجتمع. و تبين النتيجة غير المهمة أن الأثر غير كبير و ناتج عن الصدفة وليس أي شيء آخر، ولكنها لا تقول بأن الأثر معدوم (يساوي 0). وكما أوضح Cohen (1990) بأنه لا يجب أبداً تفسير نتيجة غير مهمة (مع أنها غالباً كذلك) بعدم وجود فرق بين القيم المتوسطة أو بعدم وجود علاقة بين المتحولات. يلفت Cohen الانتباه أيضاً إلى أن فرضية العدم لا تعتبر حقيقة أبداً، لأننا نعلم من توزيعات أخذ العينات (الفقرة 6.1) أن قيم المتوسط في عينتين عشوائيتين مختلفة قليلاً عن بعضها البعض، ومع أن هذه الفروق قد تكون صغيرة جداً (فقيمة المتوسط لإحدى العينتين 10 مثلاً وللعينة الأخرى 10.0001) فإنها مع ذلك مختلفة. في الحقيقة، يتم اعتبار مثل ذلك الفرق الصغير ذو دلالة إحصائية إذا تم استخدامه في عينة كبيرة نسبياً. ولذلك فإن اختبار الأهمية أو الدلالة لا يمكن أن يدلنا على أن فرضية العدم صحيحة لأنها ليست كذلك أبداً.
3. **النتائج ذات الدلالة (أو المهمة):** صحيح أنه لا يمكننا قبول فرضية العدم كحقيقة ولكن يمكننا على الأقل استنتاج أنها خاطئة عندما تكون نتائجنا ذات دلالة، أليس كذلك؟ كلا. تعتمد إحصائية الاختبار ذات الدلالة على التعليل الإحصائي، الذي يحد بشكل صارم ما يمكننا استنتاجه. مرة أخرى، يوضح Cohen (1994) أن التعليل الرسمي يعتمد على عبارة أولى من الحقيقة تليها عبارة عن الوضع الحالي للمسألة ثم خلاصة استنتاجية. ويوضح القياس المنطقي Syllogism ما نعنيه بذلك:

- إذا لم يكن للرجل أذرع فلا يمكنه العزف على الغيتار.
  - هذا الرجل يعزف على الغيتار.
  - إذاً لهذا الرجل أذرع.

يبدأ القياس المنطقي مع عبارة الحقيقة التي تسمح بالوصول للاستنتاج النهائي الذي يجب الوصول إليه، لأنك تستطيع أن ترفض أنه ليس للرجل أذرع (المقدمة antecedent) بنفي عدم مقدرته العزف على الغيتار (النتيجة consequent). وإليك الآن نسخة مقارنة من فرضية العدم:

- إذا كانت فرضية العدم صحيحة، عندئذٍ لا يمكن لإحصائية الاختبار أن تحدث.
  - لقد حدثت إحصائية الاختبار.
  - إذاً فرضية العدم خاطئة.

كل ذلك رائع باستثناء أنه لا يتم تقديم فرضية العدم بهذه الطريقة وذلك لأنها تعتمد على الاحتمالات. لذلك يجب عرضها بالشكل التالي:

- إذا كانت فرضية العدم صحيحة، عندئذٍ فإن احتمال عدم حدوث إحصائية الاختبار كبير جداً.
  * لقد حدثت إحصائية الاختبار.
  * إذاً فرضية العدم غير محتملة بشكل كبير.

إذا عدنا لمثال الغيتار، فيمكننا الحصول على عبارات مشابهة:

- إذا كان رجل ما يعزف على الغيتار، فمن المحتمل أنه لا يعزف ضمن فرقة Fugazi (وهذا صحيح لأن هناك آلاف الأشخاص الذين يعزفون على الغيتار، ولكن هناك شخصان فقط يعزفان على الغيتار في فرقة Fugazi).
  * Guy Picciotto يعزف في فرقة Fugazi.
  * إذاً من المحتمل أن لا يكون Guy Picciotto عازفاً على الغيتار.

إن النتيجة خاطئة لأن Guy Picciotto لا يعزف على الغيتار. إن ما سبق يوضح المغالطة الشائعة في اختبار الفرضيات. في الحقيقة لا يسمح اختبار الدلالة سوى بقول شيء بسيط جداً عن فرضية العدم.

2.8.1 الاختبار وحيد الطرف والاختبار ثنائي الطرف

عند استخدام الاختبارات الإحصائية، إما أن يكون لدينا توقّع معين عما سيحدث، مثل "مع ازدياد قراءة شخص ما لكتاب معين، ازدادت كراهيته لمؤلفه!"، أو أننا لا نعلم ما الذي سيحدث، مثل "إن قراءة المزيد من ذلك الكتاب قد يزيد أو ينقص كراهية القارئ لمؤلفه". إن المثال الأول موجَّه، فنحن نقول بشكل صريح أن الناس سيكرهون المؤلف كلما قرؤوا المزيد من الكتاب. إذا اختبرنا هذه الفرضية إحصائياً، فإن الاختبار يُدعى اختباراً وحيد الطرَف (one-tailed test). أما الفرضية الثانية فهي غير موجَّهة، فنحن نُعلن أن كراهية الناس للمؤلف ستتغير بسبب قراءة الكتاب، ولكننا لم نقل فيما إذا كانت الكراهية ستزداد أم ستنخفض. إذا اختبرنا هذه الفرضية إحصائياً، فإن الاختبار سيكون ثنائي الطرَف (tow-tailed test).

تخيل أننا نريد اكتشاف ما إذا كانت قراءة الكتاب تزيد أو تنقص كراهية مؤلفه. يمكننا إنجاز ذلك إما تجريبياً بأخذ مجموعتين إحداهما قرأت الكتاب والأخرى لم تقرأه، أو تلازمياً (بالارتباط) وذلك بقياس الكمية التي تمت قراءتها من الكتاب وكراهية المؤلف المقابلة لها. إذا لم تتوفر لدينا فرضية موَجَّهة فهناك ثلاث إمكانيات:

1. الأشخاص الذين قرؤوا الكتاب يكرهون المؤلف أكثر من أولئك الذين لم يقرؤوه، فالفرق (المتوسط للذين قرؤوا الكتاب مطروحاً من المتوسط لمن لم يقرؤوه) هو موجب. وتلازمياً نجد أنه كلما قرأت المزيد من الكتاب زاد كرهك للمؤلف، أي أن العلاقة طردية.
2. الأشخاص الذين قرؤوا الكتاب يكرهون المؤلف أقل من أولئك الذين لم يقرؤوه، فالفرق (المتوسط للذين قرؤوا الكتاب مطروحاً من المتوسط لمن لم يقرؤوه) هو سالب. وتلازمياً نجد أنه كلما قرأت المزيد من الكتاب قلّ كرهك للمؤلف، أي أن العلاقة عكسية.

3. ليس هناك فرق بين الأشخاص الذين قرؤوا الكتاب والذين لم يقرؤوه من ناحية كرههم للمؤلف، فالفرق (المتوسط للذين قرؤوا الكتاب مطروحاً من المتوسط لمن لم يقرؤوه) يساوي 0 تماماً. وتلازمياً لا توجد علاقة بين قراءة الكتاب و كُره مؤلفه. وهذه هي فرضية العدم.

إن توجيه إحصائية الاختبار (طردياً أو عكسياً) يعتمد على كون الفرق موجباً أو سالباً. بفرض أن هناك فرق إيجابي أو علاقة طردية (قراءة الكتاب تجعلك تكره مؤلفه)، لاكتشاف هذا الفرق علينا أن نأخذ في الاعتبار حقيقة أن متوسط القراء أكبر من متوسط غير القراء (وهكذا نشتق إحصائية اختبار موجبة). إذا كان توقعنا غير صحيح، وكانت قراءة الكتاب تخفف كراهية مؤلفه فإن إحصائية الاختبار ستكون عكسية عملياً.

ما تبعات ذلك؟ عند مستوى 0.05، إذا احتجنا لإحصائية اختبار أكبر من 10 مثلاً، وما حصلنا عليه كان 12- فإن علينا رفض الفرضية حتى إذا كان الفرق موجوداً. لكي نتجنب ذلك يمكننا النظر إلى نهايتي (أو ذيلي) التوزيع لإحصائيات الاختبار الممكنة. وهذا يعني أن نمسك كلاً من إحصائية الاختبار الموجبة وإحصائية الاختبار السالبة. على كل حال، لكل شيء ثمنه. فمن أجل المحافظة على معيار الاحتمالية عند 0.05 علينا تقسيم ذلك الاحتمال على طرفي التوزيع، بحيث يصبح لدينا 0.025 على الطرف الموجب للتوزيع، و 0.025 على الطرف السالب. يوضح (الشكل 13.1) هذه الحالة، حيث المناطق الملونة هي المناطق فوق إحصائية الاختبار المطلوبة عند مستوى 0.025 من الدلالة أو الأهمية. بتركيب الاحتمالات الموجودة على الطرفين نحصل على 0.05 وهي قيمة المعيار. إذا توقعنا شيئاً، ونظرنا إلى إحدى نهايتي التوزيع فقط (إما النهاية الموجبة أو النهاية السالبة وذلك تبعاً لاتجاه التوقع الذي وضعناه)، فإننا سننظر في هذه الحالة إلى قيمة إحصائية الاختبار التي تحدث بالصدفة وباحتمال 0.05 فقط. تمثل المنطقة المهشرة في (الشكل 13.1) المنطقة فوق إحصائية الاختبار الموجبة المطلوبة عند مستوى 0.05 من الدلالة. إن النقطة الهامة هي أنه إذا وضعنا توقعاً معيناً فإننا بحاجة لإحصائية اختبار أصغر من أجل العثور على قيمة ذات دلالة (لأننا ننظر عند نهاية واحدة فقط). ولكن إذا حدث التوقع الذي وضعناه في الاتجاه الخاطئ فلن نكون قادرين على اكتشاف الأثر الموجود فعلياً. في هذه الحالة، عليك أن تتذكر ما قلناه في (المربع 1.1) لا يمكنك المراهنة أو تغيير الرهان بعد انتهاء البطولة، ولذلك إذا لم تتوقع الاتجاه قبل جمع البيانات فأنت متأخر جداً ولا يمكنك أن تتوقع الاتجاه ثم الإدعاء بمزايا الاختبار وحيد الطرف.

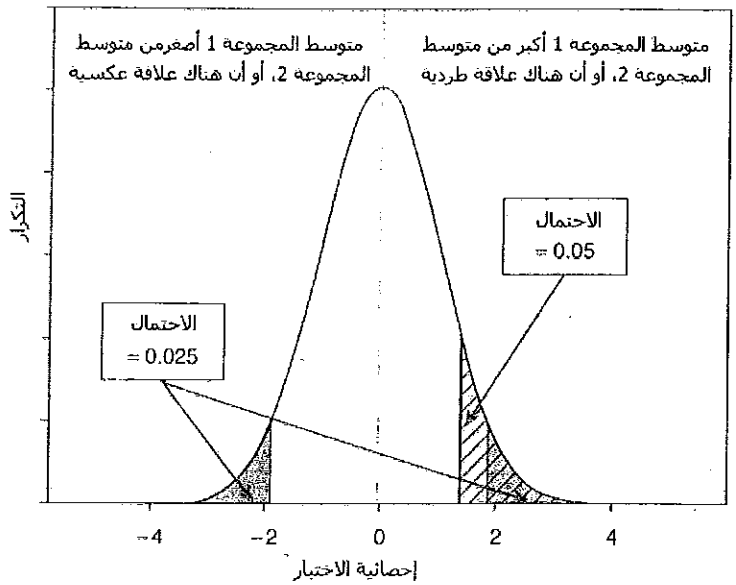

الشكل 13.1 الفرق بين الاختبار وحيد الطرف والاختبار ثنائي الطرف

3.8.1 الأخطاء من النوع الأول ومن النوع الثاني

رأينا أننا نستخدم إحصائية الاختبار لمعرفة الحالة الحقيقية للعالم (بنسبة معينة من الثقة). ونحاول بشكل خاص معرفة فيما إذا كان هناك أثر في المجتمع. وهناك إمكانيتان في العالم الحقيقي، فإما أن يكون هناك – في الحقيقة – أثر في المجتمع، أو أن لا يكون هناك – في الحقيقة – أثر في المجتمع. ولا تتوفر طريقة لمعرفة أي من هاتين الإمكانيتين هي الصحيحة، ولكن يمكننا أن ننظر إلى إحصائيات الاختبار والاحتمالات المرتبطة بها لمعرفة أي منهما أكثر احتمالاً. ومن البديهي أن تكون الدقة قدر الإمكان أمراً هاماً جداً، ولهذا السبب قال Fisher أنه علينا أن نكون متحفظين وأن نعتقد بأن النتيجة حقيقية عندما نكون على ثقة بنسبة 95%، وهذا يعني وجود احتمال قيمته 5% فقط بأن تحدث النتائج عن طريق الصدفة. ولكن حتى لو كنا واثقين بنسبة 95% فما زال هناك احتمال صغير لأن تكون النتيجة خاطئة. هناك نوعان من الأخطاء التي يمكن أن نرتكبها: الخطأ من النوع الأول (Type I error)، والخطأ من النوع الثاني (Type II error). يحدث الخطأ من النوع الأول عندما نعتقد بوجود أثر حقيقي في المجتمع، بينما لا يكون هناك أثر في الحقيقة. إذا استخدمنا معيار Fisher فإن احتمال هذا الخطأ هو 5% عندما لا يكون هناك أثر في المجتمع، وتُعرف هذه القيمة بالمستوى α (α-level). بافتراض عدم وجود أثر في المجتمع، إذا كررنا جمع البيانات 100 مرة فإننا نتوقع أنه في 5 مرات فقط قد نحصل على إحصائية اختبار كبيرة لحد معقول يسمح لنا باعتقاد أن هناك أثراً حقيقياً في المجتمع حتى لو لم يكن هناك أثر فعلياً. الخطأ المعاكس هو الخطأ من النوع الثاني الذي يحدث عندما نعتقد بعدم وجود أثر في المجتمع، بينما في الحقيقة هناك أثر. ويحدث ذلك عندما نحصل على إحصائية اختبار صغيرة (ربما لأن هناك تغايراً طبيعياً كبيراً بين العينات). في عالم

مثالي، نريد أن يكون احتمال هذا الخطأ صغيراً جداً (إذا كان هناك أثر في المجتمع، فمن المهم أن نكون قادرين على اكتشافه). يقترح Cohen (1992) أن يكون الاحتمال الأعظمي المقبول للخطأ من النوع الثاني هو 20%، وتدعى هذه القيمة بالمستوى β (β-level). وهذا يعني أنه إذا أخذنا 100 عينة من البيانات من مجتمع ما حيث هناك أثر ما، فإننا سنفشل في اكتشاف ذلك الأثر في 20 عينة (أي أننا نفقد أثراً حقيقياً واحداً من بين كل 5).

من البديهي وجود تبادل بين هذين الخطأين، فإذا خفضنا احتمال قبول الأثر كحقيقي (أي تصغير α) فإننا نزيد احتمال أن نرفض وجود الأثر الحقيقي (لأننا حازمون جداً بخصوص المستوى الذي نقبل عنده بكون الأثر حقيقي). إن العلاقة الدقيقة بين الأخطاء من النوع الأول و من النوع الثاني ليست مباشرة وذلك لأنها تعتمد على فرضيات مختلفة: لارتكاب الخطأ من النوع الأول يجب أن لا يكون هناك أثر في المجتمع، بينما ارتكاب الخطأ من النوع الثاني يتطلب أن يكون العكس صحيحاً (أي أن هناك أثراً لم نكتشفه). لذلك، ومع علمنا أنه مع انخفاض احتمال حصول الخطأ من النوع الأول يزداد احتمال حصول الخطأ من النوع الثاني، فإن الطبيعة الفعلية للعلاقة متروكة عادة للباحثين ليقوموا بتخمين مدرَّب (يعطي Howell، 2002 شرحاً تفصيلياً للعلاقة بين الأخطاء في الصفحات 107-104).

4.8.1 حجم الأثر

يشمل الإطار الذي يتم فيه اختبار فيما إذا كانت الآثار حقيقية بعض المشاكل، وقد تم شرح معظمها بشكل مختصر في المربع 2.1. المشكلة الأولى التي واجهناها هي معرفة مدى أهمية الأثر، وذلك لأنه إذا كانت إحصائية الاختبار ذات دلالة فهذا لا يعني أن الأثر الذي تقيسه ذو معنى أو هام. ولمعالجة هذا الانتقاد نقوم بقياس حجم الأثر الذي نختبره وذلك بطريقة عيارية. عندما نقيس حجم أثر ما (سواء كان ذلك تجريبياً أو بقوة العلاقة بين المتحولات) فإن ذلك يدعى بحجم الأثر (effect size). وحجم الأثر هو قياس موضوعي وعياري لمطال الأثر المراقب. إن حقيقة أن القياس عياري (standardized) تعني أنه يمكننا مقارنة حجم الآثار عبر الدراسات المختلفة التي قامت بقياس المتحولات المختلفة، أو التي استخدمت سلالم مختلفة للقياس (بحيث يمكن مقارنة حجم الأثر المعتمد على السرعة مقدرة بالميلي ثانية مع حجم الأثر المعتمد على معدل ضربات القلب). وقد تم اقتراح العديد من المقاييس لحجم الأثر، نذكر منها مقياس d الذي قدمه Cohen، ومعامل الارتباط r الذي قدمه Pearson. ويتعامل معظمكم مع معامل الارتباط كمقياس لقوة العلاقة بين متحولين (انظر الفصل الرابع)، ولكنه مقياس متعدد الاستعمال لقياس قوة أثر تجريبي ما. من الصعب التصديق بأن معامل الارتباط المتواضع يمكن استخدامه بهذه الطريقة، وذلك لأن الطلاب يتلقون معلوماتهم عن معامل الارتباط ضمن إطار البحث غير التجريبي. لن ندخل في تفاصيل ذلك الآن، ولكن عند قراءة الفصول 4 و 7 و 8 سيتضح ما نعنيه (آمل ذلك!). وشخصياً، أفضِّل معامل

الارتباط r الذي قدمه Pearson كمقياس لحجم الأثر لأنه محصور بين القيمة 0 (عدم وجود أثر) والقيمة 1 (أثر كامل أو مثالي)[3].

إن حجم الأثر مفيد لأنه يوفر مقياساً موضوعياً لأهمية الأثر. لذلك لا أهمية لنوع الأثر الذي نبحث عنه، أو المتحولات التي يتم قياسها، أو كيفية قياس هذه المتحولات. نحن نعلم أن القيمة 0 لمعامل الارتباط تعني عدم وجود أثر، وأن القيمة 1 تعني أثراً كاملاً. وقد قدم Cohen (1988، 1992) بعض الاقتراحات المقبولة على نطاق واسع حول ما يمكن أن يشكل أثراً كبيراً أو صغيراً:

- أثر صغير r=0.10: في هذه الحالة يبرر الأثر 1% من التباين الكلي.
- أثر متوسط r=0.30: في هذه الحالة يبرر الأثر 9% من التباين الكلي.
- أثر كبير r=0.50: في هذه الحالة يبرر الأثر 25% من التباين الكلي.

يمكننا استخدام هذه الخطوط العامة لتقييم أهمية الآثار (بغض النظر عن أهمية أو دلالة إحصائية الاختبار). على كل حال، لا يقاس معامل الارتباط r على سلم خطي، أي أن أثراً بمعامل ارتباط r=0.6 ليس مساوياً لمثلَي أثر بمعامل ارتباط r=0.3.

نقطة أخيرة تنبغي الإشارة إليها وهي أنه يتم حساب حجم الأثر من أجل عينة محددة. عندما ننظر إلى قيم المتوسط في عينة ما، نعلم أننا نستخدمها لاستنتاج خلاصة عن المتوسط في المجتمع بأكمله (وهي القيمة التي تهمنا فعلياً). ونفس الشيء صحيح من أجل حجم الأثر، إذ أن حجم الأثر في المجتمع هو القيمة التي تهمنا، ولكن لأنه لا يمكننا الوصول إلى هذه القيمة فإننا نستخدم حجم الأثر في العينة لتقدير الحجم المحتمل للأثر في المجتمع.

5.8.1 القدرة الإحصائية

رأينا أن حجم الأثر هو طريقة ثمينة للتعبير عن أهمية ما يجده الباحث. ويرتبط حجم الأثر في المجتمع بشكل وثيق مع ثلاث خصائص إحصائية أخرى:

1. حجم العينة التي يستند إليها حجم الأثر للعينة.
2. مستوى الاحتمال الذي سنقبل عنده الأثر بأنه ذو دلالة أو مهم إحصائياً (مستوى α).
3. قابليةُ اكتشاف أثر بذلك الحجم باختبار ما (وتُعرف بالقدرة الإحصائية statistical power).

وهكذا، إذا عرفنا ثلاثة من هذه الخصائص فإن بإمكاننا حساب الخاصية المتبقية. وهذا يعتمد طبعاً على كون الاختبار أحادي الطرف أو ثنائي الطرف (انظر الفقرة 2.8.1). ونستخدم في علم النفس

3 يمكن لعامل الارتباط أن يأخذ قيماً سالبة (ولكن ليس أقل من 1-) ويفيد ذلك عندما نقيس العلاقة بين متحولين لأن إشارة r تدل اتجاه العلاقة، ولكن في الأبحاث التجريبية فإن إشارة r تعكس فقط الطريقة التي يقوم منفذو الاختبار بترميز مجموعاتهم (انظر الفصل الرابع).

عادة القيمة 0.05 للمستوى α لذلك فنحن نعرف هذه القيمة مسبقاً. إن قدرة الاختبار هي احتمال أن يعثر اختبار معين على أثر نفترض وجوده في المجتمع. إذا أعدت التفكير بهذه النقطة فقد تتذكر أننا مررنا باحتمال أن نفشل باكتشاف أثر ما عندما يكون موجوداً فعلياً (β احتمال الخطأ من النوع الثاني). ينتج عن ذلك أن احتمال اكتشاف أثر (إذا كان موجوداً) يجب أن يكون معاكساً لاحتمال عدم اكتشاف الأثر (أي 1-β). لقد أشرنا أيضاً إلى أن Cohen (1988، 1992) يقترح أن نأمل بالحصول على احتمال 0.2 في الفشل باكتشاف أثر حقيقي، ولذلك فإن مستوى القدرة الموافق الذي ينصحنا به سيكون 0.8= 0.2- 1. يجب أن يكون هدفنا الوصول إلى القدرة 0.8 أي احتمال 80% لاكتشاف أثر ما إذا كان موجوداً فعلياً. يمكن تقدير حجم الأثر في المجتمع من خلال حجم الأثر في العينة، ويقوم منفذ الاختبار بتحديد حجم العينة لذلك فمن السهل حساب تلك القيمة. هناك أمران مفيدان يمكن إنجازهما بمعرفة أن هذه المتحولات الأربعة مرتبطة:

1. **حساب قدرة الاختبار:** بفرض أننا أنجزنا تجربتنا، واخترنا قيمة α، يمكننا إذاً تقدير حجم الأثر اعتماداً على العينة، ومعرفة عدد المشتركين الذين استخدمناهم. ولذلك يمكننا استخدام هذه القيم لحساب β قدرة الاختبار. إذا كانت هذه القيمة مساوية 0.8 أو أكثر فيمكن أن نكون واثقين بوصولنا إلى قيمة قدرة كافية لاكتشاف أية آثار قد تكون موجودة، ولكن إذا كانت القيمة الناتجة أقل، فإن علينا تكرار التجربة باستخدام عدد أكبر من المشتركين لزيادة القدرة.
2. **حساب حجم العينة الضروري للوصول إلى مستوى معين من القدرة:** بفرض أننا نعلم قيمة كل من α و β، يمكننا استخدام البحث اللاحق لتقدير حجم الأثر الذي نأمل اكتشافه في تجربة ما. وحتى لو لم يتم سابقاً بإجراء التجربة التي نريد تنفيذها فما يزال بإمكاننا تقدير حجم الأثر المحتمل اعتماداً على تجارب مشابهة. يمكننا استخدام هذا التقدير لحجم الأثر من أجل حساب عدد المشتركين المطلوب لاكتشاف ذلك الأثر (اعتماداً على قيم α و β التي اخترناها).

الاستخدام الأخير هو الأكثر شيوعاً وهو تحديد عدد المشتركين الواجب استخدامهم للوصول إلى المستوى المطلوب من القدرة. إن الحسابات الفعلية مرهقة جداً،، ولكن لحسن الحظ، تتوفر مجموعة من البرمجيات التي تقوم بهذه الحسابات (منها G*Power المجاني المتوفر في القرص المضغوط المرفق مع الكتاب، وnQuery Adviser الذي يمكن شراؤه). وقد وفّر Cohen (1988) جداول موسعة لحساب عدد المشتركين من أجل الحصول على مستوى قدرة معين (والعكس). اعتماداً على Cohen (1992) يمكننا استخدام الخطوط العامة التالية: إذا أخذنا مستوى α العياري أي 0.05 وطلبنا القدرة المفضلة 0.80 فإننا نحتاج لعدد من المشتركين يبلغ 783 لاكتشاف أثر من الحجم الصغير (r =0.1)، أو 85 مشتركاً لاكتشاف أثر متوسط الحجم (r =0.3)، أو 28 مشتركاً لاكتشاف أثر كبير الحجم (r =0.5).

9.1 بعض النصائح الختامية

لقد أردنا إنهاء هذا الفصل ببعض النصائح العامة. تتعامل الإجرائيات الإحصائية مع أرقام كثيرة، ولو وضعت أي شيء في التحليل فما يزال بإمكانك الوصول إلى نتائج ذات معنى إحصائياً، ولكن من غير المحتمل أن تكون ذات معنى تجريبياً أو عملياً. وقد دأب مدرسو الإحصاء على القول "إذا وضعت بيانات لا فائدة منها في الدخل، فإنك ستحصل على بيانات لا فائدة منها في الخرج". وبصراحة لم أفهم قصدهم بشكل حقيقي إلى أن بدأ الناس يقدمون لي مجموعات من البيانات التي تحوي ملايين المتحولات المرتبطة عشوائياً ويطلبون مني مساعدتهم في تفسيرها. في التحليل الإحصائي، ليس هناك بديل عن التفكير العملي التجريبي! ولا تنس ذلك خلال قراءتك هذا الكتاب.هناك نصيحة أخيرة، لا تصدق أي شيء يقوله عالم نفس عن الإحصاء.

10.1 ما الذي اكتشفناه عن الإحصاء؟

لقد كان ذلك درساً سريعاً ومكثفاً في نظرية الإحصاء، والنقطة الأساسية التي أريدك أن تفهمها أنه عندما تقوم ببحثك فإنك تحاول معرفة فيما إذا كانت بعض الآثار موجودة فعلياً في المجتمع (سيعتمد الأثر الذي يهمّك على نقاط الاهتمام في بحثك وعلى توقعاتك الخاصة). لن تكون قادراً على جمع البيانات من المجتمع بكامله (ما لم ترغب بقضاء حياتك كلها في جمع البيانات)، لذلك فأنت تستخدم العينة بدلاً من المجتمع. باستخدام البيانات من العينة، تقوم بملاءمة نموذج إحصائي لاختبار توقعاتك، أو بطريقة أخرى، تكتشف الأثر الذي تبحث عنه. ويتلخص علم الإحصاء بفكرة بسيطة واحدة: يمكن التنبؤ بالقيم المشاهدة عن طريق نموذج ما و خطأ مرتبط بذلك النموذج. تستخدم ذلك النموذج (وعادة الخطأ المرتبط به) لحساب إحصائية الاختبار. إذا كان النموذج قادراً على تبرير الكثير من التغاير في البيانات المجمّعة (احتمال الحصول على إحصائية الاختبار تلك هو أقل من 0.05) فيمكنك استنتاج أن الأثر الذي تبحث عنه موجود فعلاً في المجتمع. إذا كان احتمال الحصول على إحصائية الاختبار أكبر من 0.05 فإنك تستنتج أن الأثر كان صغيراً جداً بحيث لم تتمكن من اكتشافه. وبدلاً من الاعتماد على الدلالة أو الأهمية، يمكنك تقييم الأثر في العينة كمّياً بطريقة عيارية واعتباره حجم الأثر، مما يساعد في الحكم على أهمية ذلك الأثر. والآن إلى برنامج SPSS.

11.1 المصطلحات الأساسية التي اكتشفناها

المستوى α	(α - level)
المستوى β	(β - level)
مجال الثقة	(Confidence interval)

الحيدان	(Deviance)
حجم الأثر	(Effect size)
الفرضية التجريبية	(Experimental hypothesis)
التوزيع التكراري	(Frequency distribution)
المخطط التكراري	(Histogram)
درجة التحدب	(Kurtosis)
مدبب	(Leptokurtic)
نموذج خطي	(Linear model)
المتوسط	(Mean)
المنوال	(Mode)
التوزيع الطبيعي	(Normal Distribution)
فرضية العدم	(Null hypothesis)
اختبار أحادي الطرف	(One-tailed test)
مسطّح	(Platykurtic)
المجتمع	(Population)
التوزيع الاحتمالي	(Probability distribution)
العينة	(Sample)
توزيع أخذ العينات	(Sampling distribution)
الميلان	(Skewness)
الانحراف المعياري	(Standard deviation)
الخطأ المعياري	(Standard error)
القدرة الإحصائية	(Statistical power)
مجموع مربعات الأخطاء	(Sum of squared errors 'SS')
التغاير المنهجي	(Systematic variation)
إحصائية الاختبار	(Test statistic)
اختبار ثنائي الطرف	(Two-tailed test)

الخطأ من النوع الأول	(Type I error)
الخطأ من النوع الثاني	(Type II error)
التغاير اللامنهجي	(Unsystematic variation)
التباين	(Variance)
العلامة المعيارية z	(z-score)

12.1 امتحان مختصر في الإحصاء

1. لماذا نستخدم العينات؟
2. ماهو المتوسط، وكيف نعلم أنه ممثل للبيانات؟
3. ما الفرق بين الانحراف المعياري والخطأ المعياري؟
4. ماهي إحصائية الاختبار وبماذا تخبرنا؟
5. ما هي الأخطاء من النوع الأول و من النوع الثاني؟
6. ماهو حجم الأثر وكيف نقيسه؟
7. ماهي القدرة الإحصائية؟

هناك بعض الأجوبة المختصرة في الملف Answers(Chapter1).pdf على القرص المضغوط المرفق.

بيئة البرنامج SPSS

1.2 بماذا يخبرنا هذا الفصل

قدم الفصل الأول بعض المعلومات الأساسية النظرية التي ينبغي عليك معرفتها، ويقدم هذا الفصل النوع الآخر من المعلومات الأساسية التي عليك معرفتها، وتتعلق ببيئة البرنامج SPSS. وتوفر كتب عديدة مدخلاً للبيئة العامة التي يعمل ضمنها برنامج SPSS، وهي تستحق القراءة خاصة من قبل الأشخاص غير الملمّين بالحواسب والبرنامج. وقد حاولت في هذا الفصل تقديم دليل لبيئة البرنامج SPSS يمكن أن يستفيد منه الأشخاص الذين لم يسبق لهم التعامل مع هذا البرنامج، أما إذا أردت التعمق أكثر فيمكنك العودة إلى دليل التشغيل لبرنامج SPSS، كما يمكنك الاستفادة من ملفات المساعدة المتوفرة مع البرنامج. ويقدم هذا الفصل نظرة على النافذتين الأساسيتين لبرنامج SPSS (محرر البيانات (data editor) والعارض (viewer))، كما يشرح كيفية إنشاء المتحولات وإدخال البيانات وضبط خصائص المتحولات. وفي الختام، يوضح كيفية تحميل الملفات وحفظها.

2.2 رقم نسخة البرنامج SPSS

يعتمد هذا البرنامج بشكل أساسي على الإصدار 14 من برنامج SPSS (على الأقل من ناحية الأشكال)، ولكن لا تخدعك أرقام النسخ لأن الشركة معتادة على إصدار نسخ جديدة بشكل دوري. وهناك في الواقع بعض الفروق بين هذه الإصدارات، حيث يمكن لمعظمنا ملاحظتها عملياً. وأحياناً يتم إجراء تحديد شامل، فالنسخة 7.0 تختلف بشكل جذري عن النسخة 6.0، أما في النسخة 10 فقد تم تعديل طريقة إدخال المتحولات.

3.2 البداية

يستخدم البرنامج SPSS بشكل أساسي النافذتين التاليتين: نافذة محرر البيانات (data editor) (حيث تقوم بإدخال البيانات وتنفيذ الوظائف الإحصائية)، ونافذة العارض (viewer) (حيث يتم عرض النتائج لأي تحليل تقوم به). وهناك المزيد من النوافذ التي يمكن تفعيلها مثل نافذة محرر

القواعد (SPSS syntax editor) (انظر الفقرة 6.2.2) التي تسمح بإدخال أوامر SPSS يدوياً (بدلاً من استخدام القوائم الجاهزة). وتعتبر هذه النافذة فائضة مهما كان مستوى الخبرة للمستخدم، لأنك تستطيع تنفيذ معظم عمليات التحليل عن طريق النقر السريع بزر الفأرة. ومع ذلك فإنه يمكنك الوصول إلى مختلفة الوظائف الإضافية باستخدام النافذة syntax editor، وستضطر إلى التعامل معها بشكل قسري في فقرات مختلفة من هذا الكتاب.

بعد تشغيل برنامج SPSS، تظهر نافذة الإقلاع المبينة في (الشكل 1.2)، التي تسمح لك بتحديد واحد من الخيارات المختلفة التي توفرها. إذا كان لديك ملف بيانات على قرص معين وتريد فتحه، فإن عليك نقر الخيار Open an existing data source. توفر المنطقة الموجودة تحت هذا الخيار لائحة بملفات البيانات المستخدمة حديثاً، يمكنك اختيار الملف المطلوب بنقره بزر الفأرة. لفتح الملف المحدد انقر الزر OK. إذا أردت فتح ملف بيانات غير موجود في اللائحة فانقر الخيار More Files... ثم انقر الزر OK. يقوم البرنامج عندئذ بفتح نافذة استعراض قياسية ويسمح لك باستعراض الحاسب لإيجاد الملف المطلوب (انظر الفقرة 8.2.2). أما إذا أردت فتح ملف من نوع مختلف عن ملفات البيانات، كوثيقة تحوي نتائج عملية التحليل الأخيرة مثلاً، فإن عليك نقر الخيار Open another type of file ثم اختيار ملف من لائحة الملفات المستخدمة حديثاً الموجودة تحت هذا الخيار، أو تحديد الخيار More Files... واستعراض الحاسب لإيجاد الملف المطلوب. إذا أردت البدء بعملية تحليل جديدة فإنك ستقوم بإدخال البيانات في نافذة جديدة من محرر البيانات، لذلك عليك نقر الخيار Type in data ثم نقر الزر OK. يقوم برنامج SPSS بتحميل نافذة data editor جديدة خالية من البيانات.

4.2 محرر البيانات

تتضمن نافذة SPSS الرئيسية محرر بيانات بهدف إدخال البيانات. وفي هذه النافذة تحدث معظم العمليات. يحوي القسم العلوي من الشاشة شريط قوائم شبيهاً بما تجده في معظم التطبيقات الأخرى (مثل Microsoft Word). يعرض الشكل 2.2 نافذة محرر البيانات مع شريط القوائم الخاص بها. يتضمن الشريط عدة قوائم (مثل File، Edit، View وغيرها) يمكن تفعيلها بوضع مؤشر الفأرة على القائمة المطلوبة ونقرها بالزر الأيسر للفأرة نقرة واحدة. بعد النقر، تظهر قائمة من الخيارات التي يمكن تفعيلها بوضع مؤشر الفأرة على الخيار المطلوب ثم نقره بالزر الأيسر للفأرة. عند نقر خيار معين من إحدى القوائم غالباً ما تظهر نافذة جديدة، تدعى هذه النوافذ بمربعات الحوار (dialog boxes). عند الإشارة لتحديد خيار من قائمة ما، فإننا سنكتب الإجراء مع أسهم تشير إلى مسار الفأرة (بحيث يمثل كل سهم وضع المؤشر على الكلمة ونقرها بالزر الأيسر للفأرة). فإذا أردنا على سبيل المثال اختيار الأمر Save As... من القائمة File، فإننا نكتب ذلك بالشكل File ⇒ Save As...

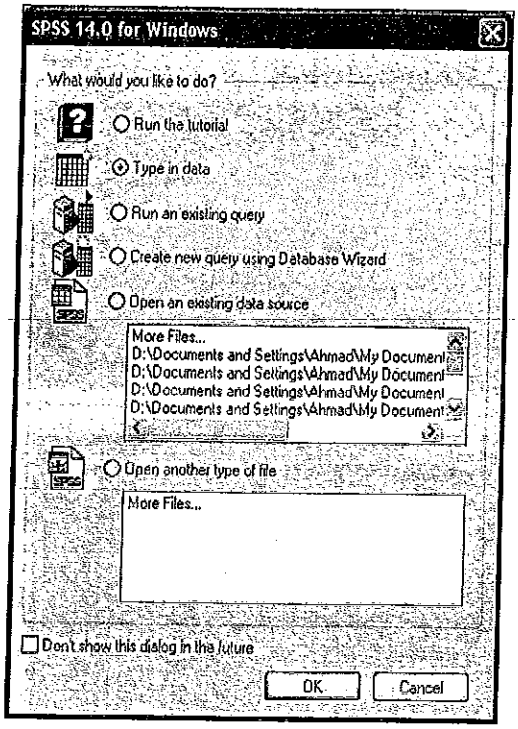

الشكل 1.2 نافذة الإقلاع في برنامج SPSS

ولنافذة محرر البيانات صفحتي عرض هما: صفحة عرض البيانات (Data View) وصفحة عرض المتحولات (Variable View). يتم إدخال البيانات إلى محرر البيانات عن طريق صفحة عرض البيانات، أما تعريف المميزات المختلفة للمتحولات في محرر البيانات فيتم في صفحة عرض المتحولات. نلاحظ في القسم السفلي من محرر البيانات صفحتي التبويب (Data View) و(Variable View)، وللتبديل بين صفحتي العرض السابقتين يكفي النقر على الصفحة المطلوبة. فإذا كنت في صفحة عرض البيانات فإن لون الخلفية لهذه الصفحة يكون أبيضاً، ويكون لون الخلفية لصفحة عرض المتحولات رمادياً. وإذا كنت في صفحة عرض المتحولات فإن لون الخلفية لهذه الصفحة يكون أبيضاً، ويكون لون الخلفية لصفحة عرض البيانات رمادياً. لننظر أولاً على بعض المزايا العامة لمحرر البيانات، والتي لا تتغير عند التبديل بين صفحتي العرض (Data View) و(Variable View). ولنبدأ مع القوائم.

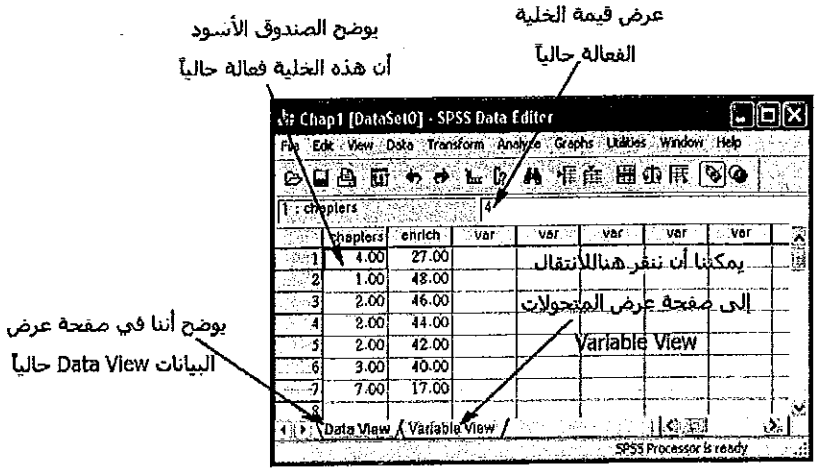

الشكل 2.2 نافذة محرر البيانات SPSS Data Editor

في العديد من التطبيقات، يكون أحد الأحرف في اسم القائمة مسطّراً، وهو يمثل اختصاراً للوصول إلى تلك القائمة، حيث يمكن اختيار الوظيفة المطلوبة دون استخدام الفأرة. ويفضّل مستخدم لوحة المفاتيح المتمرس استخدام هذه الاختصارات بدلاً من المناورات بمؤشر الفأرة. تشير الأحرف المسطّرة في القوائم إلى أنه يمكن الوصول إلى القائمة بالضغط المتزامن على المفتاح Alt ومفتاح الحرف المسطّر. فمن أجل الوصول للخيار ...Save As الموجود في القائمة File باستخدام لوحة المفاتيح، ينبغي عليك ضغط المفتاح Alt والمفتاح F بنفس الوقت (مما يؤدي لتفعيل القائمة File)، بعد ذلك تحافظ على المفتاح Alt مضغوطاً ثم تضغط المفتاح A. في الإصدار 14 من البرنامج SPSS (على الأقل حين يتم تشغيله في Windows XP) فإن الأحرف المسطّرة غير مرئية، ومع ذلك يمكن استخدام اختصارات لوحة المفاتيح. إذا ضغطت المفتاح Alt تصبح الأحرف المسطّرة مرئية. عند ضغط الفتاح Alt لمرة واحدة فقط يصبح بإمكانك اختيار أحد الأحرف المسطّرة للتجول بين القوائم المختلفة.

فيما يلي دليل مرجعي مختصر لجميع القوائم وبعض الخيارات التي تحويها. إنه ملخص فقط وسنكتشف روعة كل من هذه القوائم خلال تقدمنا عبر الكتاب.

- **القائمة File:** تسمح هذه القائمة بإنجاز مهمات عامة مثل حفظ البيانات والمخططات والخرج، وبشكل مشابه يمكنك فتح الملفات المحفوظة سابقاً وطباعة المخططات والبيانات والخرج. وتحوي بشكل أساسي جميع الخيارات التي نجدها عادة في القائمة File في التطبيقات المختلفة.
- **القائمة Edit:** تحوي هذه القائمة وظائف التحرير والتعديل في محرر البيانات. من الممكن أن نقوم في برنامج SPSS بقص مجموعات من الأرقام من أحد أقسام محرر البيانات ولصقها في قسم آخر (وهي عملية ملائمة للاستخدام عندما تدرك أنك قمت بإدخال مجموعة من البيانات في مكان خاطئ). يمكنك استخدام الخيار Options لتحديد التفضيلات المختلفة

كنوع الخط المستخدم في نافذة الخرج. إن التفضيلات الافتراضية مناسبة لمعظم الأغراض، والشيء الوحيد الذي قد ترغب بتغييره هو إعداد طول صفحة الخرج النصية في العارض ليكون لانهائياً (مما يوفر مئات الأشجار عندما تنتقل لمرحلة الطباعة). ولإنجاز ذلك عليك اختيار صفحة التبويب Viewer.

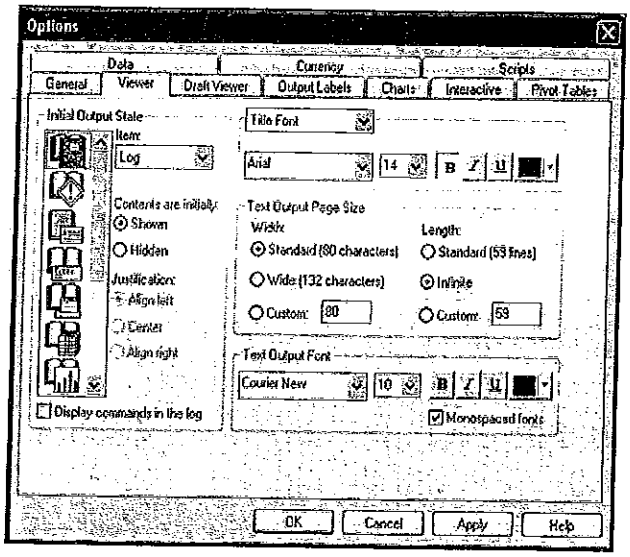

- **القائمة View:** تتعامل هذه القائمة مع مواصفات النظام كإظهار خطوط الشبكة في محرر البيانات أو إظهار تسميات القيم (ما هي تسميات القيم؟ سيغدو ذلك واضحاً فيما بعد).
- **القائمة Data:** تسمح هذه القائمة بإجراء التعديلات في محرر البيانات. من المزايا الهامة إدراج متحول insert variable المستخدمة لإدراج متحول جديد في محرر البيانات (إضافة عمود)، إدراج حالة insert case المستخدمة لإضافة صف جديد من البيانات بين صفين موجودين من البيانات، تقسيم ملف split file المستخدمة لتقسيم الملف بمتحول تجميع (انظر الفقرة 4.3)، واختيار الحالات select cases المستخدمة لتنفيذ التحليل على عينة محددة من الحالات.
- **القائمة Transform:** عليك استخدام هذه القائمة إذا كنت تريد التعامل مع أحد المتحولات بطريقة معينة. فعلى سبيل المثال، يمكنك أن تستخدم الأمر recode لتغيير القيم لمتحولات معينة (إذا أردت لسبب ما اعتماد نظام ترميز مختلف قليلاً)، انظر المربع 1.2. وتفيد الوظيفة compute في تحويل البيانات (حيث يمكنك إنشاء متحول جديد يمثل المعدل لمتحولين موجودين سابقاً). وتسمح هذه الوظيفة بتنفيذ أي عدد من الحسابات على المتحولات (انظر الفقرة 4.3.3).
- **القائمة Analyze:** وهنا تبدأ المتعة، لأن الإجرائيات الإحصائية تختبئ في هذه القائمة. وفيما يلي دليل مختصر للخيارات في قائمة الإحصاء التي ستستخدمها خلال هذا الكتاب (وهذا جزء صغير فقط مما هو متوفر):

- **القائمة الفرعية Descriptive Statistics:** تُستخدم هذه القائمة لتنفيذ الإحصاء الوصفي (المتوسط mean، المنوال mode، الوسط median وغيرها) والتكرارات والاستكشاف العام للبيانات. هناك أيضاً تعليمة تدعى crosstabs وهي مفيدة في استكشاف بيانات التكرار وتنفيذ الاختبارات مثل اختبار كاي مربع χ^2، واختبار Fischer الدقيق واختبار كابّا لـــ Cohen.
- **القائمة الفرعية Compare Means:** يمكنك أن تجد هنا اختبارات t (المرتبطة وغير المرتبطة، انظر الفصل 7)، وتحليل التباين وحيد الاتجاه ANOVA (الفصل 8).
- **القائمة الفرعية General Linear Model:** تختص هذه القائمة بأنواع تحليل التباين ANOVA المعقدة مثل ثنائي الاتجاه (غير المرتبط، المرتبط، المختلط)، وحيد الاتجاه للقياسات المتكررة، التحليل متعدد المتغيرات للتباين MANOVA (انظر الفصول 9 و10 و11 و12 و14).
- **القائمة الفرعية Correlate:** تحتفظ هذه القائمة بتقنيات الارتباط، حيث يمكنك تنفيذ الارتباطات ثنائية المتغيرات مثل R لـــ Pearson وρ لـــ Spearman وτ لـــ Kendal وكذلك الارتباطات الجزئية (انظر الفصل 4).
- **القائمة الفرعية Regression:** يوفر برنامج SPSS مجموعة متنوعة من تقنيات التراجع. يمكنك تنفيذ تراجع خطي بسيط أو تراجع خطي متعدد (انظر الفصل 5) و تقنيات أكثر تقدماً مثل التراجع المنطقي (logistic regression) (انظر الفصل 6).
- **القائمة الفرعية Loglinear:** يختبئ التحليل الخطي اللوغاريتمي في هذه القائمة (انظر الفصل 16).
- **القائمة الفرعية Data Reduction:** يمكنك أن تجد التحليل العاملي (factor analysis) في هذه القائمة (انظر الفصل 15).
- **القائمة الفرعية Scale:** في هذه القائمة تجد تحليل الوثوقية (انظر الفصل 15).
- **القائمة الفرعية Nonparametric Tests:** تتوفر مجموعة متنوعة من الإحصائيات اللابارامترية مثل إحصائية كاي مربع لجودة الملائمة، الاختبار ثنائي الحد، اختبار Mann-Whitney، اختبار Kruskal-Wallis، اختبار Wilcoxon وتحليل التباين لـــ Friedman.

- **القائمة Graphs:** يوفر البرنامج SPSS أدوات متعددة الاستخدامات لرسم المخططات البيانية. ومن المخططات التي يمكنك استخدامها: مخططات الأعمدة (bar charts)، المخططات التكرارية (histograms)، المخططات المبعثرة (scatterplots)، المخططات الدائرية (pie charts)، مخططات أعمدة الخطأ (error bar graphs) وغيرها. هناك أداة أيضاً لتحرير المخططات التي تقوم بإنشائها لتبدو أكثر جاذبية.
- **القائمة Window:** وتسمح لك بالانتقال بين النوافذ المختلفة ضمن البرنامج. فإذا كنت تعمل في نافذة الخرج، وأردت العودة إلى صفحة البيانات فيمكنك استخدام هذه القائمة.
- **القائمة Help:** وهي قائمة مفيدة جداً لأنها توفر المساعدة المباشرة حول النظام نفسه وحول الاختبارات الإحصائية. وبالرغم من أن ملفات المساعدة المتعلقة بالإحصاء عديمة الجدوى

أحياناً (لأن البرنامج ليس مصمماً ليعلمك الإحصاء) ولا بديل عن المعرفة الجيدة بهذا العلم، فإن هذه القائمة قد تساعدك بالخروج من مواقف صعبة أحياناً.

بالإضافة لشريط القوائم، هناك مجموعة من الأيقونات في القسم العلوي من نافذة محرر البيانات (انظر الشكل 2.2) وهي اختصارات لبعض الأدوات متكررة الاستخدام. يمكن الوصول إلى هذه الأدوات عن طريق شريط القوائم أيضاً إلا أن استخدام الأيقونات يوفر الوقت. وفيما يلي لائحة مختصرة بهذه الأيقونات وبوظائفها:

توفر هذه الأيقونة الخيار لفتح ملف محفوظ سابقاً (إذا كنت تعمل في محرر البيانات فإن برنامج SPSS سيفترض أنك تريد فتح ملف بيانات، أما إذا كنت في صفحة العارض فسيقدم لك الخيار بفتح ملفٍ من نوع العارض).

تسمح هذه الأيقونة بحفظ الملفات. فهي تقوم بحفظ الملف الذي تعمل فيه حالياً (سواء كان ملف بيانات أو خرج). إذا لم يتم حفظ الملف سابقاً فهي تعطي مربع الحوار save data as.

تقوم هذه الأيقونة بتفعيل مربع الحوار لطباعة ما تعمل فيه حالياً (سواء كان محرر البيانات أو الخرج). وتعتمد الخيارات الدقيقة للطباعة على الطابعة التي تستخدمها. من المفضل اختيار أجزاء من الخرج بنقر الفرع المناسب في نافذة العارض (انظر الفقرة 5.2). عندما يظهر مربع الحوار print، تذكر أن تنقر خيار طباعة النص المحدد فقط. إذا لم تقم بتحديد أجزاء من صفحة الخرج فإن برنامج SPSS سيقوم بطباعة كل ما هو موجود في تلك النافذة.

عند نقر هذه الأيقونة، تظهر لائحة تضم 12 من مربعات الحوار الأخيرة التي قمت باستخدامها. يمكنك اختيار مربع الحوار المطلوب من هذه اللائحة فيتم عرضه على الشاشة. وبذلك فإن هذه الأيقونة تفيد في تكرار بعض أجزاء التحليل.

تسمح هذه الأيقونة بالانتقال مباشرة إلى حالة ما. وهي مفيدة عند العمل في ملفات كبيرة للبيانات. فعلى سبيل المثال، إذا أردت تحليل عملية مسح لأكثر من 3000 مشترك فإن التنقل في صفحة البيانات بحثاً عن إجابات أحد المشتركين تكون عملية صعبة ومرهقة. يمكنك عندئذ استخدام هذه الأيقونة للقفز مباشرة إلى حالة معينة (الحالة 2407 مثلاً). عند نقر هذه الأيقونة يظهر مربع الحوار الذي يطلب منك إدخال رقم الحالة التي تريد القفز إليها.

عند نقر هذه الأيقونة يعطيك البرنامج معلومات عن متحول محدد في محرر البيانات (يسمح مربع الحوار الناتج باختيار المتحول الذي تريد ملخص المعلومات عنه).

تسمح هذه الأيقونة بالبحث عن كلمات أو أرقام في ملف البيانات أو نافذة الخرج.

يؤدي نقر هذه الأيقونة لإدراج حالة جديدة في محرر البيانات (حيث يقوم بإنشاء صف فارغ من الخلايا في النقطة المحددة حالياً في محرر البيانات). فإذا أردت إضافة بيانات جديدة أو نسيت وضع بيانات مشترك معين في محرر البيانات فإن هذه الوظيفة مفيدة جداً لتصحيح الوضع.

يؤدي نقر هذه الأيقونة لإدراج متحول جديد إلى يسار المتحول النشط حالياً (لتنشيط متحول ما انقر اسمه في ترويسة عموده).

إن نقر هذه الأيقونة هو اختصار للأمر ...Data ⇒ Split File (انظر الفقرة 4.3). يقود علماء الاجتماع تجاربهم عادةً على مجموعات مختلفة من الناس. ويتم تمييز المجموعات من الناس في برنامج SPSS باستخدام متحول ترميز (انظر الفقرة 4.4.2)، وتسمح هذه الوظيفة بتقسيم الخرج بمثل هذا المتحول. فعلى سبيل المثال، قد نختبر الذكور والإناث وفق مقدراتهم الإحصائية. نقوم عندئذ بترميز كل مشترك برقم يمثل جنسه وفق المتحول gender (ذكر=0، أنثى=1 مثلاً). إذاً أردنا بعد ذلك معرفة متوسط المقدرة الإحصائية لكل جنس على حدا، فإننا نطلب من البرنامج تقسيم الملف بالمتحول gender. ويتم تنفيذ عمليات التحليل اللاحقة على الذكور والإناث بشكل منفصل.

إن نقر هذه الأيقونة هو اختصار للأمر ...Data ⇒ Weight Cases. وهذه الوظيفة ضرورية عند التعامل مع إدخال البيانات التكرارية (انظر الفقرة 2.4.16)، وهي مفيدة أيضاً في بعض المسائل المتقدمة في أخذ العينات للمسح.

إن نقر هذه الأيقونة هو اختصار للأمر ...Data ⇒ Select Cases. إذا أردت تحليل جزء من البيانات فقط فإن هذه الوظيفة هي ما تحتاجه، فهي تسمح بتحديد الحالات التي تريد تضمينها في التحليل.

إن نقر هذه الأيقونة سيؤدي لإظهار أو إخفاء تسمية القيمة لأي من متحولات الترميز. نقوم غالباً بتجميع الناس معاً واستخدام متحول ترميز ما لنُعلم البرنامج بأن بعض المشتركين ينتمون إلى مجموعة معينة. فعلى سبيل المثال، إذا قمنا بترميز الجنس بالشكل ذكر=0، أنثى=1 فعندما يصادف البرنامج القيمة 1 في العمود gender يعرف أن الشخص هو أنثى. إذا نقرنا هذه الأيقونة سيظهر الترميز بدلاً من القيم العددية، أي أنك سترى الكلمة male أو female في العمود gender بدلاً من القيم 0 أو 1. تتوضح هذه الفكرة في الفقرة 4.4.2.

1.4.2 إدخال البيانات في محرر البيانات

عند تشغيل البرنامج SPSS تظهر نافذة محرر البيانات خاليةً من أية قيم وتكون تسميتها Untitled. وعند إدخال مجموعة جديدة من البيانات، فإنه يجب أن يتم بطريقة منطقية. إن محرر البيانات في SPSS مرتب بحيث يمثل كل صف البيانات لحالة واحدة بينما يمثل كل عمود متحولاً واحداً. وليس هناك تمييز بين المتحولات المستقلة وغير المستقلة، فكل متحول مهما كان نوعه سيشغل عموداً منفصلاً. النقطة الأساسية هي أن كل صف يمثل البيانات لشخص واحد. ولذلك يجب إدخال المعلومات عن تلك الحالة عبر محرر البيانات. تخيل أنك مهتم بدراسة الاختلافات بين الجنسين (الذكور والإناث) من ناحية إدراك الألم الناتج عن منبه ساخن أو بارد. تطلب من كل مشترك أن يضع يده في وعاء يحوي ماءً بارداً جداً لمدة دقيقة واحدة ثم تطلب منه تقييم مقدار الألم خلال التجربة على مقياس مدرج من 1 إلى 10. ثم تطلب من كل مشترك أن يحمل حبة بطاطا ساخنة، وتقيس مقدار الألم من جديد. لذلك سيحوي صف البيانات الخاص بكل مشترك بياناته الكاملة كالاسم والعمر والجنس ومقدار تحمل الألم الناتج عن الماء البارد ومقدار تحمل الألم الناتج عن البطاطا الساخنة، أي أنه سيحوي البيانات بالشكل التالي: Andy،31، male، 7، 10.

يمثل العمود الذي يحوي الجنس متحول تجميع، لأن المشترك يمكن أن ينتمي لمجموعة الذكور أو لمجموعة الإناث، ولكن لا يمكن أن ينتمي لكلتيهما! ولهذا يدعى هذا المتحول بالمتحول بين المجموعات. وبدلاً من تمثيل المجموعات بكلمات، فإن برنامج SPSS يفرض علينا استخدام الأرقام. ويتضمن ذلك تعيين رقم لكل مجموعة، وإعلام SPSS بالرقم الذي يمثل كل مجموعة. لذلك يتم تمثيل المتحولات بين المجموعات بعمود وحيد يتم فيه تعريف المجموعة التي ينتمي إليها الشخص برقم معين (انظر الفقرة 4.4.2). فعلى سبيل المثال، يمكنك أن تأخذ الاصطلاح التالي: إذا كان المشترك ذكراً فإنك تعطيه الرقم 0، وإذا كان أنثى فإنك تعطيها الرقم 1. بعد ذلك نطلب من برنامج SPSS أن يعتبر المشترك ذكراً إذا وجد القيمة 0 في عمود معين، وأن يعتبره أنثى إذا كانت القيمة 1 في ذلك العمود. يمكن استخدام هذا النوع من المتحولات (التي تحدد انتماء شخص ما إلى مجموعة معينة من بين عدة مجموعات) لتقسيم ملفات البيانات، ولذلك يمكنك في المثال السابق تنفيذ عملية التحليل على المشتركين الذكور أو المشتركات الإناث بشكل منفصل (انظر الفقرة 4.3).

أخيراً، قياسات الألم هي قياسات متكررة (خضع جميع المشتركين لكلا المنبهين: البارد والساخن). ولذلك يمكن إدخال مستويات هذا المتحول في عمودين منفصلين (أحدهما للألم الناتج عن المنبه الساخن، والآخر للألم الناتج عن المنبه البارد).

فكرة: يمكننا تلخيص فكرة التعامل مع المتحولات بأنه إذا تم قياس أي متحول لجميع المشتركين (قياس متكرر) فيجب تمثيله بعدة أعمدة يمثل كل منها مستوى واحداً للمتحول متكرر القياس. أما المتحولات التي تعرّف مجموعات مختلفة من الناس (عند استخدام متحول بين المجموعات وتعيين مستويات مختلفة من المتحول المستقل

للمشتركين المختلفين) فيتم تعريفها باستخدام عمود وحيد. ستصبح هذه الفكرة أكثر وضوحاً عندما تتعلم كيفية تنفيذ إجرائيات محددة.

يتألف محرر البيانات من مجموعات من الخلايا cells التي هي عبارة عن مربعات يتم وضع القيم فيها. عندما تكون الخلية نشطة يصبح الإطار المحيط بها أسوداً (كما في الشكل 2.2). يمكنك التنقل بين خلايا محرر البيانات باستخدام مفاتيح الأسهم في لوحة المفاتيح، أو بنقر الخلية التي تريد تنشيطها بمؤشر الفأرة. لإدخال رقم ما في محرر البيانات، انتقل إلى الخلية التي تريد وضع القيمة فيها، اكتب القيمة ثم اضغط مفتاح الأسهم المناسب لاتجاه الانتقال الذي ترغب به. فإذا رغبت بإدخال صف من البيانات، انتقل إلى الطرف الأيسر من الصف، أدخل القيمة ثم اضغط المفتاح →، حيث يتم إدخال القيمة والانتقال إلى الخلية التالية على الطرف الأيمن.

2.4.2 إنشاء متحول

الخطوة الأولى في إدخال البيانات هي إنشاء بعض المتحولات باستخدام صفحة عرض المتحولات (Variable View) لمحرر البيانات، ثم إدخال البيانات باستخدام صفحة عرض البيانات (Data View) لمحرر البيانات. وسنتعرف على هاتين الخطوتين من خلال تنفيذ مثال. تخيل أنك مهتم بدراسة الفروق بين المحاضرين والطلاب. نأخذ عينة عشوائية مؤلفة من 5 محاضرين و5 طلاب، ثم نسجل عدد أصدقاء كل منهم، ومعدل استهلاكهم الأسبوعي من الكحول، ومقدار دخلهم السنوي، ومدى عصبيتهم (كلما ازدادت القيمة ازدادت العصبية). يحوي (الجدول 1.2) هذه البيانات.

	عدد الأصدقاء No. of friends	مستوى الكحول Alcohol	الدخل السنوي Income	العصبية Neuroticism
محاضر	5	10	20 000	10
محاضر	2	15	40 000	17
محاضر	0	20	35 000	14
محاضر	4	5	22 000	13
محاضر	1	30	50 000	21
طالب	10	25	5 000	7
طالب	12	20	100	13
طالب	15	16	3 000	9
طالب	12	17	10 000	14
طالب	17	18	10	13

الجدول 1.2 بعض البيانات المستخدمة للتدريب

3.4.2 صفحة عرض المتحولات Variable View

قبل أن نبدأ فعلياً بإدخال أية بيانات في محرر البيانات، يجب علينا إنشاء المتحولات. ونستخدم صفحة عرض المتحولات في محرر البيانات لإنشاء المتحولات. للوصول إلى هذه الصفحة، ننقر التبويب Variable View في القسم السفلي من محرر البيانات، حيث تتغير محتويات النافذة وتتحول خلفية التسمية لصفحة عرض المتحولات إلى اللون الأبيض (انظر الشكل 3.2).

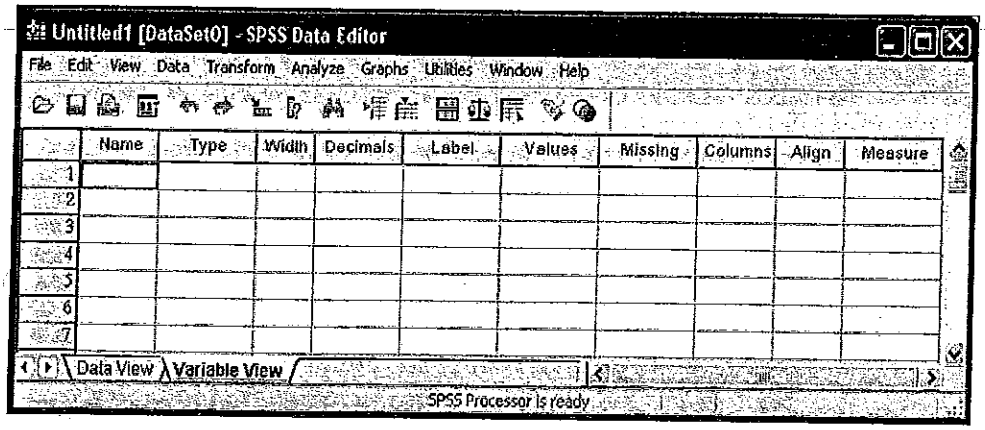

الشكل 3.2 صفحة عرض المتحولات في محرر البيانات لبرنامج SPSS

يمثل كل صف في صفحة عرض البيانات متحولاً واحداً، ويمكنك ضبط المميزات لمتحول ما بإدخال المعلومات في الأعمدة المسماة. يمكنك تغيير المميزات المختلفة كعرض العمود، وعدد المنازل بعد الفاصلة العشرية التي يتم إظهارها، وفيما إذا كانت القيمة ذات تحاذي إلى اليسار أو اليمين أو في الوسط. ومن بين المميزات الأكثر أهمية يمكن أن نذكر:

الاسم (Name) يمكنك أن تعطي اسماً في هذا العمود لكل من المتحولات. وعند الانتقال إلى صفحة عرض البيانات يظهر هذا الاسم في أعلى العمود لمساعدتك في التعرف على المتحولات في صفحة عرض البيانات. وهناك مجموعة من القواعد حول أسماء المتحولات مثل طول الاسم الذي يجب ألا يتجاوز 8 رموز، واستخدام حالة الأحرف الصغيرة فقط lower-case، كما لا يمكنك ترك فراغات في الاسم. إذا لم تحترم إحدى هذه القواعد فإنك البرنامج سيخبرك عند الانتقال إلى خلية أخرى بأن اسم المتحول غير مقبول.

النوع (Type) هناك أنواع مختلفة من البيانات. ويعتبر الرقمي (numeric) من أكثرها شيوعاً (وهو النوع الافتراضي في SPSS، ويعني أن قيمة المتحول تحوي أرقاماً). أما النوع الآخر الذي تصادفه فهو المتحول النصي (string)، وهو سلسلة من الأحرف. لذلك إذا أردت كتابة أسماء الأشخاص مثلاً فإنك بحاجة لهذا النوع من المتحولات.

التسمية (Label) إن اسم المتحول (كما رأيت سابقاً) محدود بثمانية رموز، لذلك يوفر SPSS وسيلة لإعطاء المتحول عنواناً أكثر وضوحاً (يمكن أن يحوي أحرفاً كبيرة وفراغات أيضاً). قد يبدو ذلك عديم الفائدة، ولكنها فعلياً من أفضل العادات التي يمكنك إتباعها. إذا أعطيت الاسم book للمتحول "عدد المرات التي أغلقت فيها الكتاب قبل أن أستطيع إنهاء فصل فيه"، فإن برنامج SPSS سيستخدم اسم المتحول (في هذه الحالة book) في جميع نتائج الخرج للتحليل. كل هذا رائع، ولكن صدقني أنك عندما تعود للبيانات والتحليل بعد عدة أشهر فلن تتذكر مدلول المتحول book، أو أنك ستستغرب من وجود متحول باسم sfg45c. لذلك تعوّد منذ الآن على تسمية المتحولات.

القيم (Values) يستخدم هذا العمود لتعيين أرقام لتمثيل مجموعات من الناس (انظر الفقرة 4.4.2).

المفقودة (Missing) يستخدم هذا العمود لتعيين أرقام للبيانات المفقودة (انظر الفقرة 6.4.2).

القياس (Measure) في هذا العمود يتم تحديد المستوى الذي تم عنده قياس المتحول (اسمي (Nominal)، تراتبي (Ordinal)، مقياس (Scale)).

لإدخال البيانات السابقة في محرر البيانات في SPSS، علينا إنشاء عدة متحولات. لنبدأ مع المتحول عدد الأصدقاء No. of friends، و نتبع الخطوات التالية:

1. أنقل مؤشر الفأرة إلى الخلية الأولى في العمود المسمى Name.
2. أكتب كلمة friends وتذكر أننا لا نستطيع استخدام اسم متحول أطول من 8 رموز، ولا يمكننا تضمينه أي فراغ.
3. غادر هذه الخلية باستخدام أحد مفاتيح الأسهم (يمكنك طبعاً استخدام الفأرة للنقر في خلية أخرى، إلا أن استخدام لوحة المفاتيح أسرع).

لقد قمت بإنشاء أول متحول! لاحظ أنه عند انتهائك من اسم المتحول قام برنامج SPSS بإنشاء الإعدادات الافتراضية لهذا المتحول (كافتراض أنه رقمي، وتحديد مترلتين عشريتين). والآن بما أننا نرغب في إتباع العادات الحسنة، سننتقل إلى الخلية في العمود المسمى Label ونكتب

Number of Friends. أخيراً يمكننا تحديد المستوى الذي تم عنده قياس هذا المتحول (انظر المربع 1.2) وذلك بالانتقال إلى العمود المسمى Measure واختيار إحدى القيم من القائمة المنسدلة (Nominal، Ordinal، Scale).

بعد إنشاء المتحول، يمكنك العودة إلى صفحة عرض البيانات بنقر التبويب Data View في القسم السفلي من محرر البيانات. لقد تغيرت محتويات النافذة، وتلاحظ أن تسمية العمود الأول قد أصبحت الآن friends. لإدخال البيانات، انقر الخلية البيضاء في قمة العمود المسمى friends واكتب القيمة الأولى 5. لتسجيل هذه القيمة في هذه الخلية علينا الانتقال إلى خلية مختلفة، وبما أننا نريد إدخال البيانات في هذا العمود فقط، فإن الطريقة الأنسب هي ضغط المفتاح ↓ في لوحة المفاتيح. يؤدي هذا الإجراء إلى الانتقال إلى الخلية التالية في نفس العمود، وسيظهر الرقم 5.00 في الخلية العلوية. أكتب الرقم 2 ثم اضغط المفتاح ↓ للانتقال إلى الخلية التالية وهلم جرا.

المربع 1.2 مستويات القياس

هناك عدة مستويات يمكن أن يتم عندها قياس المتحول: اسمي (nominal)، تراتبي (ordinal)، المجال (interval)، النسبة (ratio). تعتبر القيم الاسمية (nominal) في المستوى الأدنى، حيث تمثل الأرقام أسماءً فقط. فعلى سبيل المثال، إذا طرحنا السؤال التالي على بعض الأشخاص "هل استفدت من قراءة هذا الفصل" فإن إجابتهم ستكون نعم أو لا. لذلك ينقسم الأشخاص إلى فئتين فقط: المستفيدون، وغير المستفيدين. ونظراً لعدم وجود مقياس لمدى الاستفادة عند عناصر الفئة الأولى، فإن البيانات ستكون عبارة عن تسميات أو فئات فقط يمكن توزيع الناس فيها. إذا أعطينا رقماً لفئة المستفيدين وغير المستفيدين فإن قيمة الرقم ستكون غير مرتبطة بالموضوع، وهي ستمثل فئة فقط (لذلك، إذا كنت تريد استخدام المتحول كمتحول ترميز فإن البيانات ستكون من النوع الاسمي). تعطي البيانات من النوع التراتبي (ordinal) مزيداً من المعلومات مقارنة بالقيم الاسمية. إذا استخدمنا مقياساً تراتبياً لقياس شيء معين فإنه يمكننا معرفة الأشياء التي حدثت، وكذلك الترتيب الذي حدثت به. لكن هذه القيم لا تفيدنا عن الفروق بين القيم. فعلى سبيل المثال، إذا رتبنا ثلاثة أشخاص وفقاً لمستوى الاستفادة: مستفيد جداً، متوسط الاستفادة، قليل الاستفادة. فإن هذه التسميات تدلنا على مستوى الاستفادة. وباستخدام الفئات المرتبة، نحن نعلم الآن أن الشخص المستفيد جداً قد حقق فائدة أكثر من الشخص قليل الاستفادة! أما بيانات المجال (interval) فهي العلامات التي يمكن قياسها على سلم قياس تكون جميع مجالاته متساوية. فعلى سبيل المثال، وبدلاً من أن نسأل الأشخاص عن استفادتهم، يمكننا قياس الاستفادة على سلم مكون من 10 نقاط (حيث يمثل 0 عدم الاستفادة، و 10 الاستفادة الكاملة). لكي تكون البيانات من نوع المجال يجب أن يكون التغير بين القيمتين 3 و 4 لمستوى الفائدة مساوياً للتغير بين القيمتين 9 و 10. تملك البيانات من نوع النسبة (ratio) نفس الخاصية، إضافة إلى قدرتنا على القول أن شخصاً أعطى القيمة 8 لمستوى الاستفادة قد استفاد فعلياً ضعف ما استفاده شخص أعطى القيمة 4. وقد تم وضع النوعين الأخيرين من مستويات القياس للبيانات تحت الخيار Scale في برنامج SPSS. يجب أن يكون مفهوماً أنه في بعض العلوم الاجتماعية (وخاصة علم النفس) من الصعب جداً تقدير فيما إذا كانت البيانات من نوع المجال.

4.4.2 إنشاء متحولات الترميز

لقد ذكرنا في الفقرات السابقة مصطلح متحولات الترميز، وهذه الفقرة مخصصة لإعطاء وصف كامل عن هذا النوع من المتحولات (وهو نوع ستستخدمه كثيراً). متحول الترميز (coding variable) (ويدعى أيضاً متحول تجميع (grouping variable)) هو متحول يتكون من سلسلة من الأرقام التي تمثل مستويات لمتحول المعالجة أو تصف المجموعات المختلفة من الناس. يتم استخدام متحولات الترميز في التجارب لتمثيل المتحولات المستقلة التي تم قياسها بين المجموعات (حيث تم تعيين مشتركين مختلفين إلى مجموعات مختلفة). لذلك إذا أردت تنفيذ تجربة على مجموعة من المشتركين في ظروف تجريبية، وعلى مجموعة أخرى من المشتركين في مجموعة ضابطة للمقارنة، فيمكنك تعيين الرقم 1 للمجموعة التجريبية، والرقم 0 للمجموعة الضابطة. عند الانتقال لإدخال البيانات في محرر البيانات، ينبغي إنشاء متحول (يمكنك أن تدعوه group) وكتابة الرقم 1 لجميع المشتركين من المجموعة التجريبية، والرقم 0 لجميع المشتركين من المجموعة الضابطة. يخبر هذا المتحول البرنامج بأن يعامل جميع الحالات التي تكون فيها قيمته 1 كأنها تنتمي لنفس المجموعة، وبشكل مشابه للحالات التي تكون فيها قيمته 0 حيث يجب معاملتها كأنها تنتمي لنفس المجموعة. في الحالات غير التجريبية، يمكنك أن تستخدم هذه المتحولات للتمييز بين مجموعات البشر المختلفة (فقد تعطي للطلاب الرقم 1 وللمحاضرين الرقم 0 وهكذا).

في البيانات التي لدينا، هناك متحول ترميز هو المتحول الذي يميز فيما إذا كان الشخص طالباً أم محاضراً. لإنشاء هذا المتحول، نتبع نفس الخطوات لإنشاء متحول طبيعي، ولكن علينا إخبار البرنامج بالرموز الرقمية التي تم تعيينها لكل مجموعة. لذلك، يجب أولاً، العودة إلى صفحة عرض المتحولات والانتقال إلى الخلية اليسرى في الصف الثاني من محرر البيانات في العمود المسمى Name وكتابة الاسم (ندعو المتحول group). وبما أننا نحاول إتباع العادات الحسنة، فإننا ننتقل في نفس الصف إلى الخلية في العمود المسمى Label ونعطي وصفاً كاملاً للمتحول مثل "هل الشخص محاضر أم طالب؟" Is the person a lecturer or a student?. لتعريف رموز المجموعة، ننتقل في نفس الصف إلى الخلية في العمود المسمى Values. ستلاحظ أن هذه الخلية تعطي الكلمة None، وهناك زر (انظر الشكل 4.2). انقر هذا الزر للوصول إلى مربع الحوار تسميات القيم Value Labels.

يُستخدم مربع الحوار Value Labels لتحديد رموز المجموعات. ويمكن أن يتم ذلك بتنفيذ ثلاث خطوات بسيطة. انقر أولاً في حيز النص بجانب التسمية Value (أو اضغط المفتاح Alt والمفتاح u بنفس الوقت) ثم اكتب رمزاً (1 مثلاً). إن هذه الرموز هي اختيارية تماماً، ولكن تعوّد الناس على استخدام الأرقام 0 و1 و2 و3 وغيرها، ولكن يمكنك عملياً اختيار الرمز 495 أو أي رمز تريده. الخطوة الثانية هي نقر حيز النص بجانب التسمية Value Label (أو اضغط المفتاح Tab، أو المفتاح Alt مع المفتاح e) ثم اكتب التسمية المناسبة لتلك المجموعة. في الشكل 4.2 اخترنا الرمز 2 وأعطيناه التسمية Student. أما الخطوة الثالثة فهي إضافة هذا الرمز إلى اللائحة بنقر الزر Add. وكنا قد

عرّفنا الرمز 1 سابقاً للمجموعة Lecturer. عند الانتهاء من تعريف جميع قيم الرموز انقر الزر OK. إذا نقرت الزر OK ونسيت إضافة الرمز الأخير إلى اللائحة فإن برنامج SPSS يقوم بإظهار رسالة تحذير تفيد بأنك ستفقد التغيرات الأخيرة. وبلغة واضحة فإن ذلك يعني ضرورة العودة ونقر الزر Add قبل الاستمرار.

تمثل متحولات الترميز الفئات دائماً ولذلك فإن المستوى الذي يتم قياسها عنده هو الاسمي (nominal) (أو التراتبي (ordinal) إذا كان للفئات ترتيب جدّي). لذلك يجب تحديد المستوى الذي يقاس عنده المتحول بالانتقال إلى العمود الأخير المسمى Measure واختيار Nominal من القائمة المنسدلة (أو Ordinal إذا كان للفئات ترتيب جدّي).

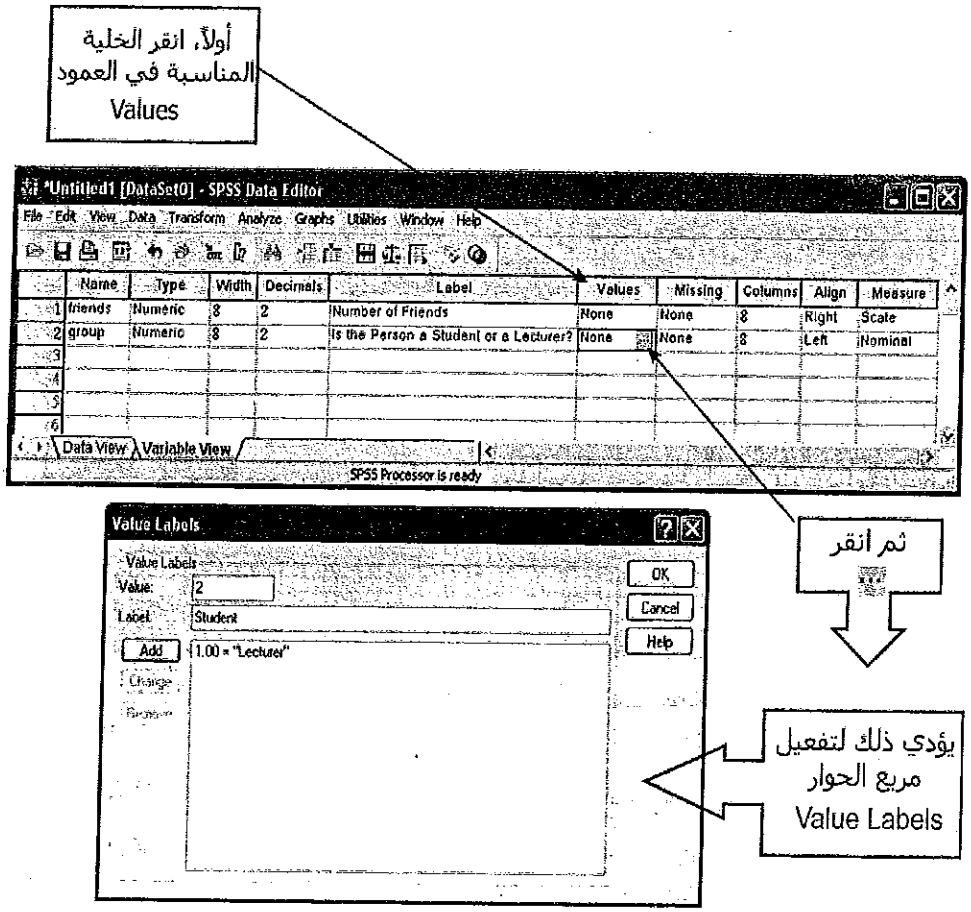

الشكل 4.2 تعريف متحولات الترميز وقيمها في برنامج SPSS

بعد تعريف الرموز، يمكن التبديل إلى صفحة عرض البيانات وإدخال القيم الرقمية في الأعمدة المناسبة (فإذا كان الشخص محاضراً اكتب الرقم 1، وإذا كان طالباً اكتب الرقم 2). الشيء الرائع

هنا هو أنه يمكن للبرنامج أن يُظهر قيم الرموز، أو تسميات القيم التي عرّفتها سابقاً، وذلك بنقر الأيقونة المناسبة في شريط الأيقونات (انظر الشكل 5.2). يوضح الشكل 5.2 كيفية ترتيب البيانات عند استخدام متحول الترميز. تذكّر أن كل صف من محرر البيانات يمثل البيانات الخاصة بمشترك واحد، وفي هذا المثال فإن من الواضح أن المشتركين الخمسة الأوائل هم محاضرون بينما بقية المشتركين هم طلاب. يوضح هذا المثال أيضاً سبب استخدام متحولات التجميع مع المتحولات التي تم قياسها بين المواضيع، وذلك لأن استخدام متحول الترميز يجعل من المستحيل انتماء مشترك ما لأكثر من مجموعة واحدة. ويجب أن تحدث هذه الحالة عند التصميم بين المجموعات (أي يجب ألا يتم اختبار مشترك ما في كلتا المجموعتين: التجريبية والضابطة). وعلى كل حال، في التصميم متكرر القياسات (ضمن المواضيع) فإن اختبار كل مشترك يجب أن يتم في جميع الظروف ولذلك لا نستخدم هذا النوع من متحولات الترميز (وذلك لأن كل مشترك يشارك في كل ظرف تجريبي).

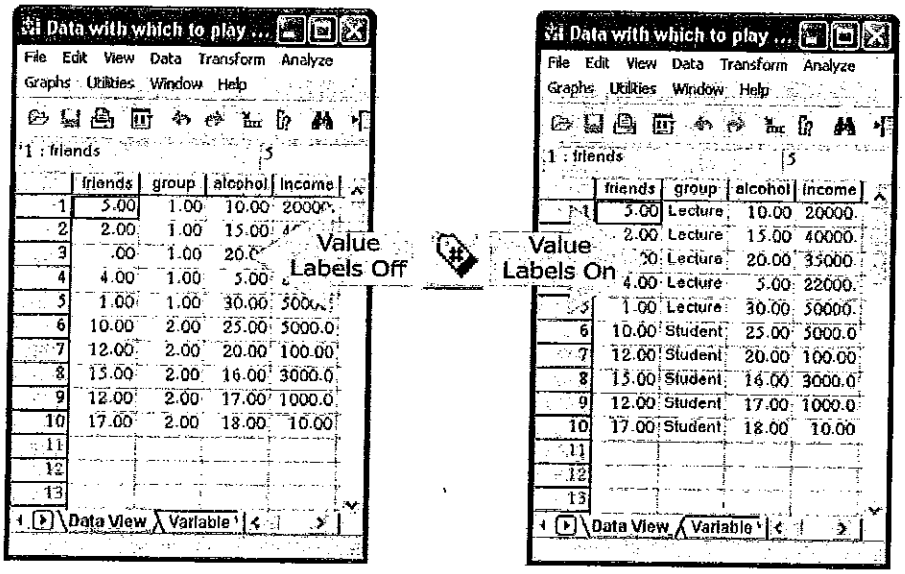

الشكل 5.2 قيم الترميز في محرر البيانات عند إظهار تسميات المتحول أو إخفائها

5.4.2 أنواع المتحولات

هناك أنواع مختلفة من المتحولات التي يمكن استخدامها في برنامج SPSS. وفي معظم الحالات، تجد أنك تستخدم المتحولات الرقمية (numeric). وتحوي هذه المتحولات أرقاماً وتضم متحولات الترميز التي تم وصفها سابقاً. وعند إنشاء متحول ما، فإن خيار تحديد نوع المتحول يكون واحداً من بين الخيارات العديدة المتاحة، ولتحديد نوع المتحول ننقر العمود المسمى Type في صفحة عرض المتحولات ثم ننقر الزر [...] (كما فعلنا في الشكل 4.2 عندما عرّفنا تسميات المتحولات). يتم تفعيل مربع الحوار نوع المتحول Variable Type الموضح في (الشكل 6.2)، والذي يعرض

الإعدادات الافتراضية. يقوم البرنامج باختيار نوع المتحول numeric بشكل افتراضي وتحديد عدد خاناته 8، ولكن يمكنك تغيير هذه القيمة بكتابة رقم جديد في الحيز المسمى Width في مربع الحوار. في الظروف العادية يمكن الاكتفاء بـ 8 خانات، إلا إذا كنت تريد القيام بعمليات حسابية تتطلب دقة خاصة. القيمة الافتراضية الثانية التي يختارها البرنامج هي 2، عدد المنازل العشرية التي يتم إظهارها (وتلاحظ ذلك عندما تكتب أرقاماً صحيحة فيقوم البرنامج بإظهار الفاصلة العشرية مع صفرين بعدها. يمكنك تغيير عدد المنازل التي تريد من البرنامج إظهارها لمتحول ما وذلك باستبدال الرقم 2 الموجود في الحيز المسمى Decimal Places بمستوى الدقة المطلوب.

يسمح مربع الحوار Variable Type بتحديد أنواع أخرى من المتحولات. في معظم الأحيان نستخدم القيم الرقمية، ولكن يمكننا أيضاً استخدام المتحول النصي String. والمتحول النصي هو ببساطة سطر من النص، يمكنه أن يمثل التعليقات حول مشترك معين، أو المعلومات الأخرى التي لا ترغب بتحليلها كمتحول تجميع (مثل اسم المشترك). إذا اخترت نوع المتحول String فإن برنامج SPSS يسمح لك بتحديد طول المتحول النصي (الذي تكون قيمته الافتراضية 8 رموز) بحيث يمكنك إدخال قيم نصية أطول عند الضرورة.

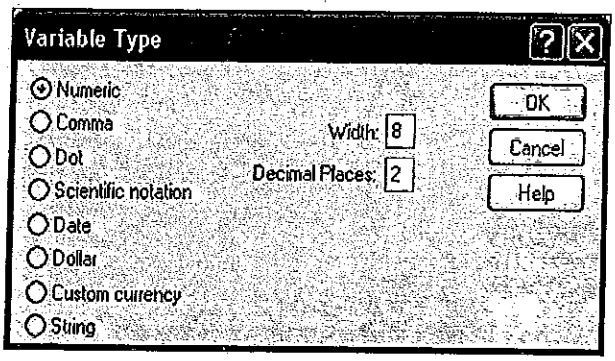

الشكل 6.2 تحديد نوع المتحول الذي يتم استخدامه

6.4.2 القيم المفقودة

نعمل كباحثين بجد واجتهاد لتجميع مجموعات كاملة من البيانات، ومع ذلك تكون هناك غالباً بعض البيانات المفقودة. ويمكن أن ينتج ذلك عن مجموعة من الأسباب المختلفة، ففي الاستبيانات الطويلة ينسى بعض المشتركين بدون قصد الإجابة على بعض الأسئلة، وفي الإجراءات التجريبية يمكن أن تقود الأعطال الميكانيكية إلى بيانات غير مسجلة، أما في الأبحاث حول المواضيع الحساسة (كالسلوك الجنسي) فقد يمارس بعض المشتركين حقهم في عدم الإجابة على سؤال معين. على كل حال، إن فقدان بعض البيانات لمشترك ما، لا يعني أن علينا إهمال بقية البيانات التي قمنا بجمعها (مع أن ذلك يسبب بعض المصاعب الإحصائية أحياناً). ولكن يجب علينا إعلام البرنامج أن هناك قيمة مفقودة لشخص معين. والمبدأ الكامن خلف القيم المفقودة شبيه جداً بمبدأ متحولات الترميز،

حيث نستخدم قيمة رقمية لتمثيل نقطة البيانات المفقودة. تخبر هذه القيمة البرنامج بعدم وجود قيمة مسجّلة لمتحول معين ما أجل مشترك ما. يقوم البرنامج بإهمال تلك الخلية في محرر البيانات (لا يستخدم في التحليل القيمة التي أدخلتها). يجب الانتباه إلى أن القيمة الرقمية المختارة لا تتطابق مع أية قيمة موجودة طبيعياً. فعلى سبيل المثال، إذا طلبنا من البرنامج اعتبار القيمة 9 كقيمة مفقودة، وكانت القيمة 9 موجودة فعلياً عند مجموعة من المشتركين، فإن البرنامج سيُعامِل بياناتهم كقيم مفقودة، بينما هي في الحقيقة موجودة وليست مفقودة.

لتحديد القيم المفقودة ننقر على العمود المسمى Missing في صفحة عرض المتحولات ثم ننقر الزر [...] لتفعيل مربع الحوار القيم المفقودة Missing Values المبين في (الشكل 7.2). يعتبر برنامج SPSS بشكل افتراضي عدم وجود قيم مفقودة ولكن إذا كان لديك بيانات مع قيم مفقودة فيمكنك تعريفها بإحدى الطرق الثلاث التالية. الطريقة الأولى هي اختيار قيم منفصلة (وذلك بنقر الخيار Discrete missing values) وهي قيم فريدة تمثل القيم المفقودة. إن السبب وراء اختيار عدة أرقام لتمثيل القيم المفقودة هو إمكانية تعريف معاني مختلفة لكل من القيم المنفصلة. فعلى سبيل المثال، يمكنك اختيار الرقم 8 لتمثيل الإجابة "غير قابل للتطبيق"، والرقم 9 لتمثيل الإجابة "لا أعلم"، والرقم 99 للدلالة على أن المشترك لم يعط أية إجابة. وطالما كان البرنامج معنياً فإنه سيُهمِل خلايا البيانات التي تحوي إحدى هذه القيم. وعلى كل حال فإن استخدام رموز مختلفة قد يكون مفيداً لتذكيرك بسبب فقدان بيانات معينة. وعادة ما تكون قيمة منفصلة واحدة كافية، وفي التجارب التي تقاس بها المواقف على مقياس مؤلف من 100 نقطة (أي أن العلامات تتراوح بين 1 و 100) فإنه يمكنك أن تختار القيمة 666 مثلاً لتمثيل القيم المفقودة لأنه لا يمكن العثور على مثل هذه القيمة في البيانات التي قمت بجمعها. أما الطريقة الثانية فهي اختيار مجال من القيم لتمثيل البيانات المفقودة، وهذا مفيد في الحالة التي يكون فيها من الضروري استثناء البيانات الواقعة بين نقطتين. فعلى سبيل المثال، يمكننا استثناء جميع العلامات الواقعة بين 5 و10. أما الطريقة الأخيرة فهي استخدام مجال من القيم مع قيمة منفصلة واحدة.

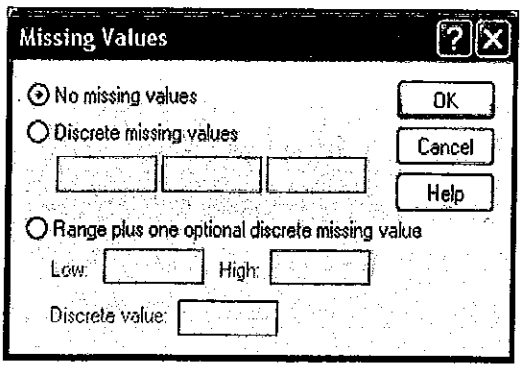

الشكل 7.2 تعريف القيم المفقودة

7.4.2 تغيير التنسيق للأعمدة

يسمح الخيار الأخير المتوفر عند تعريف متحول ما بضبط تنسيق العمود ضمن محرر البيانات. إن الخيار الافتراضي لتنسيق العمود هو أن يكون عرضه 8 رموز، وأن تتم محاذاة النص فيه إلى اليمين. يمكن تغيير هاتين القيمتين الافتراضيتين. في صفحة عرض المتحولات، يمكنك زيادة أو تخفيض القيمة الافتراضية 8 بنقر الأسهم المشيرة للأعلى والأسفل. ولتغيير محاذاة النص ضمن العمود، انقر العمود المسمى Align ثم انقر الخلية للمتحول الذي تريد تغييره. يمكنك بعد ذلك تفعيل القائمة المنسدلة بنقر السهم المشير للأسفل ثم اختيار أحد الخيارات المتاحة (محاذاة إلى اليسار Left، إلى اليمين Right، توسيط Center). من المفيد ضبط عرض العمود عندما تستخدم متحول ترميز مع تسمية للقيمة يتجاوز طولها 8 رموز.

8.4.2 اختبار سريع

بعد إنشاء المتحولين friends وtype مع قليل من التوجيه، حاول الآن إدخال بقية المتحولات الموجودة في الجدول 1.2 بنفسك. إن الشكل النهائي لصفحة عرض البيانات ولصفحة عرض المتحولات مبين في (الشكل 8.2).

5.2 عارض الخرج

إلى جانب محرر البيانات، هناك نافذة ثانية في برنامج SPSS تدعى العارض (viewer) (أو عارض الخرج (output viewer)). في السابق كانت نافذة الخرج (كما كانت تسميتها آنذاك) تُظهِر النتائج الإحصائية بخط لطيف، أما المخططات البيانية فكان يتم إظهارها في نافذة منفصلة. أما اليوم فيقوم عارض النتائج المحسّن والمذهل بعرض المخططات البيانية والجداول والنتائج الإحصائية في نفس النافذة (بخطوط أجمل وجداول أكثر ترتيباً).

يبين (الشكل 9.2) التخطيط الأساسي لعارض النتائج. في القسم الأيمن هناك مساحة كبيرة خالية يتم إظهار الخرج فيها. يقوم SPSS بإظهار المخططات ونتائج التحليل الإحصائي في هذا القسم. من الممكن تحرير المخططات البيانية، وذلك بنقر المخطط الذي تريد تحريره نقرة مزدوجة مما يؤدي لفتح نافذة جديدة يتم فيها تحرير المخطط. أما القسم الأيسر لعارض الخرج فيحوي مخططاً بشكل شجرة يوضح بنية الخرج. ولهذا المخطط الشجري أهمية كبرى، وخاصة عند تنفيذ عدة عمليات تحليل، حيث يوفر وسيلة سهلة للوصول إلى أجزاء معينة من الخرج. إن بنية الشجرة سهلة الإيضاح حيث يقوم برنامج SPSS بإضافة الإجراءات التي تقوم بها (مثل رسم مخطط بياني أو تنفيذ عملية إحصائية) كعنوان رئيسي في الشجرة.

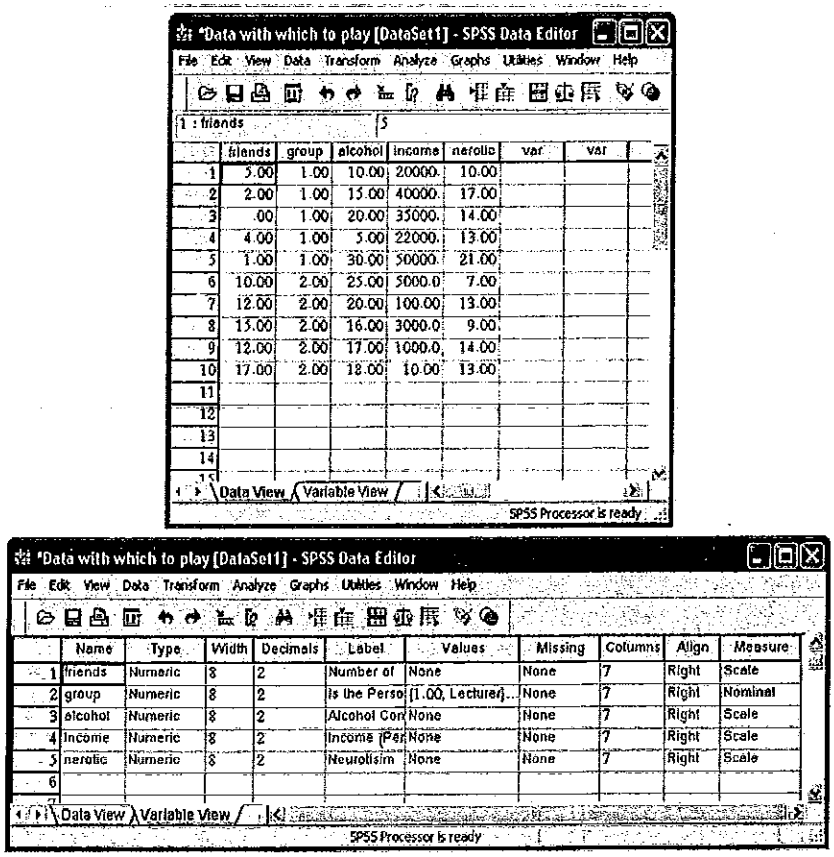

الشكل 8.2 الشكل النهائي لصفحة عرض البيانات ولصفحة عرض المتحولات من أجل البيانات الموجودة في الجدول 1.2

لقد قمنا في الشكل 9.2 بتنفيذ إجراءات رسم مخطط بياني ثم قمنا بعملية تحليل التباين وحيد الاتجاه (ANOVA) لذلك نرى هذه الأسماء تظهر كعنوان رئيسية. ولكل إجراء هناك سلسلة من الإجراءات الفرعية يتم عرضها كعناوين فرعية تحت العنوان الرئيسي. فعلى سبيل المثال، هناك عدة أقسام في الإجراء ANOVA في نافذة العارض كاختبار Levene (الذي يختبر فرضية التجانس للتباين) والآثار بين المجموعات (مثل الاختبار F الذي يبين فيما إذا كانت قيم المتوسط مختلفة بشكل كبير). يمكنك الانتقال إلى أي من هذه المكونات الفرعية للخرج ANOVA بنقر العنوان الفرعي المناسب في مخطط الشجرة. لذلك إذا أردت الانتقال إلى الآثار بين المجموعات مباشرة فإن عليم نقل السهم على الشاشة في القسم الأيسر من النافذة ونقر العنوان Tests of Between-Subjects Effects. بهذا الإجراء يتم نقل التركيز على هذا الجزء في القسم الأيمن من نافذة العارض. يمكنك أيضاً استخدام مخطط الشجرة لاختيار أجزاء من الخرج بغرض طباعتها مثلاً. فعلى سبيل المثال، إذا قررت طباعة المخطط البياني دون طباعة الخرج بكامله فيمكنك نقر العنوان الرئيسي Graph في الشجرة (في القسم الأيسر من النافذة) ثم اختيار الأمر طباعة Print لطباعة الجزء المحدد من الخرج فقط. في هذا

الإطار، من المفيد التذكير بأن اختيار عنوان رئيسي (مثل Univariate Analysis of Variance) سيؤدي لاختيار هذا العنوان مع جميع العناوين الفرعية الموجودة تحته. وهذا مفيد جداً عندما نريد طباعة النتائج لإجراء إحصائي معين.

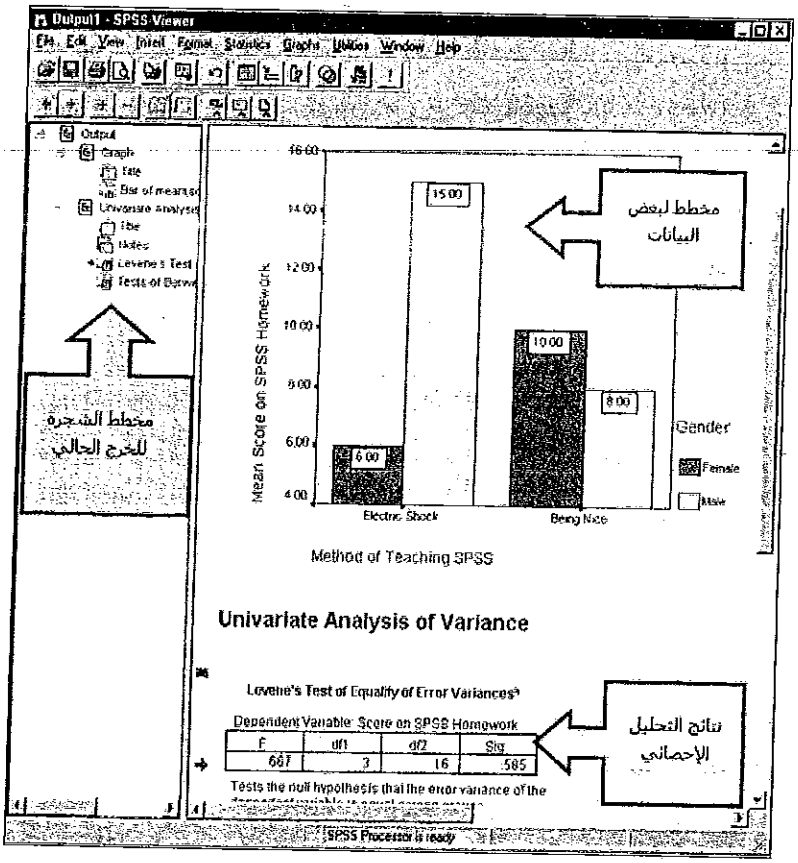

الشكل 9.2 نافذة عارض الخرج

هناك عدة أيقونات في نافذة عارض الخرج، تساعد في تنفيذ المهام بسرعة دون استخدام القوائم. بعض هذه الأيقونات مشابه للأيقونات التي تم وصفها عند الحديث عن نافذة محرر البيانات، لذلك سنركز في هذه الفقرة بشكل رئيسي على الأيقونات الخاصة بنافذة العارض.

كما في نافذة محرر البيانات، تقوم هذه الأيقونة بتفعيل قائمة الطباعة. فعند نقر هذه الأيقونة في نافذة العارض يتم تفعيل قائمة طباعة الخرج. عند تفعيل قائمة الطباعة يظهر الخيار الافتراضي لطباعة الخرج بكامله، وإمكانية اختيار طباعة الجزء الظاهر حالياً على الشاشة، أو اختيار طباعة الجزء المحدد من الخرج. لتحديد الخيار الأخير، يجب عليك أن تكون قد حددت بشكل مسبق الجزء الذي تريد طباعته من الخرج.

تعيدك هذه الأيقونة إلى محرر البيانات بسرعة.

تنقلك هذه الأيقونة إلى الخرج الأخير في نافذة العارض (أي إلى الإجراء الأخير الذي نفذته).

تقوم هذه الأيقونة بترقية (promote) الجزء النشط حالياً في الشجرة إلى مستوى أعلى. لنعد إلى الشكل 9.2، نلاحظ أن العنوان Tests of Between-Subjects Effects هو مكون فرعي للعنوان الرئيسي Univariate Analysis of Variance. إذا أردنا ترقية هذا الفرع في الخرج إلى مستوى أعلى بحيث يصبح عنواناً رئيسياً مثلاً، فإن هذه الأيقونة تقوم بهذه المهمة.

إن عمل هذه الأيقونة معاكس لما تقوم به الأيقونة السابقة، حيث تقوم بتخفيض مرتبة (demote) الجزء النشط حالياً في الشجرة إلى مستوى أدنى. لنعد إلى الشكل 9.2، إذا لم نرغب أن يكون العنوان Univariate Analysis of Variance هو القسم الوحيد فإنه باستخدام هذه الأيقونة يمكننا اختيار هذه العنوان وتخفيض مستواه بحيث يصبح جزءاً من العنوان السابق له (العنوان الرئيسي Graph). إن هذه الأيقونة مفيدة في تركيب أجزاء الخرج المتعلقة بموضوع بحث محدد.

تقوم هذه الأيقونة بطيّ (collapse) أجزاء في بنية الشجرة، أي أنها تقوم ببساطة بإخفاء المكونات الفرعية للعنوان المحدد. لنعد إلى الشكل 9.2، إذا اخترنا العنوان Univariate Analysis of Variance ونقرنا هذه الأيقونة، فإن جميع العناوين الفرعية ستختفي من بنية الشجرة، ولكنها لا تختفي فعلياً من الخرج نفسه. تفيد هذه الأيقونة عند القيام بعدد من عمليات التحليل حيث تكون بنية الشجرة معقدة جداً.

تقوم هذه الأيقونة بتوسيع (expand) الأجزاء المطوية. بشكل افتراضي، تكون جميع العناوين الرئيسية ظاهرة في مخطط الشجرة بشكلها الموسع. إذا أردت لسبب ما طيّ أجزاء من الشجرة (باستخدام الأيقونة السابقة) فإنك تستطيع إعادة توسيعها باستخدام هذه الأيقونة.

تسمح هذه الأيقونة بإخفاء أجزاء من الخرج ذاته. لذلك يمكنك اختيار جزء من الخرج في مخطط الشجرة ونقر هذه الأيقونة لإخفائه من الخرج ذاته (القسم الأيمن من النافذة). لا يتم حذف ذلك الجزء وإنما يتم إخفاؤه من العرض، ولذلك فهي شبيهة بأيقونة الطيّ التي ذكرناها سابقاً ولكن تؤثر على الخرج بدلاً من بنية الشجرة. وهي مفيدة لإخفاء الأجزاء الأقل أهمية في نافذة الخرج.

تقوم هذه الأيقونة بعمل معاكس لما تقوم به الأيقونة السابقة، فإذا قمت بإخفاء جزء محدد من الخرج ثم نقرت هذه الأيقونة فإن الجزء المحدد سيعود للظهور. بشكل افتراضي

تكون جميع أجزاء الخرج ظاهرة، وتكون هذه الأيقونة غير فعّالة، ولكنها تصبح نشطة عند إخفاء أجزاء من الخرج.

تقوم هذه الأيقونة بإدراج عنوان جديد في مخطط الشجرة. فعلى سبيل المثال، إذا كان لديك عدة اختبارات إحصائية مرتبطة بأحد مواضيع البحث العديدة، فإنه يمكنك إدراج عنوان رئيسي ثم تخفيض مستوى عناوين الاختبارات ذات العلاقة بحيث تقع جميعها تحت العنوان الجديد.

لنفترض أنك استخدمت الأيقونة السابقة ونفذت الخطوة كاملة، يمكنك باستخدام هذه الأيقونة إعطاء اسم للعنوان الجديد الذي أنشأته. يظهر اسم العنوان في الخرج. لذلك يمكنك اختيار عنوان مثل Research Question Number 1 بحيث يدل على أن جميع العناوين الفرعية تحت هذا العنوان مرتبطة بالموضوع الأول من مواضيع البحث.

تستخدم هذه الأيقونة لوضع حيز نصي في نافذة الخرج. يمكنك كتابة ما تريد في هذا الحيز. وفيما يخص الأيقونتين السابقتين، فإنه يمكنك استخدام حيز نصي لشرح ما تقصده بالموضوع الأول من مواضيع البحث.

6.2 نافذة القواعد

ذكرنا سابقاً أنه من المفيد أحياناً استخدام القواعد في SPSS. إنها لغة الأوامر والتعليمات لتنفيذ التحليل الإحصائي والتعامل مع البيانات. وفي معظم الأحيان تقوم بتنفيذ تلك الأوامر عن طريق مربعات الحوار في برنامج SPSS، ولكن استخدام القواعد يمكن أن يكون مفيداً أيضاً. هناك بعض الأشياء التي يمكنك تنفيذها باستخدام القواعد والتي لا يمكن تنفيذها عبر مربعات الحوار (ومعظم هذه الأشياء هي متقدمة نسبياً، ولكن سنقوم في هذا الكتاب بعرض بعض الخدع الجميلة باستخدام القواعد). والسبب الثاني لاستخدام القواعد هو في حالة تنفيذ عمليات تحليل متشابهة جداً على مجموعات من البيانات. في هذه الحالات، ولتنفيذ أسرع فإنه يمكنك إجراء عمليات التحليل وحفظ القواعد. ولحسن الحظ، تملك معظم مربعات الحوار في برنامج SPSS زر اللصق (Paste). فإذا حددت عمليات التحليل باستخدام مربعات الحوار فإنه يكفي النقر على هذا الزر ليقوم بلصق القاعدة في نافذة القواعد. لفتح نافذة القواعد استخدم أوامر القائمة File ⇒ New ⇒ Syntax... فتظهر نافذة القواعد كما في (الشكل 10.2).

يمكن كتابة الأوامر مباشرة في هذه النافذة. هناك بعض القواعد التي تحكم كتابة الأوامر في نافذة القواعد، منها أنه يجب إنهاء السطر بنقطة (.) فإذا نسيت وضع هذه النقطة فإن البرنامج يعطيك رسالة خطأ. إن استخدام نافذة القواعد ليس ضرورياً ولكن يمكن للراغبين باستخدامها التعرف في هذا الكتاب على بعض المبادئ الأساسية بحيث يمكنهم البدء بشكل صحيح. بعد كتابة القواعد في هذه النافذة، عليك تشغيلها باستخدام القائمة Run. يتولى الأمر Run ⇒ All تشغيل جميع القواعد

الموجودة في النافذة (وتقوم الأيقونة Run Current بهذه المهمة أيضاً)، ويمكنك تحديد القواعد التي ترغب بتنفيذها باستخدام الفأرة ثم اختيار الأمر Run ⇒ Selection لتشغيلها. يمكنك أيضاً تشغيل الأمر الحالي باستخدام Run ⇒ Current (أو ضغط مفتاح الاختصار Ctrl+R)، أو تشغيل جميع الأوامر اعتباراً من موقع المؤشر وحتى نهاية النافذة باستخدام الأمر Run ⇒ To End.

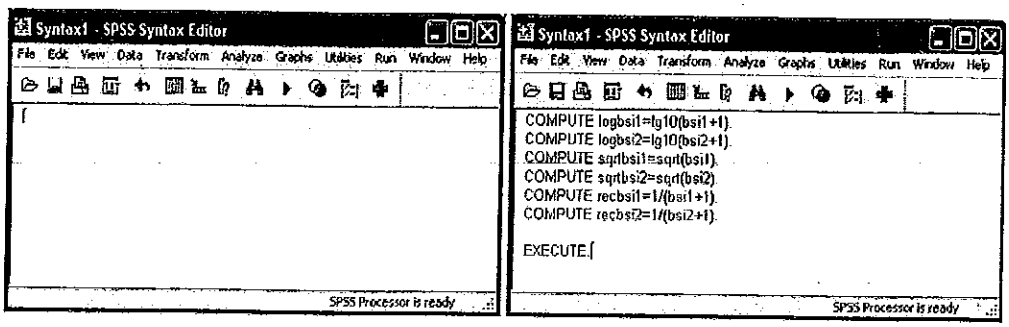

الشكل 10.2 نافذة القواعد، جديدة (إلى اليسار)، ومع بعض القواعد فيها (إلى اليمين)

7.2 حفظ الملفات

مع أن معظم المستخدمين يعرفون كيفية حفظ الملفات في نظام التشغيل Windows فإنني أعتقد أنه من الضروري معرفة ما يجب عمله ولذلك سأقوم بإعطاء فكرة مختصرة. لحفظ الملفات يكفي النقر على الأيقونة Save File أو استخدام القائمة File ⇒ Save أو File ⇒ Save As... إذا كان الملف جديداً فإن نقر الأيقونة ينشط مربع الحوار Save Data As (انظر الشكل 11.2). إذا كنت في محرر البيانات عند نقر أيقونة الحفظ فإن البرنامج سيقوم بحفظ ملف البيانات الذي تعمل فيه حالياً، ولكن إذا كنت في نافذة العارض فإنه سيقوم بحفظ الخرج الحالي.

هناك عدة سمات لمربع الحوار المبين في الشكل 11.2. يجب أولاً تحديد الموقع الأساسي الذي تريد تخزين الملف فيه. هناك عادة نوعان من المواقع لحفظ الملفات: الأقراص الصلبة والأقراص المرنة، وتتوفر حالياً سواقات الأقراص المضغوطة القابلة لإعادة الكتابة عليها، ومحركات الأقراص Zip و Jaz وغيرها. بعد تحديد الموقع الأساسي، يقوم مربع الحوار بإظهار المجلدات المتاحة على ذلك الموقع (إن وجدت). يمكنك إنشاء مجلد جديد بنقر الأيقونة Create New Folder. بعد تحديد المجلد الذي تريد تخزين الملف فيه، ينبغي عليك إعطاء اسم لهذا الملف. إذا نقرت في الحيز بجانب التسمية اسم الملف File name فإن المؤشر سيظهر في هذا المربع حيث يمكنك كتابة اسم الملف. يتم حفظ الملف بشكل افتراضي وفق التنسيق SPSS، فإذا كان الملف ملف بيانات فإن لاحقته ستكون sav.، أما إذا كان ملف نتائج (العارض) فإن اللاحقة ستكون spo.، وإذا كان ملف قواعد فإن اللاحقة ستكون sps.، وعلى كل حال يمكنك حفظ الملف بتنسيق مختلف مثل Microsoft Excel أو ملف نصي محدد بالجدولة. لتنفيذ ذلك، انقر السهم في نهاية حيز النص المجاور للتسمية Save as type

واختر التنسيق المطلوب من القائمة المنسدلة. إذا كان حفظ الملف قد تم سابقاً، فإنه يمكن تحديث الملف (حفظه ثانية) بنقر الأيقونة Save File. تظهر هذه الأيقونة في كل من نافذتي محرر البيانات والعارض، ويعتمد نوع الملف الذي يتم حفظه على النافذة النشطة حالياً. سيتم حفظ الملف في الموقع الذي يخزنه حالياً.

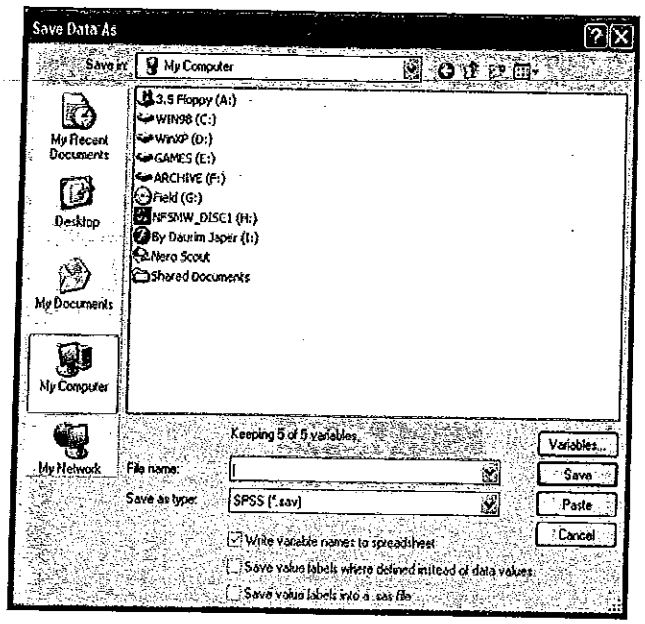

الشكل 11.2 مربع الحوار حفظ البيانات باسم Save Data As

8.2 استعادة ملف

ستتعامل خلال قراءتك لهذا الكتاب مع ملفات البيانات المتوفرة على القرص المضغوط المرفق بالكتاب. ولذلك فمن الضروري معرفة كيفية تحميل ملفات البيانات من القرص المضغوط إلى برنامج SPSS. إن العملية بسيطة جداً. لفتح ملف ما، انقر على الأيقونة فتح ملف Open File أو استخدم القائمة File ⇒ Open ⇒ Data... لتنشيط مربع الحوار المبين في (الشكل 12.2). يجب عليك أولاً إيجاد الموقع الذي يحوي الملف المطلوب. إذا كنت تريد تحميل ملف من القرص المضغوط، فإن عليك أولاً الوصول إلى محرك القرص المضغوط بنقر السهم الموجود في نهاية حيز النص المسمى Look in واختيار محرك الأقراص المطلوب من القائمة المنسدلة الناتجة. ستظهر بعد ذلك لائحة بأسماء المجلدات والملفات الموجودة على ذلك القرص والتي يمكنك فتحها. وكما في حالة حفظ الملفات، إذا كنت في محرر البيانات فإن البرنامج سيظهر ملفات البيانات فقط التي يمكن فتحها، وإذا كنت في نافذة العارض فإنه سيتم عرض أسماء ملفات الخرج التي يمكن فتحها. إذا استخدمت مسار القوائم File ⇒ Open ⇒ Data... فإنه يتم عرض ملفات البيانات، أما إذا

استخدمت مسار القوائم ...File ⇒ Open ⇒ Output فإنه يتم إظهار ملفات العارض، وإذا استخدمت مسار القوائم ...File ⇒ Open ⇒ Syntax فإنه يتم عرض ملفات القواعد. يمكنك فتح المجلد بنقره أيقونته نقرة مزدوجة. بعد عثورك على الملف المطلوب يمكنك فتحه وذلك بتحديده ثم نقر الزر فتح Open أو نقر اسم الملف نقرة مزدوجة. إذا كنت في محرر البيانات وأردت فتح ملف نتائج من ملفات العارض فيمكنك نقر السهم في نهاية الحيز المسمى Files of type حيث تظهر لائحة بالتنسيقات البديلة للملفات. انقر نوع الملف المناسب حيث يتم عرض الملفات من النوع المحدد.

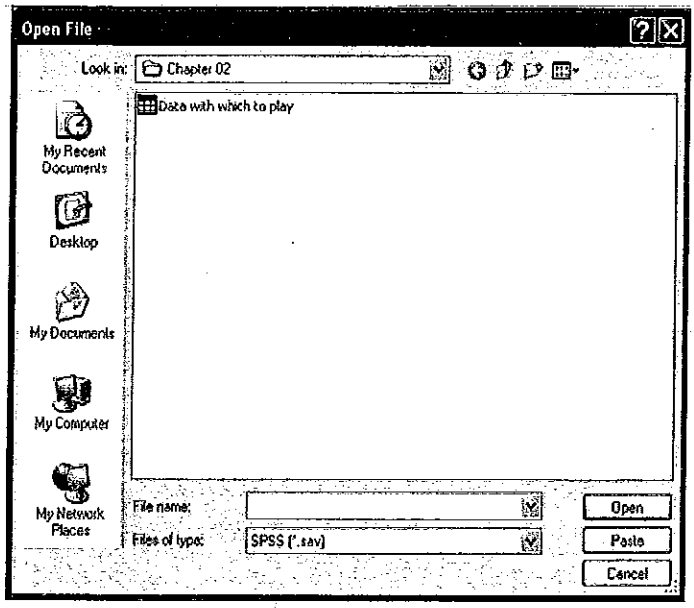

الشكل 12.2 مربع الحوار فتح ملف Open File

9.2 ما الذي اكتشفناه عن الإحصاء

قدم هذا الفصل مدخلاً أساسياً لبيئة البرنامج SPSS. لقد رأينا أن البرنامج يستخدم نافذتين رئيسيتين: محرر البيانات والعارض. لمحرر البيانات صفحتي عرض هما صفحة عرض البيانات (حيث يتم إدخال صفوف العلامات) وصفحة عرض المتحولات (حيث تقوم بتعريف المتحولات وخصائصها). أما العارض فهو عبارة عن نافذة يتم فيها عرض النتائج كالجداول والإحصائيات والمخططات البيانية. لقد قمنا أيضاً بإنشاء مجموعتنا الأولى من البيانات وذلك بإنشاء بعض المتحولات وإدخال بعض البيانات. وبذلك اكتشفنا أنه يمكن ترميز مجموعات من الأشخاص باستخدام الأرقام (متحولات الترميز) واكتشفنا أن الصفوف في محرر البيانات تمثل الأشخاص (أو حالات من البيانات) بينما الأعمدة تمثل المتحولات المختلفة. وأخيراً ألقينا نظرة على نافذة القواعد وتحدثنا عن حفظ الملفات وفتحها.

10.2 المصطلحات الأساسية التي اكتشفناها

محرر البيانات	(Data editor)
صفحة عرض البيانات	(Data view)
بيانات المجال	(Interval data)
البيانات الاسمية	(Nominal data)
المتحولات الرقمية	(Numeric variables)
البيانات التراتبية	(Ordinal data)
بيانات النسبة	(Ratio data)
المتحولات النصية	(String variables)
محرر القواعد	(Syntax editor)
صفحة عرض المتحولات	(Variable view)
العارض	(Viewer)

11.2 مهمة ينبغي إنجازها

تقضي مهمة هذا الفصل بحفظ البيانات التي قمت بإدخالها، في مكان ما على القرص الصلب على حاسبك الشخصي (أو على قرص مرن إن كنت لا تعمل على حاسبك الشخصي). أعط اسماً حساساً للملف وأحفظه في موقع يمكنك تذكره بسهولة (ربما تنشئ مجلداً باسم My Data Files في المجلد My Documents).

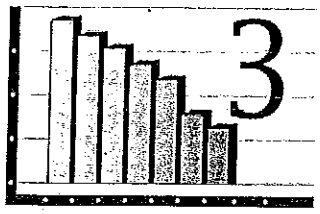

استكشاف البيانات

1.3 بماذا يخبرنا هذا الفصل

كما يوضح العنوان فإن هذا الفصل سيعلّمك الخطوات الأولى في تحليل البيانات: استكشاف البيانات. يستخدم Wright (2003) مقولة تفيد بأن على الباحثين أن ينشئوا علاقة صداقة مع بياناتهم. هذا لا يعني أن الباحثين في مجال الإحصاء يصادقون بياناتهم لأنها الصديق الوحيد الذي يملكونه، وإنما يحذر من أن كثيراً من الباحثين يهاجمون عمليات التحليل الخاصة بهم، مما يعطي نتائج غير مرتبة وغير منسجمة. يتناول هذا الفصل بعض الطرق التي تسمح باستكشاف البيانات. وتبدأ بالتعرف على كيفية فحص البيانات وتدقيقها، والتحقق من بعض الفرضيات حول البيانات، ثم نتعرف على بعض الإحصائيات الوصفية ورسم المخططات البيانية.

2.3 البيانات البارامترية

1.2.3 فرضيات البيانات البارامترية

إن عدداً من الإجرائيات الإحصائية الموصوفة في هذا الكتاب هي اختبارات بارامترية (parametric tests) تعتمد على التوزيع الطبيعي (الذي تم شرحه في الفقرة 5.1). والاختبار البارامتري هو الاختبار الذي يتطلب بيانات من أحد التوزيعات العديدة التي قام الإحصائيون بوصفها، ولكي تكون البيانات بارامترية هناك مجموعة من الفرضيات التي يجب تحقيقها. إذا كنت تستخدم اختباراً بارامترياً مع بيانات غير بارامترية فإن النتائج ستكون على الأرجح غير دقيقة. لذلك من المهم جداً التحقق من الفرضيات قبل الإقرار بأن اختباراً إحصائياً معيناً مناسب للتحليل. وعبر هذا الكتاب، ستدرك أسباب اهتمامنا المفرط بالفرضيات والتحقق منها. ولكي تكون الاختبارات الإحصائية المعتمدة على التوزيع الطبيعي دقيقة فإن هناك أربعة فرضيات يجب أن يحققها الاختبار. يظن العديد من الطلاب أن التحقق من الفرضيات عمل ممل، وغالباً ما يرتبكون بكيفية الإقرار بتحقق فرضية ما. لذلك يقدم هذا الفصل جولة تدريجية في عالم الفرضيات البارامترية. وفيما يلي فرضيات الاختبارات البارامترية:

1. **البيانات موزعة طبيعياً (Normally distributed data):** يُفترض أن تكون البيانات قادمة من واحد أو أكثر من المجتمعات الموزعة طبيعياً. والسبب الأساسي خلف اختبار الفرضية يستند إلى وجود مجتمعات موزعة طبيعياً، ولذلك إذا كان هذا الافتراض غير محقق فإن المنطق خلف اختبار الفرضية يكون خاطئاً (مررنا بهذه المبادئ في الفصل 1 وسيتم شرحها مرة أخرى في الفصل 6). ويحدّق معظم الباحثين ببيانات العينة لديهم (باستخدام المخطط التكراري) فإذا بدت بيانات العينة طبيعية ولو بشكل خشن فإنهم يفترضون أن المجتمع طبيعي أيضاً. سنوضح في هذا الفصل كيف يمكنك الانتقال خطوة أخرى إلى الأمام وذلك باختبار فيما إذا كانت بيانات العينة مختلفة بشكل ملحوظ عن التوزيع الطبيعي.

2. **تجانس التباين (Homogeneity of variance):** ويعني هذا الافتراض أن التباينات يجب أن تكون ذاتها عبر البيانات. في الحالات التي يتم فيها اختبار عدة مجموعات من المشتركين فإن هذا الافتراض يعني أن كل واحدة من العينات تأتي من مجتمع له نفس تباين المجتمعات الأخرى. أما في الحالات الترابطية فإن هذا الافتراض يعني أن التباين لمتحول ما يجب أن يكون مستقراً عند جميع المستويات لمتحول آخر (انظر الفقرة 6.3).

3. **بيانات المجال (Interval data):** يجب أن يتم قياس البيانات عند مستوى المجال على الأقل (انظر المربع 1.2 في الفصل 2). وهذا يعني أن المسافة بين نقطتين على سلم القياس يجب أن تكون ذاتها على طول سلم القياس. فعلى سبيل المثال، إذا كان لديك مقياس للقلق مكون من 10 نقاط، فإن الاختلاف في القلق الممثل بتغير العلامة من 2 إلى 3 يجب أن يكون مساوياً للاختلاف الممثل بتغير العلامة من 9 إلى 10.

4. **الاستقلال (Independence):** يقضي هذا الافتراض بأن البيانات القادمة من مشتركين مختلفين هي مستقلة، أي أن سلوك مشترك معين لا يؤثر على سلوك آخر. في حالة القياسات المتكررة (حيث يقاس المشتركون في حالات تجريبية متعددة)، ومن أجل مشترك معين فإننا نتوقع أن تكون النتائج في الحالات التجريبية المختلفة غير مستقلة، لكن السلوك بين المشتركين المختلفين يجب أن يكون مستقلاً. لنأخذ شخصين على سبيل المثال، مشتركان في تجربة ما حيث يجب عليهما الإشارة فيما إذا كانا يتذكران صوراً معينة سبق لهما مشاهدتها. إذا كان عليهما التشاور لإعطاء جواب حول مشاهدتهما لصورة معينة فإن إجاباتهما لن تكون مستقلة، لأن إجابة أحدهما على سؤال معين ستعتمد على إجابة الشخص الآخر، وهذا يناقض فرضية الاستقلال. أما إذا لم يكن بإمكانهما التشاور (كأن يكونا في غرفتين منفصلتين) فإن إجاباتهما ستكون مستقلة (ما لم يستخدما التخاطر!)، أي أن إجابات أحدهما لم تتأثر بإجابات الشخص الآخر.

لسوء الحظ، فإن اختبار فرضيتي بيانات المجال والقياسات المستقلة يتم بالحس السليم فقط. أما فرضية تجانس التباين فيتم اختبارها بطرق مختلفة وفق الإجرائيات المختلفة، ولذلك سنناقش هذه الفرضية في فقرة مستقلة (الفقرة 6.3) كما سنناقش هذه الاختبارات كلما دعت الحاجة. وهكذا

تبقى لدينا فرضية التوزيع الطبيعي للبيانات لكي نتحقق منها، وهذه الفرضية الأكثر أهمية بين الفرضيات الأربع. إن أسهل طريقة للتحقق من هذه الفرضية هي النظر إلى توزيع البيانات للعينة. إذا كانت بيانات العينة موزعة طبيعياً فإن نميل لافتراض بأنها تأتي من مجتمع موزع طبيعياً. وبشكل مشابه إذا لم تكن بيانات العينة موزعة طبيعياً فإننا نفترض أنها قادمة من مجتمع غير طبيعي. لذلك، وبهدف اختبار هذه الفرضية فإنه يمكننا البدء برسم عدد مرات حدوث كل قيمة من قيم البيانات (توزيع تكراري) ثم النظر إليه والتساؤل هل يبدو طبيعياً.

3.3 رسم المخططات وتدقيق البيانات

سنلقي نظرة الآن على كيفية استخدام التوزيعات التكرارية والأنواع الأخرى من المخططات البيانية والإحصائيات الوصفية بهدف تدقيق البيانات. وسنستخدم مثالاً لتوضيح ما نقوم بعمله. كان أحد علماء الأحياء قلقاً حول الآثار الصحية المحتملة للمهرجانات الموسيقية. لذلك قام في أحدى السنوات بحضور مهرجان Glastonbury الموسيقي، وقام بقياس نظافة 810 من الأشخاص الذين يحضرون الحفلات خلال الأيام الثلاثة للمهرجان. بشكل نظري، تمت عملية القياس لكل شخص من الحضور في كل يوم من الأيام الثلاثة. ولكن بسبب صعوبة تعقب الأشخاص، كانت هناك بعض القيم المفقودة في اليومين الثاني والثالث. تم قياس النظافة باعتماد تقنية قياسية وكانت العلامات متدرجة بين 0 (رائحة نتنة) و 5 (رائحة عطرة كزهرة في يوم ربيعي جميل). ولأننا نعلم أن الحفاظ على الصحة العامة في مثل هذه الأماكن شبه مفقود فإن هذا الباحث قد توقع أن النظافة الشخصية ستتدهور بشكل كبير خلال الأيام الثلاثة للمهرجان. يمكنك الحصول على ملف البيانات الخاص بهذا المثال من القرص المضغوط المرفق تحت اسم GlastonburyFestival.sav (انظر الفقرة 8.2 لتتذكر كيفية فتح ملف البيانات).

1.3.3 الخطوة 1: اكتشاف الأخطاء البديهية باستخدام المخططات التكرارية

إن أول شيء سنقوم به هو رسم مخطط تكراري لمعرفة توزيع البيانات. يملك برنامج SPSS مجموعة أدوات لرسم أنواع مختلفة من المخططات البيانية. إذا نقرت أمر القائمة Graphs فإن القائمة المنسدلة تعرض الأنواع المختلفة للمخططات البيانية المتوفرة. ربما تعاملت سابقاً مع بعض أنواع المخططات المعروضة (كالمخططات الدائرية، ومخططات الأعمدة، وغيرها):

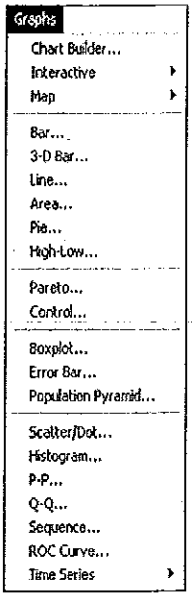

- **مخطط الأعمدة Bar:** ويستخدم عادة لرسم القيم المتوسطة لمجموعات مختلفة من الناس (تلخيص مجموعات من الحالات)، أو القيم المتوسطة لمتحولات مختلفة (تلخيص لمتحولات منفصلة).
- **المخطط الخطي Line:** يستخدم أيضاً لرسم القيم المتوسطة.
- **المخطط الدائري Pie:** يستخدم لرسم التكرارات والنسب المئوية.
- **رسم الصندوق Boxplot:** رسم تخطيطي يعتمد الصندوق لإظهار الوسط ومجال انتشار العلامات والمجال بين الربعيّين الحديين (interquartile range) (مقياس لانتشار مجموعة من القيم ويساوي الفرق بين الحد الأعلى للربعيّ السفلي والحد الأدنى للربعيّ العلوي).
- **مخطط أعمدة الخطأ Error Bar:** يبين المتوسط ومجال الثقة عند 95% لقيمة المتوسط (انظر الفصل 7).
- **المخطط المبعثر Scatter:** يظهر العلاقات بين متحولين (انظر الفصل 5).
- **المخطط التكراري Histogram:** يظهر التكرار لعلامات مختلفة (يفيد في التحقق من توزيع العلامات).

تلاحظ أن القائمة تحوي أيضاً خيار المخططات التفاعلية (Interactive)، وعند نقره تظهر قائمة فرعية تحوي بعض أنواع المخططات الموجودة في القائمة الأصلية. والمخططات التفاعلية هي عملياً مخططات أكثر جمالاً ويفترض أن تتغير بشكل تفاعلي عند أي تغير للبيانات (ومن هنا جاء الاسم). لذلك إذا أردنا رسم مخطط تكراري فإنه يمكننا اختيار Graphs ⇒ Interactive ⇒ Histogram لفتح مربع الحوار المبين في (الشكل 1.3).

لاحظ أن المتحولات في محرر البيانات موجودة في القسم الأيسر من مربع الحوار، ويمكنك سحب أيّ منها إلى حيزات النص الخالية. يتم تمثل المحورين بأسهم، لذلك تستطيع سحب المتحول الذي تريده إلى الحيز المرغوب. يحوي المحور الشاقولي متحولاً يدعى Count بشكل مسبق. بما أننا نريد رسم التكرار لكل قيمة من العلامات فإن SPSS سيحصي عدد مرات حدوث هذه القيمة. وكبداية، سنقوم برسم المخطط التكراري لبيانات النظافة في اليوم الأول من أيام المهرجان. اختر هذا المتحول من اللائحة واسحبه إلى الحيز الخاص بالمحور الأفقي. يجب أن يكون الشكل النهائي لمربع الحوار كما في (الشكل 1.3). ربما لاحظت وجود حيز يدعى Panel Variables، وإذا قمت بسحب متحول ما إلى ذلك الحيز فإن برنامج SPSS سيقوم بإنشاء مخطط تكراري لكل مستوى من مستويات ذلك المتحول. لذلك إذا كان لدينا متحول ترميز للجنس على سبيل المثال، ووضعناه في هذا الحيز فإننا سنحصل على مخططين تكراريين، أحدهما للذكور والآخر للإناث. إن الخيارات الافتراضية مناسبة جداً لذلك يمكنك نقر الزر OK (إذا أردت رسم مخطط التوزيع الطبيعي فوق المخطط التكراري فيمكنك نقر صفحة التبويب Histogram وتحديد الخيار Normal curve).

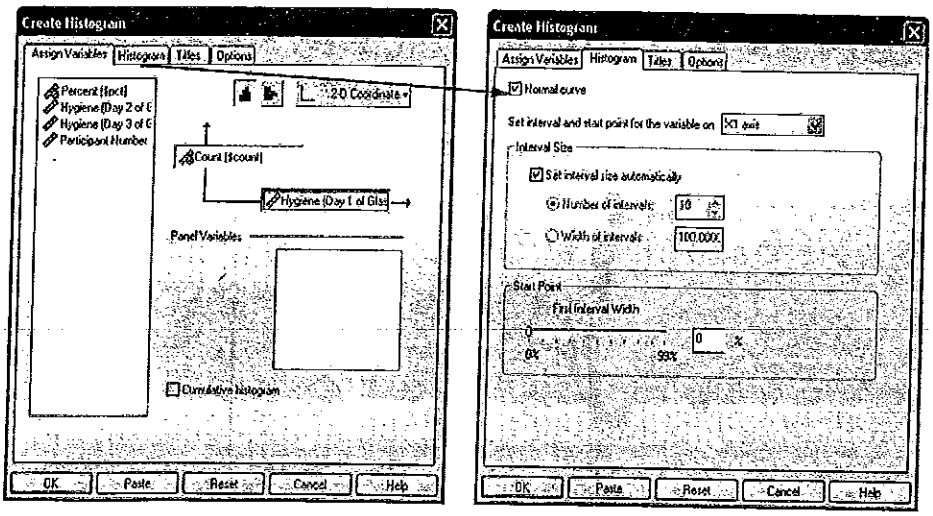

الشكل 1.3 مربع الحوار لرسم مخطط تكراري تفاعلي (يؤدي نقر صفحات التبويب في القسم العلوي لتغيير محتوى مربع الحوار)

يبين (الشكل 2.3) المخطط التكراري الناتج، وأول ما يلفت النظر في المخطط وجود حالة مختلفة جداً عن البقية. وتبدو جميع العلامات محشورة في أحد طرفي التوزيع لأنها أقل من القيمة 5 (مما يعطي توزيعاً مدبباً (leptokurtic)) باستثناء علامة واحدة تبلغ قيمتها 20. وهذه القيمة منعزلة (outlier) أي أنها مختلفة جداً عن بقية القيم. تؤثر القيم المنعزلة على قيمة المتوسط وتزيد الانحراف المعياري بشكل مفرط، ولذلك يعتبر تدقيق البيانات طريقة هامة لاكتشاف مثل تلك القيم. الغريب في هذه القيمة المنعزلة أن قيمتها 20، وهي أعلى بكثير من الحد الأعلى لسلم القياس (تذكر أن مقياس النظافة كان مدرجاً من 0 إلى 5 فقط!)، ولذلك لا بد أن تكون هذه القيمة غير صحيحة. على كل حال، إن البحث عن هذه الحالة بين 810 حالات سيكون مضنياً ومتعباً جداً لذلك نلجأ لاستخدام مخطط رسم الصندوق (boxplot).

سنتحدث بشكل أكبر عن مخطط رسم الصندوق لاحقاً في هذا الفصل، لذلك سنكتفي الآن باختيار Graphs ⇒ Boxplot لفتح مربع الحوار. نحدد الخيار تلخيص المتحولات المنفصلة Summaries of separate variables وننقر الزر Define. يؤدي ذلك لفتح مربع حوار آخر يحوي قسمه الأيسر لائحة بجميع المتحولات في محرر البيانات، أما في القسم الأيمن فيحوي مربعاً يسمى "الصناديق تمثل" Boxes Represent. حدد المتحولات الثلاثة (التي تمثل علامات النظافة خلال أيام المهرجان الثلاثة) من القسم الأيسر وانقلها إلى القسم الأيمن بنقر الزر الموجود بين القسمين. انقر الزر Options... لضبط خيارات المخطط، ثم انقر الخيار Exclude cases variable by variable لاستثناء الحالات حسب المتحول. لقد حددنا هذا الخيار لأن بعض المتحولات تملك قيماً مفقودة، وإذا نقرنا الخيار Exclude cases listwise فإنه عند وجود قيماً مفقودة لحالة معينة ولأيّ من المتحولات الثلاثة فإن البيانات لتلك الحالة لن تستخدم على الإطلاق. وبما أننا لا نريد هذا الخيار، وإنما نريد استثناء

الحالات للمتحول الذي يحوي القيم المفقودة فإن الخيار Exclude cases variable by variable هو المناسب. يبين (الشكل 3.3) الحالة النهائية لمربعات الحوار. انقر الزر OK لرسم المخطط.

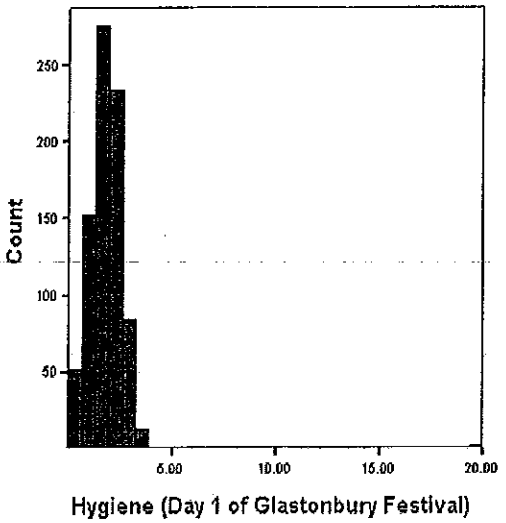

الشكل 2.3 المخطط التكراري لعلامات النظافة في اليوم الأول من مهرجان Glastobury

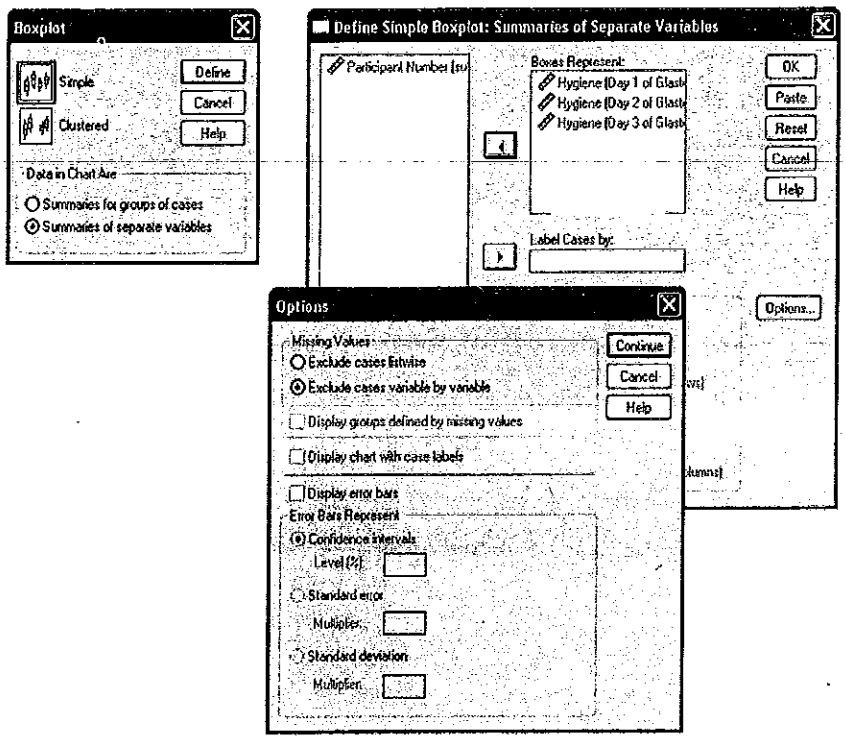

الشكل 3.3 مربعات الحوار لتعريف رسم الصندوق من أجل عدة متحولات

يبين (الشكل 4.3) مخطط رسوم الصندوق الناتجة. إن أهم ما يجب ملاحظته هو أن القيمة المنعزلة التي تم اكتشافها في المخطط التكراري قد ظهرت بشكل نجمة في رسم الصندوق وبجانبها رقم ما. يرتبط هذا الرقم بالحالة من البيانات التي أعطت القيمة المنعزلة، وهي الحالة 611. إذا انتقلنا إلى محرر البيانات، وصفحة عرض البيانات بالتحديد فإننا نستطيع تحديد هذه الحالة بنقر أيقونة الانتقال إلى حالة معينة Goto Case وكتابة الرقم 611 في مربع الحوار الناتج. عند الانتقال إلى الحالة 611 فإننا نكتشف القيمة 20.02 التي ربما نتجت عن خطأ في الكتابة للقيمة 2.02. في هذه الحالة، يجب علينا العودة إلى صف البيانات والتحقق من القيمة. سنفترض أننا عدنا البيانات وتحققنا من القيمة ووجدنا أنها 2.02، لذلك نقوم بتصحيح القيمة 20.02 في محرر البيانات لتصبح 2.02 قبل الاستمرار في هذا المثال.

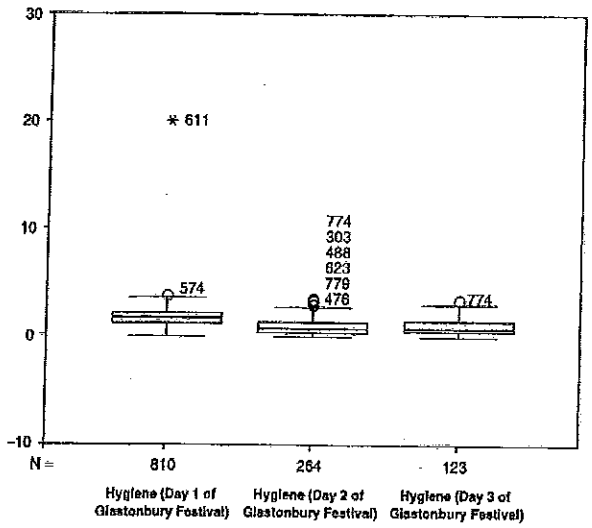

الشكل 4.3 رسوم الصندوق لعلامات النظافة عبر الأيام الثلاثة لمهرجان Glastobury

بعد إزالة الخطأ، سنعيد رسم المخطط التكراري. وبنفس الوقت سنرسم المخططات التكرارية لعلامات النظافة في اليومين الثاني والثالث. يبين (الشكل 5.3) المخططات التكرارية للأيام الثلاثة. إن ما يلفت النظر هو أن بيانات اليوم الأول تبدو أكثر صحة بعد أن تمت إزالة النقطة التي كانت مكتوبة بشكل خاطئ. ويبدو التوزيع طبيعياً، فهو متناظر بشكل جيد، ولا يبدو مدبباً أو مسطحاً بشكل كبير، وكلها أمور جيدة. ولكن التوزيعات الخاصة باليومين الثاني والثالث ليست متناظرة لحد ما. فهي تبدو إيجابية الميلان (positively skewed). بشكل عام، إن ما تظهره هذه التوزيعات هو أن علامات النظافة لليومين الثاني والثالث متجمعة حول الحد الأدنى للمقياس. تذكر أنه كلما كانت القيمة أصغر كانت نظافة الشخص أقل، لذلك يمكن تفسير التوزيع بأن نظافة الأشخاص تتدهور مع تقدم أيام المهرجان. ويحدث الميلان (عدم التناظر) لأن فئة قليلة من الجمهور تصر على

المحافظة على مستوى نظافتها (رغم تضافر كل العوامل ضدها) خلال فترة المهرجان. على كل حال، إن هذا النوع من التوزيعات يسبب مشكلة عند استخدام الاختبارات البارامترية. سنبحث في الفقرة التالية عن كيفية إعطاء تقييم كمي لعدم التناظر والتدبب لهذه التوزيعات.

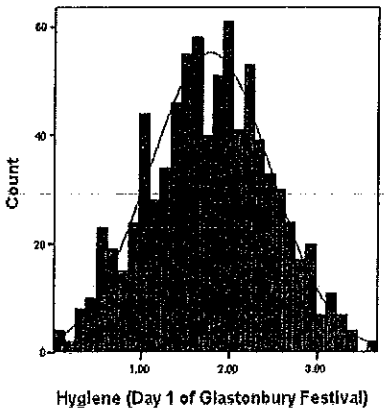

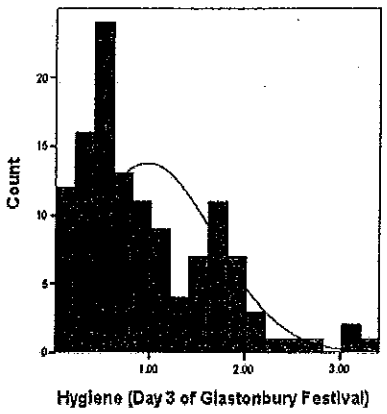

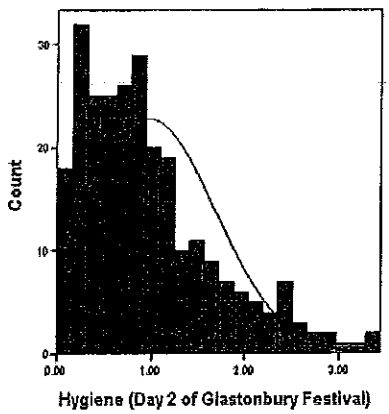

الشكل 5.3 المخططات التكرارية لعلامات النظافة خلال الأيام الثلاثة للمهرجان

2.3.3 الخطوة 2: الإحصائيات الوصفية ورسم الصندوق

بعد أن ألقينا نظرة على التوزيعات لعلامات النظافة واكتشفنا القيم المدخلة بشكل خاطئ وصححنا تلك القيم، يمكننا الانتقال للبحث في طرق التقييم الكمي لشكل التوزيعات والبحث عن القيم المنعزلة. لاستكشاف توزيع المتحولات مستقبلاً فإنه يمكننا استخدام الأمر frequencies الذي يمكن الوصول إليه عبر الأوامر Analyze ⇒ Descriptive Statistics ⇒ Frequencies... حيث نحصل على مربع الحوار الرئيسي المبين في (الشكل 6.3). تظهر متحولات محرر البيانات في القسم الأيسر من مربع الحوار، ويمكن نقلها إلى الحيز الموجود في القسم الأيمن والمسمى Variable(s) وذلك بتحديد متحول (أو مجموعة متحولات) ثم نقر الزر الموجود بين القسمين. تتم عمليات التحليل التي

تختارها على كل متحول موجود في اللائحة Variable(s). إذا تم تحديد متحول ما في اللائحة Variable(s) باستخدام الفأرة، فمن الممكن إعادته إلى القسم الأيسر بنقر الزر الموجود بين القسمين (والذي يشير باتجاه يعاكس الاتجاه السابق). بشكل افتراضي يقوم برنامج SPSS بإنتاج توزيع تكراري لجميع العلامات في الجدول. هناك مربعا حوار يمكن اختيارهما لضبط مزيد من الخيارات. يمكن الوصول لمربع الحوار الأول إحصائيات Statistics بنقر الزر ...Statistic، أما مربع الحوار الآخر Charts فيمكن الوصول إليه بنقر الزر ...Charts.

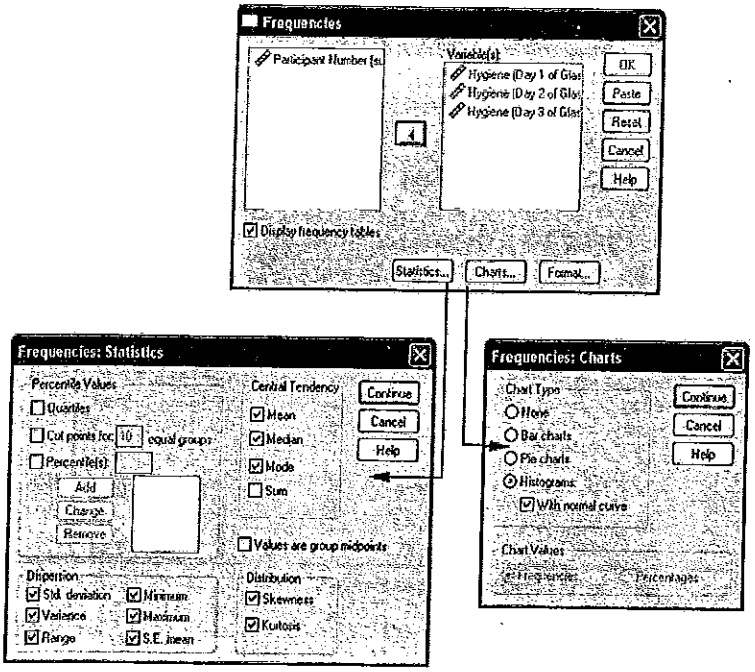

الشكل 6.3 مربعات الحوار الخاصة بالتعليمة frequencies

يسمح مربع الحوار Statistics بتحديد مجموعة من الخيارات للطرق التي يمكن بها وصف توزيع العلامات، كالقياسات المتعلقة بالتوجه المركزي (المتوسط، المنوال، الوسط)، والقياسات المتعلقة بالتغايرية (المجال، الانحراف المعياري، التباين، فواصل الأرباع)، والقياسات المتعلقة بالشكل (التدبب وعدم التناظر). لوصف المميزات الخاصة بالبيانات ينبغي علينا اختيار: المتوسط، المنوال، الوسط، الانحراف المعياري، التباين، والمجال. وللتحقق من أن توزيع العلامات طبيعي، يجب علينا النظر إلى قيم التدبب وعدم التناظر. أما خيارات مربع الحوار Charts فتوفر طريقة سهلة لرسم التوزيعات التكرارية للعلامات (كمخطط الأعمدة أو المخطط الدائري أو المخطط التكراري). لقد رسمنا سابقاً المخططات التكرارية للبيانات، لذلك لسنا بحاجة لتحديد هذه الخيارات، ولكن يمكنك استخدام هذه الخيارات في عمليات التحليل القادمة. عند الانتهاء من تحديد الخيارات المناسبة، تتم

العودة إلى حيز الحوار الرئيسي Frequencies بنقر الزر Continue. وعند النقر على الزر OK في مربع الحوار الرئيسي تبدأ عملية التحليل.

يعرض الخرج 1.3 لبرنامج SPSS جدول الإحصائيات الوصفية للمتحولات الثلاثة في هذا المثال. من هذا الجدول يمكننا أن نرى أن معدل النظافة كان 1.77 (من 5) في اليوم الأول، ولكنه انخفض إلى 0.96 في اليوم الثاني، وإلى 0.98 في اليوم الثالث.

Statistics

		Hygiene (Day 1 of Glastonbury Festival)	Hygiene (Day 2 of Glastonbury Festival)	Hygiene (Day 3 of Glastonbury Festival)
N	Valid	810	264	123
	Missing	0	546	687
Mean		1.7711	.9609	.9765
Std. Error of Mean		.02437	.04436	.06404
Median		1.7900	.7900	.7600
Mode		2.00	.23	.44[a]
Std. Deviation		.69354	.72078	.71028
Variance		.48100	.51952	.50449
Skewness		-.004	1.095	1.033
Std. Error of Skewness		.086	.150	.218
Kurtosis		-.410	.822	.732
Std. Error of Kurtosis		.172	.299	.433
Range		3.67	3.44	3.39
Minimum		.02	.00	.02
Maximum		3.69	3.44	3.41

a. Multiple modes exist. The smallest value is shown

الخرج 1.3

أما القياسات الهامة الأخرى فهي عدم التناظر والتدبب، وهي قيم مرتبطة بالخطأ المعياري. في التوزيع الطبيعي، تكون قيم التدبب وعدم التناظر مساوية للصفر. تدل القيم الموجبة لعدم التناظر على تراكم العلامات في القسم الأيسر من التوزيع، بينما تدل القيم السالبة على تراكمها في القسم الأيمن منه. تشير القيم الموجبة للتدبب إلى توزيع مدبب بينما تشير القيم السالبة إلى توزيع مسطّح. وكلما ابتعدت القيمة عن الصفر زاد احتمال أن لا تكون البيانات موزعة طبيعياً. على كل حال، إن القيم الفعلية للتدبب وعدم التناظر ليست بحد ذاتها غنية بالمعلومات. لذلك نأخذ القيم ونحولها إلى علامات معيارية (علامات z). لقد رأينا في الفقرة 3.5.1 أن العلامات المعيارية هي علامات أو نقاط من توزيع طبيعي قيمته المتوسطة 0 وانحرافه المعياري 1. إن السبب الداعي لتحويل النقاط إلى علامات z هي أنها طريقة لجعلها معيارية. لذلك يمكننا أخذ متحول مقاس بوحدات معينة وتحويله إلى علامات z. وعندها يمكننا مقارنة العلامات حتى لو كانت مقاسة في الأصل بوحدات مختلفة. تتم عملية التحويل إلى علامات z بطرح قيمة المتوسط للتوزيع وتقسيم الناتج على الانحراف

المعياري للتوزيع. وهكذا يتم تحويل عدم التناظر والتدبب إلى علامات z باستخدام العلاقات التالية:

$$z_{skewness} = \frac{S - 0}{SE_{skewness}}$$

$$z_{kurtosis} = \frac{K - 0}{SE_{kurtosis}}$$

في المعادلات السابقة، تدل S (Skewness) و(Kurtosis) K على عدم التناظر والتدبب، ويقوم برنامج SPSS بحساب هذه القيم مع أخطائها المعيارية SE. يمكن مقارنة علامات z مع القيم التي تتوقع الحصول عليها بطريق الصدفة فقط (القيم المعروفة للتوزيع الطبيعي مبينة في الملحق). لذلك فإن القيمة المطلقة التي تكون أكبر من 1.96 ذات دلالة عند احتمال p<0.05، والقيمة الأكبر من 2.58 ذات دلالة عند احتمال p<0.01، أما القيم المطلقة التي تكون أكبر من 3.29 فهي ذات دلالة عند احتمال p<0.001. تسبب العينات الكبيرة أخطاءً معيارية صغيرة، ولذلك عندما تكون أحجام العينة كبيرة فإن القيم المهمة تظهر حتى من أجل الانحرافات الصغيرة بعيداً عن التوزيع الطبيعي. في معظم العينات، يكون البحث عن قيم أكبر من 1.96 مقبولاً، ولكن في العينات الصغيرة يجب زيادة هذا المعيار للمستوى 2.58 أما في العينات الكبيرة جداً، وبسبب مشكلة الأخطاء المعيارية الصغيرة التي تحدثنا عنها، فلا يجب تطبيق أي معيار. إذا كانت لديك عينة كبيرة (200 حالة أو أكثر) فمن المهم جداً النظر إلى شكل التوزيع والنظر إلى قيم عدم التناظر والتدبب بدلاً من حساب دلالتها.

بالنسبة لعلامات النظافة، فإن قيمة العلامة المعيارية لعدم التناظر هي 0.047- / 0.086 = 0.004- في اليوم الأول، و7.300 = 0.150 / 1.095 في اليوم الثاني، و4.739 = 0.218 / 1.033 في اليوم الثالث. من الواضح عدم وجود ميلان في اليوم الأول، ولكن في اليومين الثاني والثالث هناك ميلان إيجابي واضح تماماً تظهره العلامة المعيارية > 1.96 (كما كان ذلك بديهياً من المخطط التكراري). على كل حال، تذكر دائماً ما قلناه عن العينات كبيرة الحجم. أما العلامات المعياري للتدبب فهي: 2.38- = 0.172 / 0.410- في اليوم الأول، و2.75 = 0.299 / 0.822 في اليوم الثاني، و1.69 = 0.433 / 0.732 في اليوم الثالث. تدل هذه القيم على تدبب واضح (عند مستوى p<0.05) في الأيام الثلاثة، ولكن بسبب العينات الكبيرة، فإن ذلك لا يفاجئنا، ولهذا يمكننا الارتياح لحقيقة أن جميع هذه القيم هي أصغر من العتبة العليا 3.29.

أفكار مفيدة

- للتحقق من أن توزيع العلامات طبيعي، يجب علينا إلقاء نظرة على قيم عدم التناظر و التدبب في نافذة الخرج لبرنامج SPSS.
- تشير القيم الموجبة للتدبب إلى توزيع مدبب، بينما تدل القيم السالبة على توزيع مسطّح.
- كلما ابتعدت القيمة عن الصفر زاد احتمال أن لا تكون البيانات موزعة طبيعياً.

يوفر الخرج التوزيعات التكرارية مجدولة من أجل كل متحول من المتحولات. وتعرض هذه الجداول كل نقطة من العلامات وعدد مرات حدوثها ضمن مجموعة البيانات. إضافة إلى إظهار كل قيمة من قيم التكرار كنسبة مئوية من العينة. كما يعطي النسب المئوية التراكمية التي تدل على عدد الحالات (كنسبة مئوية) التي تقع أدنى من علامة معينة. فعلى سبيل المثال، يمكننا أن نرى أن 15.4% من علامات النظافة كانت أدنى من 1 في اليوم الأول للمهرجان، بينما وصلت في اليوم الثاني إلى 63.3%.

بعد التحقق من شكل التوزيع، ينبغي علينا النظر إلى القيم المنعزلة (انظر المربع 1.3). هناك طريقتان لتنفيذ ذلك، الأولى بالنظر إلى رسم الصندوق، والثانية بالنظر إلى العلامات المعيارية. سنترك التعامل مع العلامات المعيارية (للمربع 2.3)، وسنهتم هنا بالأشكال الجميلة لرسوم الصندوق. لقد قلنا سابقاً أن برنامج SPSS يستطيع إنجاز رسوم الصندوق كما في (الشكل 3.3)، وسنكرر هذه العملية لعلامات النظافة. يجب أن تكون رسوم الصندوق الناتجة مختلفة الآن (لأننا صححنا القيمة غير الصحيحة)، وهذا ما نراه في (الشكل 7.3).

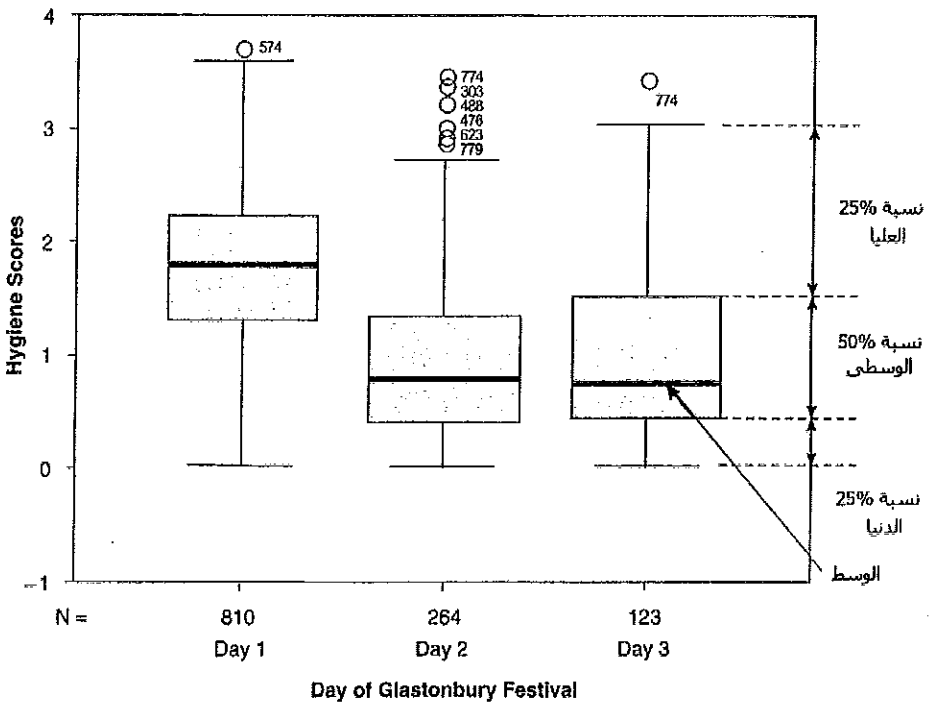

الشكل 7.3 رسوم الصندوق لعلامات النظافة خلال الأيام الثلاثة لمهرجان Glastonbury

المربع 1.3 القيم المنعزلة

القيمة المنعزلة (Outlier) هي نقطة من البيانات مختلفة جداً عن بقية البيانات. عند تحليل البيانات يجب أن نكون حذرين من مثل هذه القيم لأنها تؤثر على النموذج المستخدم لملاءمة البيانات. وكمثال جيد عن هذا التأثير يمكن أن نأخذ أحد النماذج الإحصائية البسيطة مثل المتوسط. قام Field & Hole (2003) بدراسة تقييم الزبائن للطبعة الأولى من كتابهم عبر موقع Amazon.co.uk. وقد قام 7 أشخاص بمراجعة الكتاب وتقييمه على مقياس تتراوح القيم فيه بين 1 و5 نجوم، وكانت علامات التقييم هي: 2 و5 و4 و5 و5 و5 و5. نلاحظ أن جميع هذه القيم متشابهة (4 و5) باستثناء القيمة الأولى (2) التي كانت مختلفة جداً عن البقية. على المحور الأفقي للمخطط نجد أرقام المراجعين، وعلى المحور الشاقولي نجد قيمة التقييم لكل منهم. هناك خط أفقي على المخطط يمثل قيمة المتوسط للعلامات السبع (وهي 4.43). نلاحظ أن جميع العلامات باستثناء قيمة واحدة تقع قريباً من ذلك الخط. إن العلامة 2 مختلفة جداً وتقع بعيداً عن خط قيمة المتوسط. تعتبر هذه القيمة مثالاً جيداً عن القيم المنعزلة. يمثل الخط الأفقي المتقطع قيمة المتوسط للعلامات بعد استثناء القيمة المنعزلة (والتي تصبح 4.83). إن هذا الخط أعلى من خط المتوسط الأساسي، مما يدل على أن إهمال القيمة المنعزلة قد زاد من قيمة المتوسط (بمقدار 0.4). يوضح هذا المثال كيف أن علامة واحدة يمكن أن تؤثر على قيمة المتوسط، في هذه الحالة قامت النقطة الأولى (2) بسحب المتوسط نحو الأسفل. ومن الناحية العملية، فإن لذلك أثراً أكبر لأن Amazon تقوم بتدوير العلامة لأقرب نصف نقطة، وبدلاً من التقييم 5 يمكن أن نحصل على تقييم أقل إثارة للإعجاب أي 4.5.

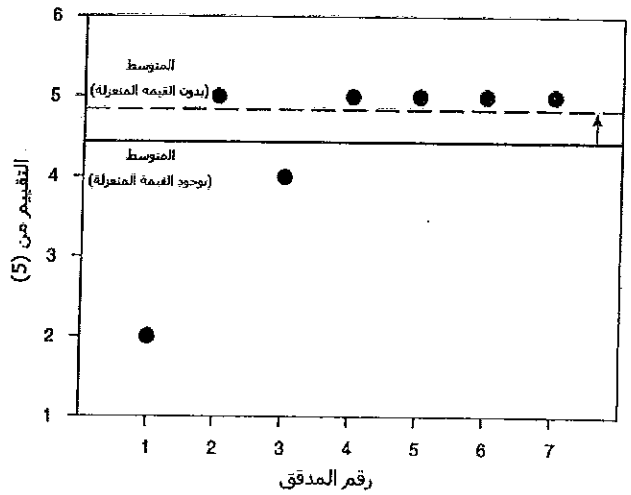

إن رسوم الصندوق في (الشكل 7.3) تخبرنا شيئاً ما عن التوزيعات لعلامات النظافة في الأيام الثلاثة لمهرجان Glastonbury. يبين رسم الصندوق العلامة الدنيا (الخط الأفقي السفلي) والعلامة العليا (الخط الأفقي العلوي). أما المسافة بين الخط الأفقي الأدنى والحافة الدنيا للصندوق الملون فتمثل المجال الذي تقع ضمنه نسبة 25% الدنيا من العلامات (وتدعى أيضاً الربعيّ السفلي (bottom quartile)). يبين الصندوق الملون نسبة 50% الوسطى من العلامات (وتدعى أيضاً المجال بين الربعين الحديين

(interquartile range)) وهي 50% من العلامات التي تكون أكبر من القسم الأدنى للمنطقة الملونة ولكنها أصغر من القسم العلوي للمنطقة الملونة. أما المسافة بين الحافة العليا للصندوق الملون والخط الأفقي العلوي فتظهر المجال الذي تقع ضمنه نسبة 25% العليا من العلامات (وتدعى أيضاً الربعيّ العلوي (top quartile)). في المنطقة الوسطى للصندوق الملون هناك خط أفقي سميك نسبياً يمثل قيمة الوسط (median)، فإذا قمت بترتيب علامات النظافة فإن هذه القيمة ستكون هي العلامة التي تقع في منتصف المجال. وكما رأينا فإن هذه المخططات تظهر لنا مجال العلامات، والمجال الذي تقع فيه 50% من العلامات الوسطى، وقيمة الوسط أيضاً. وهي تخبرنا كالمخططات التكرارية فيما إذا كان التوزيع متناظراً أو غير متناظر. في اليوم الأول، نلاحظ أن الخطوط الممتدة من جهتي الصندوق متساوية في الطول (أي أن الربعيّ السفلي والربعيّ العلوي متساويان) وهذا يعني أن التوزيع متناظر. أما في اليومين الثاني والثالث فإن الخطوط الممتدة من الجهة العلوية أطول من تلك الممتدة من الجهة السفلية مما يدل على أن التوزيع غير متناظر (فنسبة 25% العليا منتشرة على مجال أوسع من نسبة 25% الدنيا). أخيراً نلاحظ وجود بعض الدوائر فوق رسم الصندوق. إنها الحالات التي يمكن اعتبارها قيماً منعزلة. بجانب كل دائرة هناك رقم يدل على الصف الذي يحوي تلك القيمة في محرر البيانات. في الفقرة التالية سنرى ما يمكننا عمله مع هذه القيم المنعزلة.

المربع 2.3 استخدام العلامات z لإيجاد القيم المنعزلة

للبحث عن القيم المنعزلة يمكننا الاستعانة بالعلامات المعيارية (العلامات z)، وهي طريقة بسيطة لجعل مجموعة من البيانات معيارية. ونعني بذلك كتابة العلامات بدلالة توزيع ذي متوسط وانحراف معياري معروفين. وبشكل خاص، فإننا نستخدم توزيعاً بمتوسط يساوي 0 وانحراف معياري يساوي 1 (انظر الفقرة 5.1). والفائدة من ذلك إنشاء نقاط قياسية يمكن تطبيقها على أية مجموعة من البيانات (بغض النظر عن قيمة المتوسط والانحراف المعياري الأصلية). ولتحويل مجموعة البيانات إلى علامات z نأخذ كل قيمة من البيانات (X) ونطرح منها قيمة المتوسط لجميع النقاط ($\bar{X}$) ثم نقسم الناتج على الانحراف المعياري لكل العلامات:

$$z = \frac{X - \bar{X}}{s}$$

وبدلاً من تنفيذ عملية التحويل لجميع النقاط يدوياً، يمكنك استخدام مربع الحوار Descriptives في برنامج SPSS الذي يمكنك الوصول إليه باستخدام الأمر Analyze ⇒ Descriptive Statistics ⇒ Descriptives... اختر متحولاً (كبيانات النظافة لليوم الثاني من المهرجان)، أو عدة متحولات، ثم حدد الخيار Save standardized values as variables لحفظ القيم المعيارية كمتحولات، ثم انقر الزر OK. يقوم برنامج SPSS بإنشاء متحول جديد في محرر البيانات (بنفس اسم المتحول مع بادئة z). يمكننا بعد ذلك استخدام هذه القيم وإحصاء عدد القيم الواقعة ضمن الحدود الهامة. إذا أخذنا القيمة المطلقة للعلامات المعيارية (أي أننا أهملنا إشارة العلامات z) فإننا نتوقع أن يكون لدينا في توزيع طبيعي 5% من القيم أكبر من 1.96 (وغالباً نستخدم القيمة 2)، و 1% من القيم أكبر من 2.58، وعدم وجود أية قيم أكبر من 3.29.

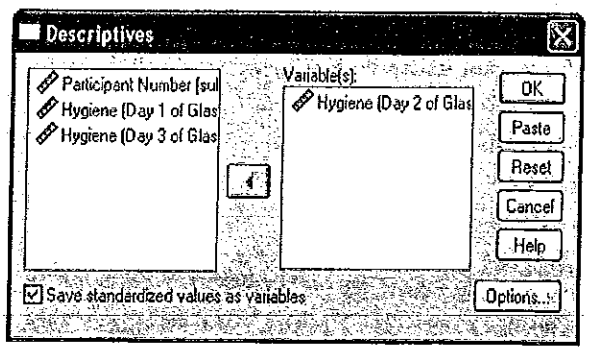

يمكننا أيضاً استخدام القواعد في نافذة القواعد لبرنامج SPSS لإنشاء العلامات z وعدّها. يحوي القرص المضغوط المرفق ملف قواعد باسم Outliers (Percentage of Z-scores).sps، تمت كتابته لإنتاج جدول لبيانات النظافة الخاصة باليوم الثاني من المهرجان. يمكنك تحميل هذا الملف وتشغيل القواعد فيه، أو فتح نافذة القواعد (انظر الفقرة 6.2) وكتابة التعليمات التالية (ولا تنس النقطة في نهاية كل سطر). إن الجمل المحصورة بين نجمتين هي تعليقات، لذلك لست مضطراً لكتابتها في نافذة القواعد:

```
DESCRIPTIVES
VARIABLES=day2/SAVE.
```

يتم تطبيق التابع Descriptives لبرنامج SPSS على المتحول day2 (بدلاً من استخدام مربع الحوار) لحفظ العلامات z في محرر البيانات (حيث يتم حفظها كمتحول يسمى zday2).

```
COMPUTE outlier1=abs(zday2).
EXECUTE.
```

يتم إنشاء متحول جديد في محرر البيانات باسم outlier1، يحوي القيم المطلقة لعلامات z التي تم إنشاؤها.

```
RECODE
outlier1 (3.29 thru Highest = 4) (2.58 thru Highest=3) (1.96 thru Highest=2) (Lowest thru 2=1).
EXECUTE.
```

تتم إعادة ترميز المتحول outlier1 وفقاً للنقاط القياسية التي وصفناها سابقاً. لذلك إذا كانت القيمة أكبر من 3.29 فيتم إعطاؤها الرمز 4، وإذا كانت واقعة بين 2.58 و 3.29 فيتم إعطاؤها الرمز 3، وإذا كانت واقعة بين 1.96 و 2.58 فيتم إعطاؤها الرمز 2، أما إذا كانت أقل من 1.96 فإنها تأخذ الرمز 1.

```
VALUE LABELS outlier1
1 'Absolute z-score less than 2' 2 'Absolute z-score greater than 1.96' 3 'Absolute z-score greater
than 2.58' 4 'Absolute z-score greater than 3.29'.
FREQUENCIES
VARIABLES=outlier1
/ORDER= ANALYSIS.
```

أخيراً، تُستخدم الأداة frequencies لإنتاج جدول يخبرك عن النسب المئوية للقيم ذوات الترميز 1 و 2 و 3 و 4 للمتحول outlier1.

إن الجدول الناتج عن هذه القواعد مبين في نهاية المربع الحالي. لننظر إلى العمود المسمى Valid Percent. نتوقع أن تكون 95% من الحالات ذات قيمة مطلقة أصغر من 1.96، و 5% (أو أقل) بقيمة مطلقة أكبر من 1.96، و 1% (أو أقل) بقيمة مطلقة أكبر من 2.58. أخيراً نتوقع عدم وجود حالات تكون قيمتها المطلقة أكبر من 3.29 (وهذه الحالات هي التي تمثل القيم المنعزلة المهمة). ولكن علامات النظافة لليوم الثاني من مهرجان Glastonbury تبين أن 93.2% من القيم تملك علامات معيارية أصغر من 1.96. بطريقة أخرى، هذا يعني أن 6.8% (لننظر إلى الجدول حيث نجد 4.5%+1.5%+0.8%) كانت أعلى من 1.96. وهذه القيمة أكبر بقليل من القيمة 5% التي نتوقعها في توزيع طبيعي. لننظر إلى القيم الواقعة أعلى من 2.58، نتوقع أن نجد 1%، ولكننا مرة أخرى نجد قيمة أعلى تبلغ 2.3% (وهي 1.5%+0.8%). أخيراً نجد 0.8% من الحالات ذات قيمة مطلقة أعلى من 3.29 (أي أن هناك 0.8% من القيم المنعزلة المهمة). وهذا يعني أن هناك عدداً كبيراً من القيم المنعزلة في مجموعة البيانات، وينبغي علينا اتخاذ إجراء ما حولها.

OUTLIER1

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	Absolute z-score less than 2	246	30.4	93.2	93.2
	Absolute z-score greater than 1.96	12	1.5	4.5	97.7
	Absolute z-score greater than 2.58	4	.5	1.5	99.2
	Absolute z-score greater than 3.29	2	.2	.8	100.0
	Total	264	32.6	100.0	
Missing	System	546	67.4		
Total		810	100.0		

3.3.3 الخطوة 3: تصحيح المشاكل في البيانات

عرضنا في الفقرة السابقة طرقاً مختلفة لاستكشاف البيانات، ورأينا كيفية البحث عن المشاكل الموجودة في توزيع البيانات وكيفية اكتشاف القيم المنعزلة. السؤال التالي هو ما الذي يمكننا عمله إزاء هذه المشاكل؟ إذا اكتشفنا قيماً منعزلة في البيانات فإن هناك عدة خيارات لتخفيف أثرها. قبل الإقدام على أية خطوة، ينبغي علينا التحقق من أن عملية إدخال البيانات للحالات ذات المشكلة قد تمت بشكل صحيح. إذا كانت القيم صحيحة فإن هناك ثلاثة خيارات أساسية:

1. **إزالة الحالة:** يشمل ذلك حذف البيانات للشخص المساهم بالقيمة المنعزلة. على كل حال، يمكن أن يتم ذلك عند توفر الأسباب المقنعة للاعتقاد بأن هذه الحالة لا تنتمي للمجتمع الذي تريد أخذ عينة منه. فعلى سبيل المثال، إذا كنت تقوم ببحث عن العوامل التي تجعل القطط تخرخر (تموء بصوت خفيف من السعادة purr) وكانت هناك قطة لا تخرخر أبداً، فيمكنك اعتبار هذه القطة كحالة منعزلة (لأن جميع القطط تخرخر). وعند التحقيق اكتشفت أن هذه القطة كانت كلباً (ولذلك فهي لا تخرخر) يرتدي لباس قطة، عندئذ تكون لديك الأسباب المقنعة لاستثناء هذه الحالة لأنها تأتي من مجتمع آخر (الكلاب التي تحب أن تلبس كالقطط) غير المجتمع المستهدف عبر الدراسة (مجتمع القطط).

2. **تحويل البيانات:** إذا كان لديك توزيع غير طبيعي فإن هذا الخيار يجب تنفيذه على أية حال (التوزيعات غير المتناظرة ستملك بطبيعتها نقاطاً منعزلة، وذلك لأن هذه القيم المنعزلة هي التي سببت عدم تناظر التوزيع). وعمليات التحويل (انظر القسم التالي في هذه الفقرة) ستخفف أثر هذه القيم المنعزلة.

3. **تغيير العلامة:** إذا فشل التحويل فيمكنك عندئذ استبدال العلامة. تبدو هذه العملية كالغش (فأنت تعدّل البيانات عما تم تجميعه فعلياً)، ولكن إذا كانت القيمة التي تقوم بتعديلها غير ممثلة وتؤثر على النموذج الإحصائي بطريقة ما، فإن تعديل هذه العلامة هو أهوَنُ الشرَّين. وهناك عدة خيارات يمكن اللجوء إليها لتنفيذ هذا التعديل:

   أ. **القيمة الكبرى التالية مضافاً إليها 1:** تعديل قيمة العلامة لتصبح مساوية للقيمة الكبرى التالية في مجموعة البيانات مضافاً إليها القيمة 1.

   ب. **تحويل عكسي من علامة z:** تشكل العلامة z ذات القيمة 3.29 قيمة منعزلة (انظر المربع 2.3) لذلك نحسب القيمة التي تعطي العلامة z القيمة 3.29 (وربما 3) وذلك بإعادة ترتيب معادلة العلامة z في المربع 2.3 لتصبح $X=(z\times s)+\bar{X}$. ويعني ذلك أننا نحسب قيمة المتوسط ($\bar{X}$) والانحراف المعياري (s) للبيانات، مع معرفتنا لقيمة z التي تساوي 3 (أو بشكل أدق 3.29) لذلك نقوم بإضافة ثلاثة أمثال الانحراف المعياري إلى قيمة المتوسط ونبدل القيمة المنعزلة بهذه العلامة الجديدة.

   ج. **قيمة المتوسط مضافاً إليها ضعفي الانحراف المعياري:** وهو صيغة معدلة عن التحويل العكسي السابق، حيث نضيف ضعفي قيمة الانحراف المعياري إلى قيمة المتوسط (بدلاً من ثلاثة أضعاف الانحراف المعياري).

إن الفقرة التالية مرعبة، لذلك لا تقلق إذا لم تفهم منها شيئاً ! وتتجنب معظم المناهج الدراسية عملية تحويل البيانات بهذه الطريقة لذلك يمكنك تجاوزها إذا أردت.

من بين الخيارات الأساسية التي أوردناها سابقاً، ربما تكون عملية تحويل البيانات هي الأفضل لأنها لا تقوم بتبديل علامة واحدة حيث يتم عملية التحويل ذاتها على جميع العلامات (فأنت لا تهتم بتغيير قيمة واحدة من العلامات، بل تقوم بعمل يخفف من أثر العلامات القصوى). إن الفكرة وراء التحويلات هي تحويل جميع البيانات لتصحيح مشاكل التوزيع أو القيم المنعزلة. ومع أن بعض الطلاب يعتقدون (لأسباب يمكن فهمها) أن عملية تحويل البيانات تبدو مشبوهة (وغالباً ما تقفز عبارة "التلاعب بالعلامات" إلى عقول الطلاب)، فهي ليسن كذلك لأنك تقوم بنفس التحويل على جميع البيانات. إن تحويل البيانات لا يؤثر على العلاقات بين المتحولات (فالفروق النسبية لمتحول معين بين الأشخاص تبقى ذاتها)، ولكنه يغيّر الفروق بين المتحولات المختلفة (لأنه يغيّر وحدات القياس). لذلك إذا كان لديك متحول واحد ذو توزيع غير متناظر، وكنت تريد مقارنة الفروق بين ذلك المتحول ومتحولات أخرى في مجموعة البيانات فإن عليك تطبيق التحويل على تلك المتحولات أيضاً. فمن أجل بيانات النظافة المتوفرة لدينا، قد نرغب بمعرفة كيفية تغيّر مستويات

النظافة خلال الأيام الثلاثة للمهرجان (كمقارنة المتوسط لليوم الأول مع المتوسطات لليومين الثاني والثالث). إن علامات اليومين الثاني والثالث غير متناظرة ونريد تحويلها، ولكن بسبب المقارنة اللاحقة مع علامات اليوم الأول، فإن علينا تحويل بيانات اليوم الأول (مع أنها متناظرة). إذا لم نطبق التحويل على بيانات اليوم الأول أيضاً فإن أية فروق في علامات النظافة بين اليوم الأول واليوم الثاني أو اليوم الثالث ستكون ناتجة بسببنا وذلك لأننا طبقنا التحويل على متحول ما دون تطبيقه على بقية المتحولات.

عندما تكون البيانات التي تريد تصحيحها إيجابية الميلان (كما هي الحالة لدينا) فإن هناك ثلاثة تحويلات يمكن الاستفادة منها (وكما سترى، فإنه يمكن اعتمادها للتعامل مع البيانات سلبية الميلان أيضاً):

1. **تحويل اللوغاريتم $\log(X_i)$:** إن حساب اللوغاريتم لمجموعة من الأرقام يؤدي لتصغير الطرف الأيمن للتوزيع. وبذلك يتم تخفيض الميلان الإيجابي. لا يمكنك طبعاً الحصول على لوغاريتم الصفر أو الأعداد السالبة، لذلك إذا كانت البيانات تتجه نحو الصفر أو تعطي قيماً سالبة فعليك إضافة رقم ثابت لجميع البيانات قبل إجراء التحويل. فعلى سبيل المثال، إذا كانت هناك قيم معدومة في مجموعة البيانات فيمكنك استخدام التحويل $\log(X_i+1)$، أما إذا كانت هناك قيم سالبة فيمكنك إضافة القيمة التي تريدها بحيث تكون أصغر القيم في مجموعة البيانات موجبة.
2. **تحويل الجذر التربيعي $\sqrt{X_i}$:** إن حساب الجذر التربيعي للقيم الكبيرة له أثر أكبر من حساب الجذر التربيعي للقيم الصغيرة. وبالتالي فإن حساب الجذر التربيعي لجميع العلامات سيجلب القيم الكبيرة قريباً من المركز بشكل أفضل مما يفعله التحويل اللوغاريتمي. وهذه طريقة مفيدة لتخفيف البيانات إيجابية الميلان. ولكن ما زالت هناك مشكلة مع القيم السالبة، إذ لا يمكنك حساب الجذر التربيعي لها.
3. **تحويل المقلوب $1/X_i$:** إن تقسيم العدد 1 على جميع العلامات سيؤدي لتخفيض القيم الكبيرة. للمتحول الناتج قيمة دنيا قريبة جداً من الصفر (فالعدد الكبير جداً يصبح قريباً من الصفر). عند استخدام هذا التحويل يجب ألا ننسى أن القيم الأصلية الكبيرة تصبح صغيرة (أقرب إلى الصفر)، بينما القيم الأصلية الصغيرة تصبح كبيرة بعد التحويل. تخيل أن لديك القيمتان 1 و10، بعد التحويل تصبح لديك القيمتان 1/1=1 و1/10=0.1، فالقيمة التي كانت صغيرة أصبحت بعد التحويل أكبر من القيمة التي كانت كبيرة قبل التحويل. على كل حال يمكنك تجنب هذه الحالة بعكس العلامات قبل التحويل، وذلك بإيجاد القيمة العظمى ثم تبديل كل قيمة من العلامات بطرحها من القيمة العظمى. لذلك يصبح التحويل بالشكل: $1/(X_{Highest}-X_i)$.

يمكن استخدام أي من هذه التحويلات لتصحيح البيانات المزاحة سلبياً، ولكن عليك أولاً عكس العلامات (كطرح كل قيمة من القيمة العظمى)، وعندما تفعل ذلك لا تنس عكسَ القيم مرة أخرى بعد التحويل.

4.3.3 الخطوة 4: تحويل البيانات باستخدام SPSS

المسألة التالية هي كيفية تنفيذ التحويلات في برنامج SPSS، وهذا يقودنا إلى التعليمة compute. تسمح التعليمة compute بتنفيذ مجموعة من التوابع على أعمدة البيانات في محرر البيانات. ومن الوظائف النموذجية جمع العلامات عبر عدة أعمدة، أو حساب الجذر التربيعي للعلامات في عمود ما، أو حساب المتوسط لمجموعة متحولات. للوصول إلى التعليمة compute يمكنك استخدام القائمة Transforn ⇒ Compute... حيث نحصل على مربع الحوار المبين في (الشكل 8.3). في القسم الأيمن من مربع الحوار الناتج هناك لائحة بأسماء التوابع، وهناك لوحة مفاتيح تشبه الآلة الحاسبة في الوسط. معظم التوابع في الآلة الحاسبة واضحة، وفيما يلي سرد لأكثرها شيوعاً:

الجمع: يقوم هذا الزر بإضافة علامة الجمع (+) في منطقة الأوامر. فعلى سبيل المثال، يقوم الأمر day1 + day2 بإنشاء عمود يحوي كل صف فيه قيمة النظافة في العمود day1 مضافة إلى قيمة النظافة في العمود day2، فمن أجل المشترك رقم 1 يكون لدينا 2.56 + 1.35 = 4.

الطرح: يقوم هذا الزر بإضافة علامة الطرح (−) في منطقة الأوامر. فعلى سبيل المثال، إذا أردنا حساب تغير النظافة بين اليومين الأول والثاني، فإننا نكتب day2 - day1، حيث يتم إنشاء عمود يحوي كل صف فيه قيمة النظافة في العمود day1 مطروحة من قيمة النظافة في العمود day2، فمن أجل المشترك رقم 1 يكون لدينا 1.30- = 2.65 - 1.35 أي أن نظافة الشخص قد انخفضت بمقدار 1.30 (على مقياس مؤلف من 5 نقاط) بين اليومين الأول والثاني.

الضرب: يقوم هذا الزر بإضافة علامة الضرب (×) في منطقة الأوامر. فعلى سبيل المثال، يقوم الأمر day1 × day2 بإنشاء عمود يحوي كل صف فيه قيمة النظافة في العمود day1 مضروبة بقيمة النظافة في العمود day2، فمن أجل المشترك رقم 1 يكون لدينا 2.65 × 1.35 = 3.58.

التقسيم: يقوم هذا الزر بإضافة علامة القسمة (/) في منطقة الأوامر. فعلى سبيل المثال، يقوم الأمر day1 / day2 بإنشاء عمود يحوي كل صف فيه قيمة النظافة في العمود day1 مقسومة على قيمة النظافة في العمود day2، فمن أجل المشترك رقم 1 يكون لدينا 2.65 / 1.35 = 1.96.

الرفع لأس: يُستخدم هذا الزر لرفع العدد الذي يسبقه إلى قوة العدد الذي يليه. فعلى سبيل المثال، يقوم الأمر day1**2 بإنشاء عمود يحوي علامات اليوم الأول مرفوعة للأس 2، فمن أجل المشترك رقم 1 يكون لدينا $(2.65)^2 = 7.02$.

أصغر تماماً من: تُستخدم هذه العملية عادة لتوابع تضمين الحالات التي تكون أقل من قيمة معينة. إذا نقرت الزر ...if يظهر مربع حوار جديد، ويسمح باختيار حالات معينة سيتم عليها تنفيذ العملية المطلوبة. فإذا كتبت day1<1 فإن برنامج SPSS سينفذ التعليمة compute على المشاركين الذين كانت علامات نظافتهم في اليوم الأول للمهرجان أصغر من 1 (أي 0.99 أو أدنى). لذلك يمكننا استخدام هذه التعليمة لمعرفة المشاركين الذين كانت رائحتهم نتنة منذ اليوم الأول للمهرجان.

أصغر أو يساوي: هذه العملية مشابهة للعملية السابقة باستثناء أن حالة المساواة ستكون متضمنة أيضاً.

أكبر تماماً من: تُستخدم هذه العملية عادة لتوابع تضمين الحالات التي تكون أعلى من قيمة معينة. إذا نقرت الزر ...if وكتبت day1>1 في مربع الحوار الناتج فإن برنامج SPSS سينفذ التعليمة compute على المشاركين الذين كانت علامات نظافتهم في اليوم الأول للمهرجان أكبر من 1 (أي 1.01 أو أعلى). لذلك يمكننا استخدام هذه التعليمة لاستثناء المشاركين الذين كانت رائحتهم نتنة منذ اليوم الأول للمهرجان (لأننا نهتم بدراسة لآثار المهرجان على النظافة، وهؤلاء الأشخاص سيشوهون البيانات بنشر الروائح الكريهة منذ اللحظة الأولى.

أكبر أو يساوي: هذه العملية مشابهة للعملية السابقة باستثناء أن حالة المساواة ستكون متضمنة أيضاً.

يساوي لـ: يمكن استخدام هذه العملية لتضمين الحالات التي يملك فيها المشتركون قيمة محددة. فإذا كتبت day1=1 في المربع الحوار ...if فإنك ستكون متأكداً من تضمين الحالات التي تكون فيها قيمة المتحول day1 مساوية للقيمة 1. وهذه العملية مفيدة بشكل خاص عند استخدام متحولات الترميز للبحث ضمن مجموعة واحدة فقط. فعلى سبيل المثال، إذا كان لدينا المتحول music الذي يرمّز أنواع الموسيقى للمشاركين في المهرجان (انظر الفقرة 10.5) فيكون 1=Indie Kid، 2=Metaller، 3=Crusty، 4=no، وقمت بكتابة music=2 فستتم عملية التحليل على الأشخاص الذين عرّفوا عن أنفسهم كـ Metaller.

لا يساوي لـ: هذه العملية ستتضمن جميع الحالات باستثناء قيمة محددة. فالأمر music~=2 يعني تضمين جميع الحالات باستثناء الأشخاص الذين عرّفوا عن أنفسهم كـ Metaller.

نوع المتحول: يفتح هذا الزر مربع الحوار الذي يسمح بتسمية المتحول الجديد وتحديد نوعه.

يتم وضع علامات عملية الحساب compute في عمود جديد في محرر البيانات، ولذلك فإن أول شيء ينبغي عمله هو إعطاء تسمية للمتحول الجديد (في حيز النص المسمى المتحول الهدف Target Variable). إذا استخدمت اسم متحول معرّف سابقاً في محرر البيانات، فإن برنامج SPSS سيخبرك بذلك ويسألك فيما إذا كنت تريد استبدال المتحول القديم بالمتحول الجديد. إذا كان جوابك نعم فإن SPSS سيقوم باستبدال البيانات الموجودة في العمود القديم بنتائج الحساب compute. أما إذا كان جوابك لا، فلن يحدث شيء وعندها ستضطر لإعادة تسمية المتحول الجديد. إذا نقرت الزر Type & Label... سيظهر مربع حوار جديد، حيث يمكنك منح المتحول الجديد تسمية وصفية وتحدد نوعه (رقمي أو نصي، انظر الفقرة 5.4.2). يشكل الحيز المسمى Numeric Expression المكان الذي تتم فيه كتابة الأوامر الرياضية (ولذلك قمت بتسميته منطقة الأوامر). يمكنك إدخال أسماء المتحولات إلى منطقة الأوامر وذلك باختيار المتحول المطلوب من لائحة المتحولات ونقر زر السهم بين هاتين المنطقتين. وبشكل مشابه، يمكنك اختيار بعض التوابع من لائحة التوابع المتوفرة وإدخالها إلى منطقة الأوامر بنقر زر السهم الموجود بينهما.

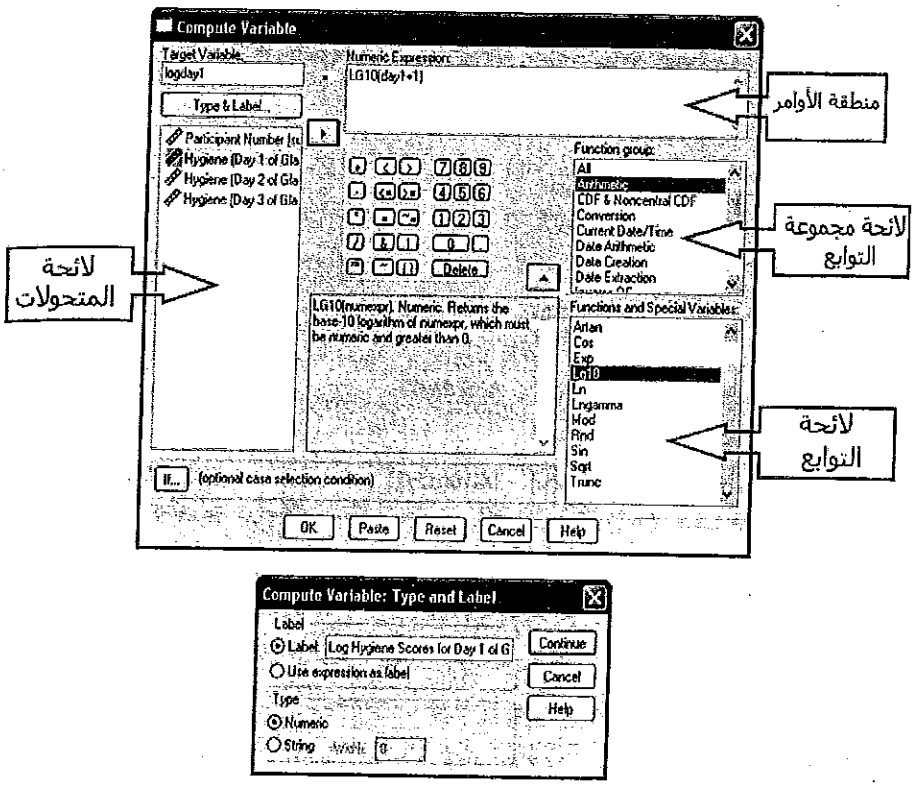

الشكل 8.3 مربع الحوار للتعليمة compute

يبين الجدول 1.3 أهم التوابع المفيدة، حيث يعرض الشكل القياسي للتابع، واسم التابع، ومثالاً عن كيفية استخدام التابع، وكيف سيكون الخرج عند تنفيذ ذلك المثال. هناك بعض التوابع الأساسية لحساب قيمة المتوسط، والانحراف المعياري والمجموع في الأعمدة. وهناك بعض التوابع كالجذر التربيعي واللوغاريتم التي تفيد في عمليات تحويل البيانات (والتي تحدثنا عنها سابقاً). وللقراء المهتمين، يقدم دليل المستخدم لبرنامج SPSS (وكذلك ملفات المساعدة help files) تفاصيلاً عن جميع التوابع المتوفرة في مربع الحوار compute.

التابع	الاسم	مثال الدخل	الخرج
Mean(?,?,...)	المتوسط	Mean(day1,day2,day3)	من أجل كل صف، يقوم برنامج SPSS بحساب متوسط علامة النظافة عبر الأيام الثلاثة للمهرجان.
SD(?,?,...)	الانحراف المعياري	SD(day1,day2,day3)	من أجل كل صف، يقوم برنامج SPSS بحساب الانحراف المعياري للقيم الموجودة في الأعمدة المسماة day1 و day2 و day3.
SUM(?,?,...)	المجموع	Sum(day1,day2)	من أجل كل صف، يقوم برنامج SPSS بحساب مجموع القيم الموجودة في العمودين day1 و day2.
SQRT(?)	الجذر التربيعي	SQRT(day2)	إنشاء عمود يحوي كل صف فيه الجذر التربيعي للقيمة الموجودة في نفس الصف من العمود day2. مفيد في تحويل البيانات غير المتناظرة أو البيانات ذات التباينات غير المتجانسة.
ABS(?)	القيمة المطلقة	ABS(day1)	إنشاء متحول يحوي القيمة المطلقة للقيم في العمود المسمى day1.
LG10(?)	اللوغاريتم العشري	LG10(day1)	إنشاء متحول يحوي قيم اللوغاريتم العشري للمتحول day1. ويفيد في تحويل البيانات إيجابية الميلان.
Normal(stddev)	أرقام عشوائية طبيعية	Normal(5)	إنشاء متحول يحوي الأرقام العشوائية من توزيع طبيعي بمتوسط يساوي 0 وانحراف معياري 5

الجدول 1.3 بعض التوابع المفيدة في مربع الحوار compute

والآن بعد عرفنا بعض المعلومات الأساسية عن التعليمة compute لنبدأ باستخدامها لتحويل البيانات المتوفرة لدينا. نفتح أولاً مربع الحوار الأساسي للتعليمة compute باستخدام أمر القائمة Transform ⇒ Compute... اكتب اسم المتحول logday1 في حيز النص المسمى Target Variable

ثم انقر الزر Type & Label... أعط تسمية وصفية معبرة للمتحول مثل "التحويل اللوغاريتمي لعلامات النظافة في اليوم الأول من مهرجان Glastonbury". انتقل في لائحة التوابع المتوفرة حتى يظهر التابع LG10(numexpr). اختر هذا التابع ثم انقر الزر المشير للأعلى لنقل التابع إلى منطقة الأوامر. عند نقل التابع يظهر بالشكل التالي في منطقة الأوامر LG10(?)، حيث يجب استبدال إشارة الاستفهام باسم المتحول الذي تريد تحويله، والذي يمكنك كتابته يدوياً أو نقله من لائحة المتحولات المتوفرة في القسم الأيسر من مربع الحوار. استبدل إشارة الاستفهام بالمتحول day1. بالنسبة لعلامات النظافة في اليوم الثاني، هناك بعض القيم المعدومة، لذلك لا يمكننا استخدام اللوغاريتم. للتغلب على هذه المشكلة نقوم بإضافة قيمة ثابتة لجميع العلامات الأصلية قبل حساب اللوغاريتم. يمكن استخدام أية قيمة ثابتة بشرط أن تجعل جميع القيم أكبر من الصفر. بما أن أصغر قيمة لدينا هي 0 فإننا نكتفي بإضافة العدد 1 لجميع العلامات، وهذا يضمن أنها تصبح أكبر من الصفر. لتنفيذ ذلك، تأكد من وجود المؤشر بين القوسين ثم انقر علامة الجمع (+) يليها الرقم 1. يجب أن يبدو مربع الحوار الأخير كما في الشكل 8.3، لاحظ أن التعبير الرياضي أصبح بالشكل LG10(day1+1) أي أن برنامج SPSS سيضيف العدد 1 لكل علامة من علامات النظافة لليوم الأول، ثم يحسب لوغاريتم القيمة الناتجة. انقر الزر OK لإنشاء متحول جديد logday1 يحوي القيم التي تم تحويلها. عليك الآن إتباع نفس الخطوات لإنشاء متحولات مشابهة logday2 و logday3 من أجل بيانات اليومين الثاني والثالث.

نعلم الآن كيفية تنفيذ التحويل اللوغاريتمي للبيانات، ولنحاول التعرف على الأنواع الأخرى من التحويلات. إذا أردنا استخدام تحويل الجذر التربيعي فيمكننا إتباع نفس الطريقة واستخدام اسم مثل sqrtday1 واختيار التابع SQRT(numexpr) من لائحة التوابع المتوفرة. سيظهر التابع SQRT(?) في منطقة الأوامر Numeric Expression حيث يمكنك استبدال إشارة الاستفهام بالمتحول الذي تريد تحويله، في هذه الحالة day1. ويكون الشكل النهائي للتابع SQRT(day1). كرر العملية السابقة لإنشاء المتحولات sqrtday2 وsqrtday3 التي تمثل الجذر التربيعي لكل من المتحولين day2 وday3 على الترتيب.

أخيراً، إذا أردنا استخدام تحويل المقلوب على بيانات اليوم الأول، فيمكننا استخدام اسم مثل recday1 ثم نقر الزر 1 يليه الزر (/). يمكنك طبعاً استخدام اسم المتحول الذي تريد تحويله من لائحة المتحولات المتوفرة (إما بنقر زر السهم، أو بكتابة اسم المتحول). بما أن بيانات اليوم الثاني تحوي بعض القيم المعدومة، فإن التقسيم عليها سيعطي رسالة خطأ (لا يمكن التقسيم على 0). ولذلك يجب علينا إضافة قيمة ثابتة للمتحول كما فعلنا في حالة التحويل اللوغاريتمي. ويمكن لأن قيمة ثابتة أن تفي بالغرض، ولكن جرت العادة على استخدام العدد 1. لذلك وبدلاً من اختيار المتحول الذي نريد تحويله، ننقر زر القوسين (). يتم وضع قوسين في منطقة الأوامر، نضع المؤشر بين هذين القوسين ثم نختار المتحول الذي نرغب بتحويله من لائحة المتحولات المتوفرة (بنقر زر السهم أو بكتابة اسم المتحول يدوياً). انقر الزر الممثل لعلامة الجمع (+) ثم انقر الزر 1 (أو اكتب 1+ باستخدام لوحة المفاتيح). ستصبح العبارة الرقمية في منطقة الأوامر هي 1/(day1+1). انقر

الزر OK لإنشاء المتحول الجديد الذي يحوي القيم المحوَّلة. كرر هذه العملية بنفسك من أجل بيانات اليومين الباقيين. إذا كنت تقوم بحساب عدد كبير من المتحولات فإن الطريقة الأسرع هي استخدام نافذة القواعد كما يبين ذلك المربع 3.3.

المربع 3.3 استخدام القواعد لحساب المتحولات الجديدة

إذا كنت تقوم بحساب عدد كبير من المتحولات فإن الطريقة الأسرع هي استخدام القواعد، كما هي الحال في تحويل البيانات في المثال الخاص بهذا الفصل. يحوي القرص المضغوط المرفق ملف القواعد Transformations.sps الذي يحوي جميع التحويلات التي تمت مناقشتها في الفقرة السابقة والتي يبلغ عددها 9. قم بتحميل هذا الملف ثم تشغيله، أو افتح نافذة قواعد جديدة واكتب فيها ما يلي:

```
COMPUTE logday1 = LG10(day1+1).
COMPUTE logday2 = LG10(day2+1).
COMPUTE logday3 = LG10(day3+1).
COMPUTE sqrtday1 = SQRT(day1).
COMPUTE sqrtday2 = SQRT(day2).
COMPUTE sqrtday3 = SQRT(day3).
COMPUTE recday1 = 1/(day1+1).
COMPUTE recday2 = 1/(day2+1).
COMPUTE recday3 = 1/(day3+1).
EXECUTE.
```

تقوم كل تعليمة COMPUTE بتنفيذ ما يكافئ العمل المنفذ باستخدام مربع الحوار compute في الشكل 8.3. لذلك فإن الأسطر الثلاثة الأولى تنشئ المتحولات الجديدة logday1 و logday2 و logday3، وهي التحويل اللوغاريتمي للمتحولات day1 و day2 و day3 مضافاً إليها العدد 1. تقوم الأسطر الثلاثة التالية بتنفيذ تحويل الجذر التربيعي للمتحولات day1 و day2 و day3 وتنشئ المتحولات الجديدة sqrtday1 و sqrtday2 و sqrtday3 على التوالي. وتقوم الأسطر الثلاثة التالية بتنفيذ تحويل المقلوب بنفس الطريقة. أما السطر الأخير فيحوي عبارة التنفيذ التي بدونها لن يتم تنفيذ أي من عمليات الحساب السابقة. لا تنس أن كل سطر ينتهي بنقطة.

لنلق نظرة الآن على التوزيعات الجديدة (الشكل 9.3). قارن هذه التوزيعات مع التوزيعات الأصلية قبل التحويل المبينة في الشكل 5.3. يمكنك أن تلاحظ الآن أن التحويلات الثلاثة قامت بتحسين بيانات النظافة لليوم الثاني، حيث اختفى الميلان الإيجابي (وخاصة عند استخدام تحويل الجذر التربيعي). على كل حال، ولأن بيانات النظافة في اليوم الأول كانت متناظرة بشكل أفضل قبل عملية التحويل، فقد أصبحت سلبية الميلان باستخدام تحويلات اللوغاريتم والجذر التربيعي، وإيجابية الميلان باستخدام تحويل المقلوب (وهذا ناتج كما أشرنا سابقاً لأن المقلوب يؤدي لعكس العلامات). إذا كنا

نهتم بعلامات اليوم الثاني فقط فيمكننا استخدام العلامات المحوَّلة، ولكن إذا أردنا البحث في التغيرات في العلامات فإن علينا الموازنة بحكمة بين الفوائد التي نجنيها من عملية التحويل لعلامات اليوم الثاني والمشاكل الناتجة في علامات اليوم الأول، أي أن تحليل البيانات يكون محبطاً أحياناً.

إذا أدى التحويل إلى تصحيح المشكلة في التوزيع فيمكنك تنفيذ التحليل الإحصائي الذي تريده على العلامات المحوَّلة. أما إذا لم يصحح التحويل المشكلة فعليك في هذه الحالة التفكير باستخدام اختبار لا يعتمد على فرضية البيانات الموزعة طبيعياً، وستتعرف على هذه الاختبارات عبر الفصول المختلفة في هذا الكتاب.

4.3 استكشاف مجموعات البيانات

في بعض الأحيان تحوي البيانات مجموعات مختلفة من الناس (رجال ونساء، من جامعات مختلفة، أشخاص مكتئبين وآخرين غير مكتئبين، وغير ذلك). هناك طرق عديدة لإنتاج الإحصائيات الوصفية الأساسية للمجموعات المنفصلة من الناس (وسنمر بهذه الطرق في الفقرة التالية). على كل حال، سنغتنم هذه الفرصة لتقديم وظيفة تدعى فصل الملف (split file) حيث يسمح بتكرار عمليات التحليل على مجموعات متعددة من الحالات. تسمح الوظيفة split file بتحديد متحول تجميع ما (تذكّر أن هذه المتحولات مستخدمة لتحديد فئات من الناس). ثم يتم تنفيذ الإجرائيات اللاحقة في برنامج SPSS على كل فئة يحددها متحول التجميع ذاك.

ربما ضجرت من بيانات النظافة لمهرجان Glastobury لذلك سنستخدم البيانات في الملف SPSSExam.sav على القرص المضغوط المرفق. يحوي هذا الملف البيانات المتعلقة بأداء الطلاب في امتحان SPSS. تم قياس أربعة متحولات هي: exam ويمثل علامات امتحان SPSS في السنة الأولى كنسبة مئوية، computer ويقيس المهارة في مجال الحاسب كقيمة من مئة، lecture يمثل النسبة المئوية لمحاضرات SPSS التي تم حضورها، numeracy قياس المهارات الرياضية (الحسابية) على مؤشر من 15 نقطة. هناك متحول يدعى uni يشير إلى حضور الطالب في جامعة Sussex أو جامعة Duncetown. ولكي نبدأ يجب أولاً فتح الملف SPSSExam.sav (انظر الفقرة 8.2 لتتذكر كيفية فتح ملف البيانات). ولننظر بشكل عام إلى هذه البيانات.

1.4.3 تشغيل التحليل من أجل جميع البيانات

لعرض التوزيع للمتحولات يمكننا استخدام تعليمة التكرارات frequencies، التي مررنا بها سابقاً (انظر الشكل 6.3). استخدم مربع الحوار لوضع المتحولات الأربعة (exam و computer و lecture وnumeracy) في حيز المتحولات Variables. انقر بعد ذلك الزر Statistics... لاختيار مربع الحوار إحصائيات statistics واختر بعض قياسات التوجه المركزي (المتوسط، المنوال، الوسط)، قياسات التغايرية (المجال، الانحراف المعياري، التباين، مقسمات الربعيّ)، وقياسات الشكل (التدبب وعدم

التناظر). انقر أيضاً الزر ...Charts للوصول إلى مربع الحوار مخططات بيانية charts، واختر التوزيع التكراري للعلامات مع منحني التوزيع الطبيعي (انظر الشكل 6.3 إذا أردت أية مساعدة حول أيّ من هذه الخيارات). انقر الزر Continue للعودة إلى مربع الحوار الرئيسي، انقر الزر OK لتنفيذ عملية التحليل.

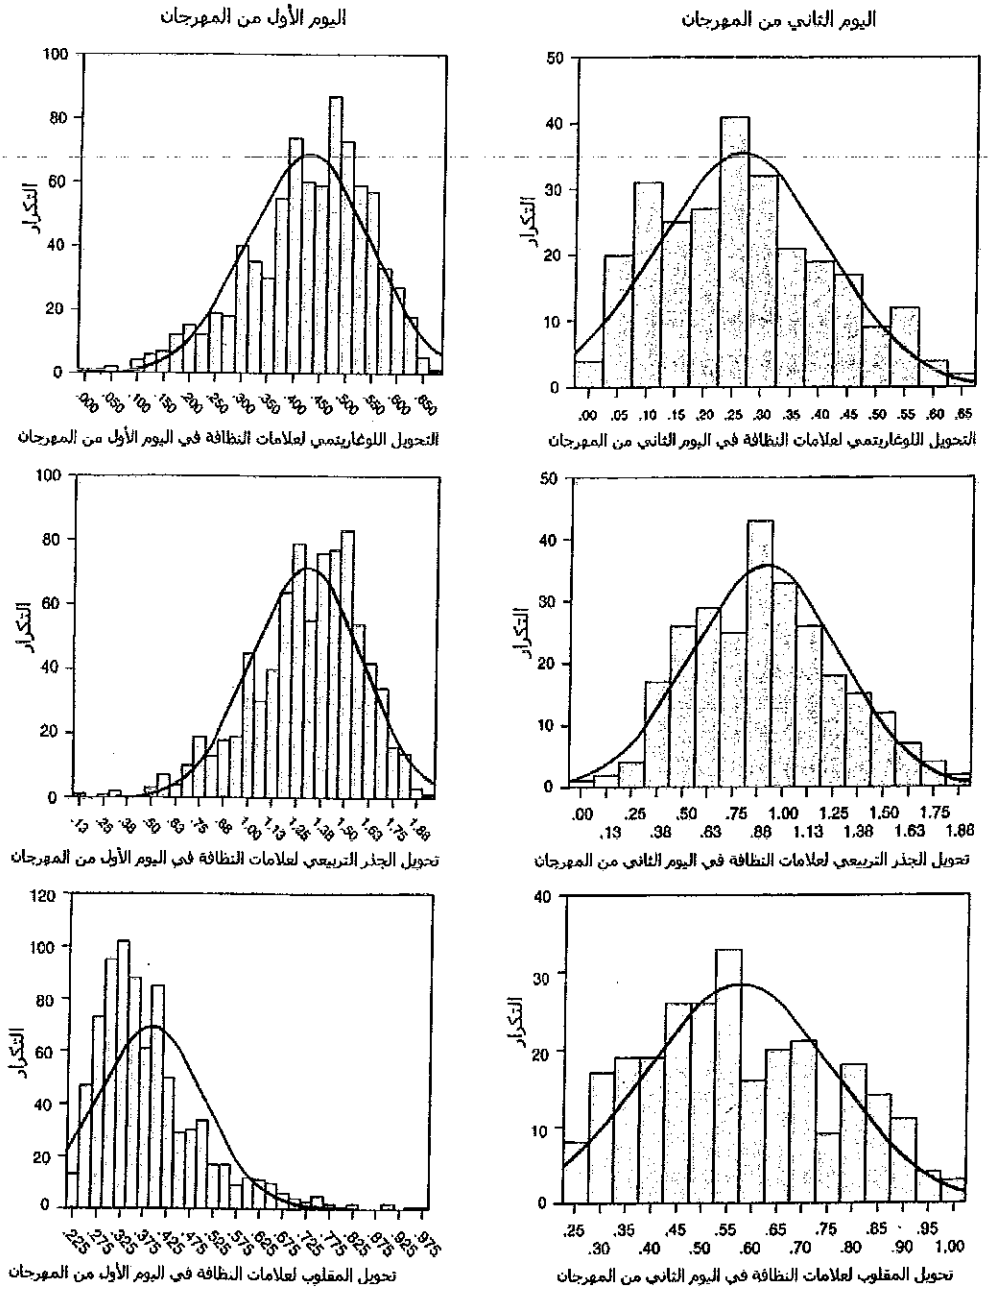

الشكل 9.3 التوزيعات لبيانات النظافة في اليومين الأول والثاني بعد التحويلات المختلفة

2.4.3 خرج SPSS من أجل جميع البيانات

يعرض الخرج 2.3 جدول الإحصائيات الوصفية للمتحولات الأربعة في هذا المثال. من هذا الجدول يمكننا أن نرى أنه في المتوسط يحضر الطلاب 60% تقريباً من المحاضرات، ويحصلون على 58% في امتحانات SPSS، وتبلغ علاماتهم 51% في اختبارات مهارة الحاسب، ويحصلون على 5 فقط من 15 في اختبار المهارات الرياضية. بالإضافة لذلك، نرى أن الانحراف المعياري لمهارة الحاسب كان صغيراً نسبياً مقارنة بالانحراف المعياري لكل من النسبة المئوية لحضور المحاضرات وعلامات الامتحان. ولهذين المتحولين أكثر من منوال واحد (أي أنها متعددة المنوال (multimodal)). أما القياسات الهامة الأخرى فهي عدم التناظر والتدبب، والأخطاء المعيارية المرتبطة بها. لقد مررنا بهذه القياسات سابقاً، ووجدنا أن بإمكاننا تحويل هذه القيم إلى علامات z (علامات معيارية) وذلك بتقسيمها على الخطأ المعياري الخاص بها. فمن أجل علامات امتحان SPSS تكون العلامة z لعدم التناظر هي -0.107/0.241=-0.44. أما المهارات الرياضية فتكون العلامة z لعدم التناظر هي 0.961/0.241=3.99. من الواضح أن علامات المهارات الرياضية إيجابية الميلان، أي أن هناك تراكماً للعلامات في القسم الأيسر من التوزيع (أي أن علامات معظم الطلاب متدنية). حاول حساب العلامات z لبقية المتحولات.

Statistics

		Percentage on SPSS exam	Computer literacy	Percentage of lectures attended	Numeracy
N	Valid	100	100	100	100
	Missing	0	0	0	0
Mean		58.1000	50.7100	59.7650	4.8500
Std. Error of Mean		2.13156	.82600	2.16848	.27057
Median		60.0000	51.5000	62.0000	4.0000
Mode		72.00[a]	54.00	49.50[a]	4.00
Std. Deviation		21.31557	8.26004	21.68478	2.70568
Variance		454.35354	68.22818	470.22957	7.32071
Skewness		-.107	-.174	-.422	.961
Std. Error of Skewness		.241	.241	.241	.241
Kurtosis		-1.105	.364	-.179	.946
Std. Error of Kurtosis		.478	.478	.478	.478
Range		84.00	46.00	92.00	13.00
Minimum		15.00	27.00	8.00	1.00
Maximum		99.00	73.00	100.00	14.00

a. Multiple modes exist. The smallest value is shown

الخرج 2.3

يوفر الخرج توزيعات تكرارية مجدولة لكل من المتحولات. تعرض هذه الجداول كل علامة وعدد مرات تكرارها ضمن مجموعة البيانات. بالإضافة لذلك، يتم التعبير عن كل قيمة من قيم التكرار كنسبة مئوية من العينة (في هذه الحالة، كانت قيم التكرارات والنسب المئوية متساوية لأن حجم

العينة كان 100 عنصر). كما تعطى النسب المئوية التراكمية، والتي تخبرنا عن عدد الحالات (كنسبة مئوية) تقع أدنى من علامة معينة. فعلى سبيل المثال، نجد أن 66% من علامات المهارات الحسابية كانت أقل أو تساوي 5، وأن 74% كانت أقل أو تساوي 6 وهكذا. وعند النظر باتجاه آخر نجد أن 8% فقط (92%-100) حصلوا على علامة أكبر من 8.

أخيراً، هناك المخططات التكرارية لكل متحول مع التوزيع الطبيعي. ويبين الشكل 10.3 هذه المخططات البيانية التي تعرض مجموعة من الأشياء الهامة. أولاً، تبدو مهارة الحاسب موزعة طبيعياً (أي أن هناك عدد قليل من الأشخاص ذوي مهارة ممتازة، وعدد قليل آخر من معدومي المهارة، أما الغالبية فهي ذات مستويات متقاربة من المعرفة في مجال الحاسب). إن علامات امتحان SPSS ممتعة جداً لأن التوزيع غير طبيعي كما هو واضح، ففي الحقيقة يبدو التوزيع ثنائي المنوال (bimodal) (هناك قمّتان تشيران لوجود منوالين). وتوافق هذه الملاحظة المعلومة الأخيرة من جدول الإحصائيات الوصفية. أما حضور المحاضرات فيبدو موزعاً بشكل طبيعي، ولكن أطراف التوزيع محملة بشكل كبير (مع أن معظم الطلاب يحضرون غالبية المحاضرات، فإن هناك عدداً معقولاً من الأشخاص يواظب بشكل دائم على جميع المحاضرات، وهناك عدد أكبر من النسبة الطبيعية ممن يحضرون عدداً قليلاً من المحاضرات). ولذلك يوجد عدد كبير من التكرارات عند طرفي التوزيع. أخيراً أعطى اختبار المهارات الرياضية بيانات إيجابية الميلان بشكل كبير (أي أن أداء غالبية الطلاب كان سيئاً جداً في هذا الاختبار، وقلة منهم فقط أجادت فيه). وهذا يوافق ما تشير إليه إحصائية عدم التناظر.

توفر الإحصائيات الوصفية والمخططات التكرارية صورة لحظية لتوزيع البيانات. ويمكن أن تكون هذه الصورة مفيدة جداً، فعلى سبيل المثال يشير التوزيع ثنائي المنوال لعلامات امتحان SPSS إلى أن الطلاب إما أن يكونوا ممتازين جداً في الإحصاء أو سيئين جداً (وهناك عدد قليل نسبياً ممن يقع بين هاتين الحالتين المتطرفتين). وبالحدس نجد أن هذه النتيجة تتوافق مع طبيعة الموضوع، فعلم الإحصاء يصبح سهلاً جداً عندما تتوضح أموره، ولكن قبل أن يحدث ذلك فإنه يبدو صعباً بشكل ميؤوس منه. ومع أن المخططات التكرارية والمعلومات الوصفية عن التوزيع توفر مجموعة من المعلومات فإن هناك طرقاً موضوعية يمكن من خلالها الوصول إلى تحديد درجة الطبيعية في مجموعة من البيانات.

3.4.3 تشغيل التحليل من أجل مجموعات مختلفة

إذا أردنا الحصول على إحصائيات وصفية منفصلة لكل من الجامعتين، فإنه يمكننا فصل الملف ثم استخدام تعليمة التكرارات التي استخدمناها في الفقرة السابقة. لفصل الملف استخدم أمر القائمة Data ⇒ Split File... أو انقر الأيقونة Split File. انقر الخيار Organize output by groups في مربع الحوار الناتج (انظر الشكل 11.3) لتنظيم الخرج حسب المجموعات. عند تحديد هذا الخيار، يتم تنشيط حيز النص Groups Based on الذي سيحوي متحول التجميع (أو الترميز). اختر

المتحول الذي يحوي رموز المجموعات والذي تريد استخدامه لتكرار عملية التحليل (في هذا المثال، نختار المتحول Uni) وانقله إلى حيز النص بنقر زر السهم الموجود بين حيزي النص في مربع الحوار. بشكل افتراضي، يقوم SPSS بترتيب الملف حسب هذه المجموعات (فيقوم بسرد فئة معينة تليها فئة أخرى في محرر البيانات). لقد طلبنا تنفيذ الإحصائيات لعلامات المتحولين numeracy وexam، يمكنك اختيار المتحولات الأخرى إذا رغبت بذلك.

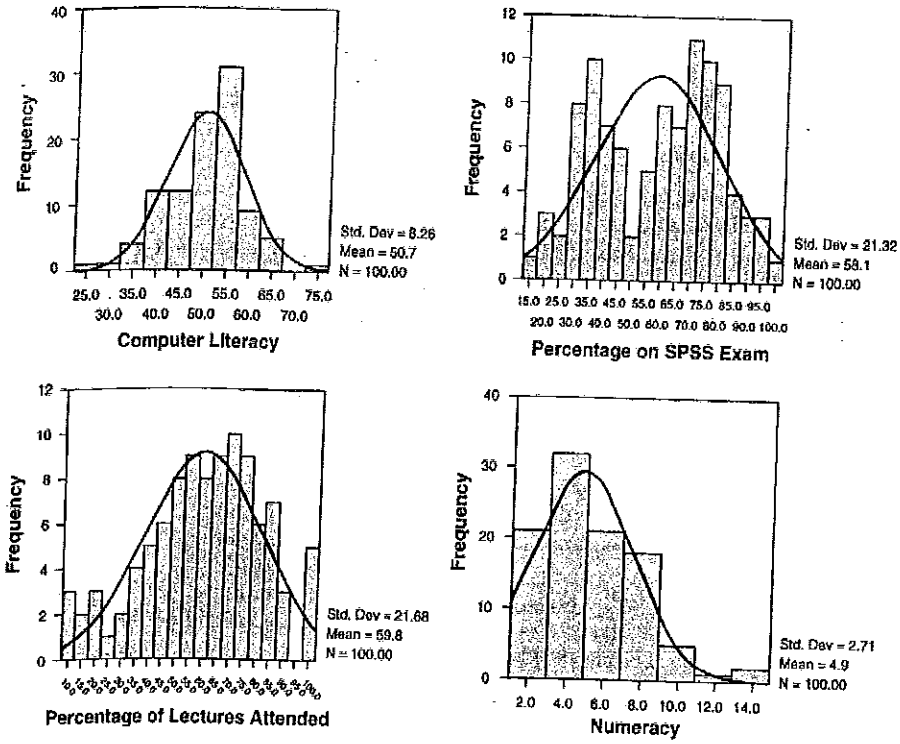

الشكل 10.3 المخططات التكرارية لبيانات المثال SPSSExam

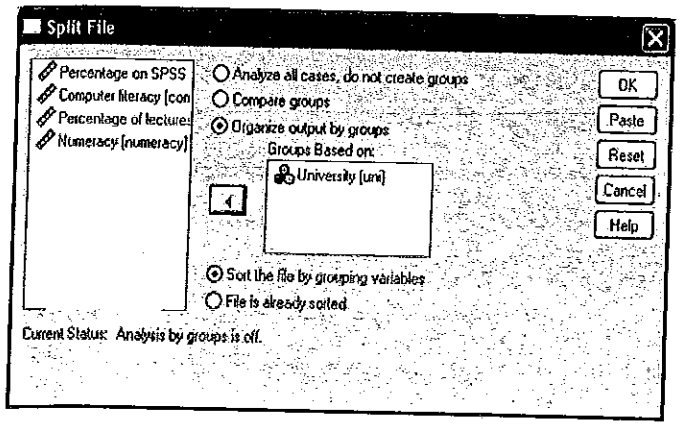

الشكل 11.3 مربع الحوار لتعليمة فصل الملف Split File

4.4.3 الخرج من أجل مجموعات مختلفة

ينقسم خرج SPSS إلى قسمين: يحوي الأول علامات الطلاب في جامعة Duncetown، بينما يحوي القسم الثاني علامات طلاب جامعة Sussex. يبين الخرج 3.3 جدولَي الخلاصة الأساسيين. من هذين الجدولين يبدو واضحاً أن علامات طلاب جامعة Sussex أعلى من طلاب جامعة Duncetown في كل من امتحان SPSS و اختبار المهارات الرياضية. تبين قيم المتوسطات أن طلاب جامعة Sussex قد حصلوا على ضعف علامات طلاب جامعة Duncetown في امتحان SPSS، وأن علاماتهم في اختبار المهارات الرياضية أعلى بنسبة 10% من علامات طلاب جامعة Duncetown. أما الانحراف المعياري لعلامات امتحان SPSS فهو أقل في جامعة Sussex، بينما الانحراف المعياري لعلامات اختبار المهارات الرياضية فهو أعلى في جامعة Sussex، ولكن الفروق ليست كبيرة.

University = Duncetown University

Statistics[b]

		Percentage on SPSS exam	Numeracy
N	Valid	50	50
	Missing	0	0
Mean		40.1800	4.1200
Std. Error of Mean		1.78032	.29227
Median		38.0000	4.0000
Mode		34.00[a]	4.00
Std. Deviation		12.58877	2.06664
Variance		158.47714	4.27102
Skewness		.309	.512
Std. Error of Skewness		.337	.337
Kurtosis		-.567	-.484
Std. Error of Kurtosis		.662	.662
Range		51.00	8.00
Minimum		15.00	1.00
Maximum		66.00	9.00

a. Multiple modes exist. The smallest value is shown

b. University = Duncetown University

University = Sussex University

Statistics[b]

		Percentage on SPSS exam	Numeracy
N	Valid	50	50
	Missing	0	0
Mean		76.0200	5.5800
Std. Error of Mean		1.44321	.43433
Median		75.0000	5.0000
Mode		72.00[a]	5.00
Std. Deviation		10.20502	3.07120
Variance		104.14245	9.43224
Skewness		.272	.793
Std. Error of Skewness		.337	.337
Kurtosis		-.264	.260
Std. Error of Kurtosis		.662	.662
Range		43.00	13.00
Minimum		56.00	1.00
Maximum		99.00	14.00

a. Multiple modes exist. The smallest value is shown

b. University = Sussex University

الخرج 3.3

يوضح (الشكل 12.3) المخططات التكرارية لهذه المتحولات التي تم فصلها اعتماداً على اسم الجامعة. إن أول ما يثير الانتباه بالنسبة لعلامات الامتحان أن التوزيعات تبدو طبيعية. ويبدو هذا غريباً لأن التوزيع الإجمالي لعلامات الامتحان كان ثنائي المنوال. ولكن يمكن فهم ذلك عندما نعرف أن توزيع العلامات لجامعة Duncetown يتمركز عند علامة 35% تقريباً، بينما يتمركز توزيع العلامات لجامعة Sussex عند العلامة 75% تقريباً. وهذا يوضّح مدى أهمية النظر إلى التوزيعات ضمن المجموعات. فإذا كنا مهتمين بمقارنة الجامعتين فليس مهماً أن يكون التوزيع الإجمالي للعلامات ثنائي المنوال، وكل ما يهمّنا هو أن تأتي كل مجموعة من توزيع طبيعي، وفي هذا المثال تبدو هذه المسألة صحيحة. عند تركيب العينتين، ينتج عن تركيب التوزيعين الطبيعيين لهما

توزيع ثنائي المنوال (أحدهما قريب من مركز التوزيع لبيانات الجامعة الأولى، والمنوال الآخر قريب من مركز التوزيع لبيانات الجامعة الثانية). أما بالنسبة لعلامات المهارات الرياضية، فإن التوزيع لجامعة Duncetown كان إيجابي الميلان بشكل طفيف (هناك تركيز كبير عند الطرف الأدنى للعلامات)، وكذلك كان التوزيع لجامعة Sussex ولكن العلامات بشكل عام أعلى من جامعة Duncetown. ولذلك فإن الميلان الإيجابي الكلي الذي رأيناه سابقاً يعود لدمج هذين التوزيعين. عند انتهاء العمل بتعليمة فصل الملف Split File تذكر أن تقوم بإيقافها (وإلا فإن برنامج SPSS سينفذ جميع عمليات التحليل اللاحقة على كل مجموعة على حدا). لإيقاف هذه التعليمة افتح مربع الحوار Split File وانقر الخيار Analyze all cases, do not create groups كي يقوم البرنامج بتحليل جميع الحالات ولا يقوم بإنشاء مجموعات منفصلة.

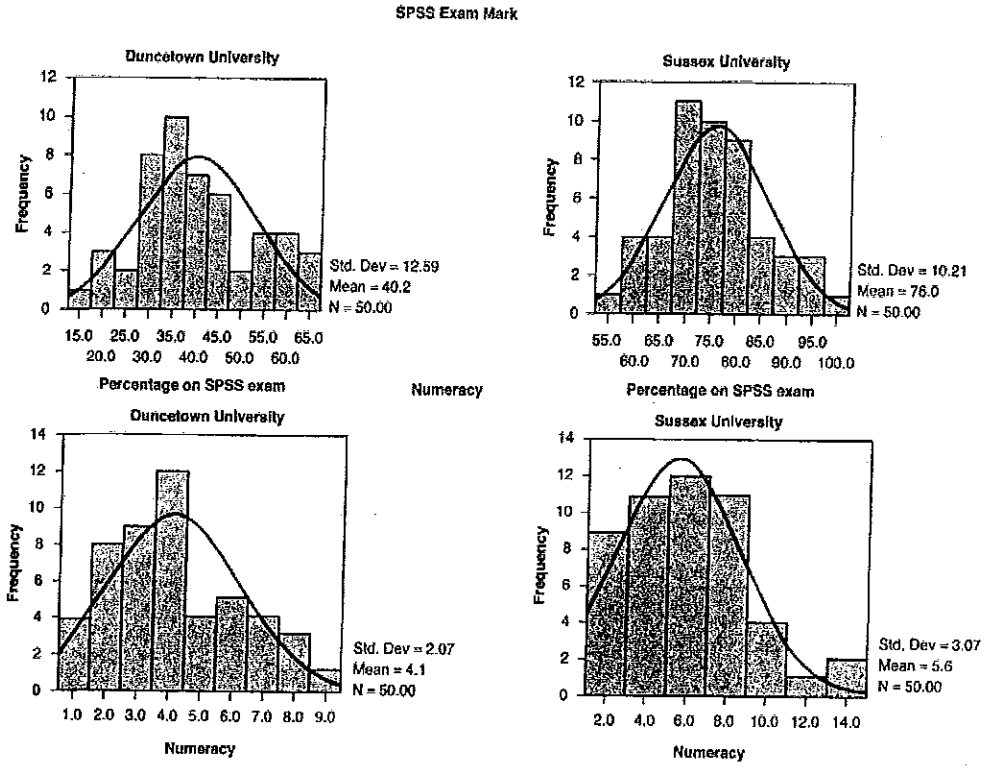

الشكل 12.3 توزيعات علامات الامتحان والمهارات الرياضية لكل من جامعتي Duncetown و Sussex

5.3 اختبار فيما إذا كان التوزيع طبيعياً

إن تأمّل المخططات التكرارية أمر رائع، ولكنها تخبرنا معلومات قليلة عما إذا كان التوزيع قريباً لحد معقول من الطبيعية. إن النظر إلى المخططات التكرارية أمر شخصي وغير موضوعي، وعرضة لسوء الاستعمال (يمكننا أن نتخيل أحد الباحثين وهم ينظر إلى توزيع مشوه تماماً ثم يقول لمساعده

"حسناً، يبدو التوزيع طبيعياً بالنسبة لي"، ويجيبه مساعده "فعلاً، إنه طبيعي"). إن ما نحتاجه هو اختبار موضوعي لإقرار فيما إذا كان توزيع ما طبيعياً أم لا. إن إحصائيات عدم التناظر والتدبب التي رأيناها سابقاً تخبرنا القليل عن الانحرافات عن الطبيعية، ولكن كل واحدة منها تتعامل مع سمة واحدة فقط من سمات اللاطبيعية. هناك طريقة أخرى للنظر إلى المشكلة وهي معرفة فيما إذا كان التوزيع بكامله منحرفاً عن توزيع طبيعي قابل للمقارنة. تقوم اختبارات Kolmogorov-Smirnov (انظر الشكل 13.3) و Shapiro-Wilk بذلك، فهي تقارن العلامات في العينة مع مجموعة من العلامات موزعة طبيعياً بنفس قيمة المتوسط والانحراف المعياري. إذا كان الاختبار بدون دلالة ($p>0.05$) فهذا يعني أن التوزيع للعينة لا يختلف بشكل كبير عن التوزيع الطبيعي (من المحتمل أن يكون طبيعياً). أما إذا كان الاختبار ذا دلالة أو مهماً ($p<0.05$) فهذا يعني أن التوزيع المدروس يختلف بشكل معتبر عن التوزيع الطبيعي (أي أنه غير طبيعي). تبدو هذه الاختبارات عظيمة، فمن خلال عملية سهلة يمكنها أن تخبرنا فيما إذا كانت العلامات موزعة طبيعياً أم لا. ولكنها محدودة للأسف، فعند التعامل مع العينات كبيرة الحجم يصبح من السهل الحصول على نتائج ذات دلالة من انحرافات صغيرة عن الطبيعية، ولذلك فإن اختباراً ذا دلالة لا يخبرنا بالضرورة فيما إذا كان الانحراف عن الطبيعية كافياً للتأثير على الإجرائيات الإحصائية التي نطبقها على البيانات. لذلك فإن علينا استخدام هذه الاختبارات بكل الوسائل، ولكن علينا أيضاً رسم البيانات ومحاولة اتخاذ قرار صحيح مبني على المعرفة حول حدود اللاطبيعية.

الشكل 13.3 Andrei Kolmogorov

1.5.3 تنفيذ اختبار Kolmogorov-Smirnov في SPSS

يمكن الوصول لاختبار Kolomogorov-Smirnov (والذي سندعوه من الآن فصاعداً اختبار K-S) عبر أمر القائمة Analyze ⇒ Descriptive Statistics ⇒ Explore... يوضح (الشكل 14.3) مربعات الحوار للتعليمة Explore. أدخل أولاً المتحولات التي تهتم بدراستها في الحيز المسمى Dependent List وذلك باختيارها في القسم الأيسر ونقلها بنقر زر السهم الموجود بين حيزي النص.

لنختر على سبيل المثال علامات الامتحان والمهارات الرياضية. من الممكن أيضاً اختيار معامل ما (أو متحول تجميع) يتم بواسطته فصل الخرج (فإذا اخترت المتحول uni ونقلته إلى حيز النص المسمى Factor List فإن برنامج SPSS سيعطي تحليلاً استكشافياً لكل مجموعة، بشكل شبيه لتعليمة فصل الملف Split File). إذا نقرت الزر ...Statistics سيظهر مربع حوار جديد، ولكن الخيارات الافتراضية جيدة (ستعطي قيم المتوسطات والانحرافات المعيارية وغيرها). أما الخيار الأهم فيمكننا الوصول إليه بنقر الزر ...Plots. اختر في مربع الحوار الناتج الخيار Normality plots with tests، حيث سيعطي كلاً من اختبار K-S وبعض المخططات البيانية التي تسمى مخططات Q-Q الطبيعية (Normal Q-Q plots) وذلك لجميع المتحولات المحددة. بشكل افتراضي، يقوم برنامج SPSS بإنتاج مخططات رسم الصندوق (مقسمة وفق المجموعات إذا تم تحديد معامل الفصل) وكذلك مخططات الساق والأوراق. انقر الزر Continue للعودة لمربع الحوار الرئيسي ثم انقر الزر OK لتنفيذ عملية التحليل.

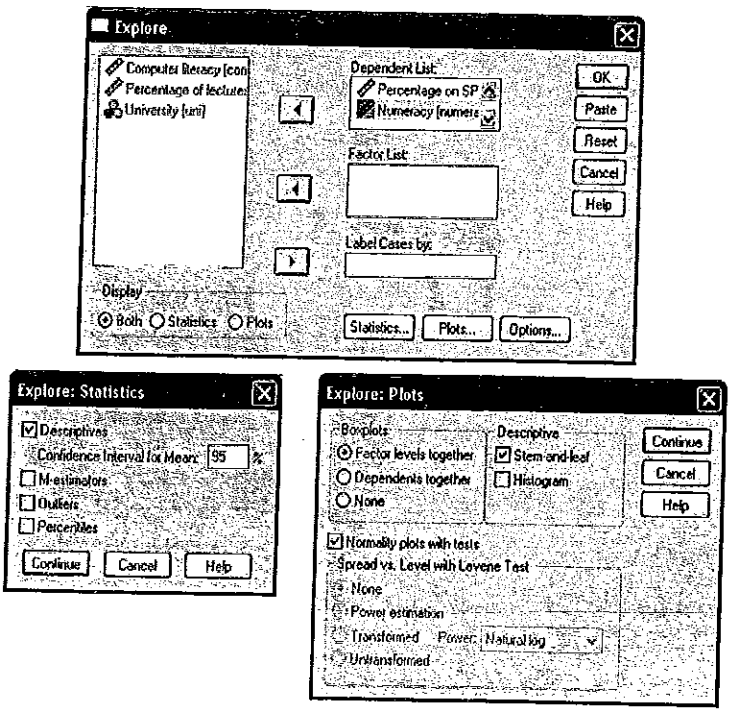

الشكل 14.3 مربعات الحوار للتعليمة Explore

2.5.3 الخرج من إجرائية explore

يحوي الجدول الأول الذي يعطيه SPSS الإحصائيات الوصفية (المتوسط وغيره) ويجب أن نحصل على نفس القيم التي حصلنا عليها عند استخدام إجرائية التكرارات. إن الجدول الأهم هو الجدول المتعلق باختبار K-S المبين في الشكل التالي:

Tests of Normality

	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Percentage on SPSS exam	.102	100	.012	.961	100	.005
Numeracy	.153	100	.000	.924	100	.000

a. Lilliefors Significance Correction

يتضمن هذا الجدول إحصائية الاختبار ذاتها، عدد درجات الحرية (df) الذي يجب أن يكون مساوياً لحجم العينة، وقيمة مستوى الدلالة للاختبار (Sig.). تذكر أن قيمة الدلالة الأقل من 0.05 تشير إلى انحراف عن الطبيعية. ونجد أنه بالنسبة لكل من علامات امتحان SPSS والمهارات الرياضية فإن اختبار K-S عالي الدلالة، مما يشير إلى أن كلا التوزيعان ليس طبيعياً. وهذه النتيجة تعكس ما وجدناه سابقاً من أن توزيع علامات امتحان SPSS كان ثنائي المنوال، بينما كان توزيع علامة المهارات الرياضية إيجابي الميلان. على كل حال، تؤكد هذه الاختبارات أن الانحرافات كانت مهمة أو ذات دلالة. وهذه النتيجة مهمة لأن المخططات التكرارية أخبرتنا بأن توزيعات العينة تحيد عن الطبيعي، ولكنها لم تخبرنا عن مقدار الانحراف لكي نعتبره هاماً. يتم ترميز إحصائية الاختبار لاختبار K-S بالحرف D، وبذلك يمكننا إعطاء النتائج بالطريقة التالية: D(df)=Statistic, p<value. فمن أجل علامات امتحان SPSS نكتب: p<0.05، D(100)=0.102، ومن أجل علامات المهارات الرياضية نكتب:p<0.001، D(100)=0.153، أي أن التوزيعين غير طبيعيين.

النقطة الأخيرة التي يجب أن نتذكرها عند النظر إلى علامات الامتحان كمجموعات منفصلة، فإن التوزيع يبدو طبيعياً تماماً، ولكن إذا سُئلنا عن اختبارات منفصلة لكل من الجامعتين (وذلك بوضع متحول التجميع uni في حيز النص Factor List لمربع الحوار Explore) فإن اختبار K-S قد لا يكون مهماً. في الحقيقة، إذا حاولت تنفيذ ذلك، فإنك ستحصل على الجدول المبين في الخرج 4.3 والذي يوضح أن النسب المئوية في علامات امتحان SPSS هي طبيعية ضمن المجموعتين (القيم في العمود Sig. هي أكبر من 0.05). إن ذلك هام، فإذا تضمن التحليل مقارنة المجموعات فإن التوزيع الإجمالي ليس مهماً، وإنما المهم هو التوزيع لكل مجموعة.

Tests of Normality

	University	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
Percentage on SPSS exam	Duncetown University	.106	50	.200*	.972	50	.283
	Sussex University	.073	50	.200*	.984	50	.715
Numeracy	Duncetown University	.183	50	.000	.941	50	.015
	Sussex University	.155	50	.004	.932	50	.007

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

الخرج 4.3

ينتج برنامج SPSS مخطط Q-Q الطبيعي لجميع المتحولات المحددة (انظر الشكل 15.3). يرسم مخطط Q-Q الطبيعي القيم التي تتوقع الحصول عليها إذا كان التوزيع طبيعياً (القيم المتوقعة (Expected values)) مقابل القيم الفعلية الموجودة في مجموعة البيانات (القيم المشاهدة (Observed values)). يتم تمثيل القيم المتوقعة بخط قطري مستقيم، بينما يتم تمثيل القيم المشاهدة بنقاط منفصلة. إذا كانت البيانات موزعة طبيعياً فإن القيم المشاهدة (النقاط المنفصلة) يجب أن تقع على طول الخط المستقيم، وهذا يعني أن القيم المشاهدة هي نفسها القيم التي تتوقع الحصول عليها من مجموعة بيانات موزعة طبيعياً. إن أي انحراف للنقاط عن الخط المستقيم يمثل انحرافاً عن الطبيعية. لذلك إذا بدا مخطط Q-Q الطبيعي كخط مستقيم تلتف حوله النقاط كالأفعى فهذا يعني وجود انحراف عن الطبيعية. وعندما يكون الخط مائلاً بشكل متناسق تحت الخط القطري أو مرتفعاً فوقه فهذا يعني أن التدبب يختلف عن التوزيع الطبيعي، وعندما يكون المنحني بشكل الحرف S فهذا يدل على مشكلة عدم تناظر.

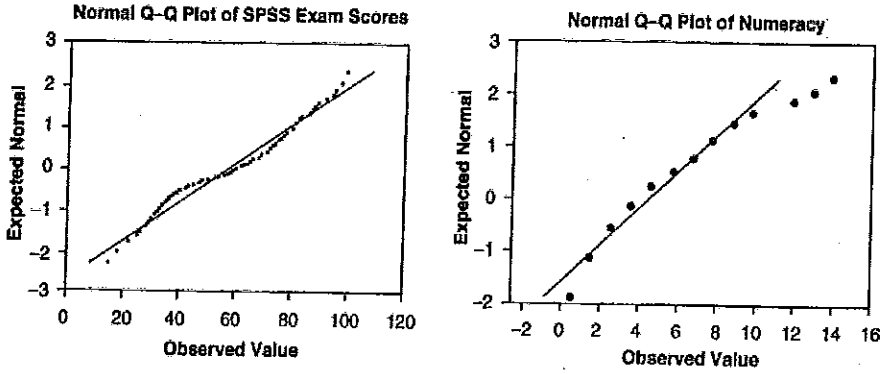

الشكل 15.3 مخططات Q-Q الطبيعية لعلامات امتحان SPSS و المهارات الرياضية

من أجل المتحولين اللذين تم تحليلهما، فإننا نعلم مسبقاً أن البيانات ليست طبيعية، وتؤكد هذه المخططات صحة ما لاحظناه سابقاً لأن النقاط تنحرف بشكل كبير عن الخط المستقيم. وهذا الانحراف هو أكبر من أجل علامات المهارات الرياضية، مما يتناغم مع القيمة الكبيرة للدلالة لهذا المتحول في اختبار K-S. إن انحرافاً مماثلاً عن الطبيعية يخبرنا بعدم إمكانية استخدامنا لاختبار بارامتري، وذلك لأن فرضية الطبيعية ليست محققة. وفي مثل هذه الظروف يمكننا التحول إلى الاختبارات اللابارامترية كوسيلة لاختبار الفرضيات التي نهتم بدراستها (انظر الفصل 4).

6.3 اختبار تجانس التباين

لقد ركزنا سابقاً على فرضية البيانات الموزعة طبيعياً، ولكننا أشرنا في بداية هذا الفصل إلى فرضية أخرى هي تجانس التباين (homogeneity of variance). وتعني هذه الفرضية أنه عند تدقيق

المستويات لمتحول معين، فإن التباين للمتحولات الأخرى يجب ألا يتغير. إذا قمت بتجميع مجموعات من البيانات فإن ذلك يعني أن التباين لمتحول أو متحولات النتيجة يجب أن يكون نفسه في كل مجموعة من هذه المجموعات. إذا جمعت بيانات مستمرة (كما في الحالات الترابطية)، فإن هذه الفرضية تعني أن التباين لمتحول ما يجب أن يبقى ثابتاً عند جميع مستويات المتحول الآخر. لنوضح ذلك بمثال. يهتم أخصائي السمع بآثار الحفلات الصاخبة على حاسة السمع عند الناس. لذلك قرر إرسال 10 أشخاص في جولة مع الفرقة الأكثر صخباً التي يعرفها Motörhead. سيحضر هؤلاء الأشخاص الحفلات التي ستقيمها الفرقة في المدن التالية: Brixton وBrighton وBristol وEdinburgh وNewcastle وCardiff وDublin، وبعد كل حفلة يقوم أخصائي السمع بقياس عدد الساعات بعد الحفلة التي يبقى الشخص فيها يسمع رنيناً في أذنيه.

يبين (الشكل 16.3) عدد الساعات بعد كل حفلة التي يبقى فيها الرنين في أذني كل شخص (تم تمثيل كل شخص بدائرة). تمثل الخطوط الأفقية العدد المتوسط للساعات التي يبقى فيها الرنين في الأذنين بعد كل حفلة، وتم توصيل قيم المتوسطات بخط كي يمكننا رؤية المنحى العام للبيانات. تذكّر أنه في كل حفلة، تمثل الدوائر العلامات التي تم حساب المتوسط منها. يمكننا الآن، وفي المخططين البيانيين، أن نشاهد ازدياد قيم المتوسطات مع حضور الأشخاص لحفلات أكثر. فبعد الحفلة الأولى، بقيت بعض الآذان ترن لحوالي 12 ساعة، ولكن بعد الحفلة الثانية بقيت ترن لمدة 15-20 ساعة، ومع انتهاء الحفلة الأخيرة في الجولة بقيت الآذان ترن لمدة 45-50 ساعة (يومين). إذاً هناك أثر تراكمي للحفلات على الرنين في الأذنين. وقد وجدنا هذا النمط في المخططين، والفارق بين المخططين لا يتعلق بقيم المتوسطات (فهي متساوية تقريباً)، ولكن بانتشار العلامات حول قيمة المتوسط. إذا نظرت إلى المخطط الأيسر فإن انتشار العلامات حول المتوسط بعد كل حفلة يبقى ذاته (العلامات متراكمة حول المتوسط بشكل مضغوط). بطريقة أخرى، إذا قسنا المسافة الشاقولية بين العلامة الأدنى والعلامة الأعلى بعد حفلة Brixton، ثم قسنا المسافة ذاتها لبقية الحفلات، فإن جميع هذه المسافات تكون متماثلة تقريباً. ومع ازدياد قيم المتوسط فإن انتشار علامات فقد السمع يبقى ذاته عند كل مستوى من متحول الحفلة (انتشار العلامات هو ذاته بعد حفلات Brixton وBrighton وBristol وEdinburgh وNewcastle وCardiff وDublin). وهذا ما نعنيه بتجانس التباين. يعرض المخطط الأيمن صورة مختلفة، فإذا نظرت إلى انتشار العلامات بعد حفلة Brixton، فإنك ترى أنها متراكمة حول المتوسط بشكل مضغوط (المسافة الشاقولية بين العلامة الأدنى والعلامة الأعلى صغيرة)، ولكن بعد حفلة Dublin (على سبيل المثال) فإن العلامات منتشرة بشكل واسع حول المتوسط (المسافة الشاقولية بين العلامة الأدنى والعلامة الأعلى كبيرة). وهذا مثال عن تنوع أو عدم تجانس التباين (heterogeneity of variance)، أي أنه عند بعض المستويات لمتحول الحفلة فإن تباين العلامات مختلف عن بقية المستويات (في هذه الحالة تكون المسافة الشاقولية بين العلامة الأدنى والعلامة الأعلى مختلفة بعد الحفلات المختلفة).

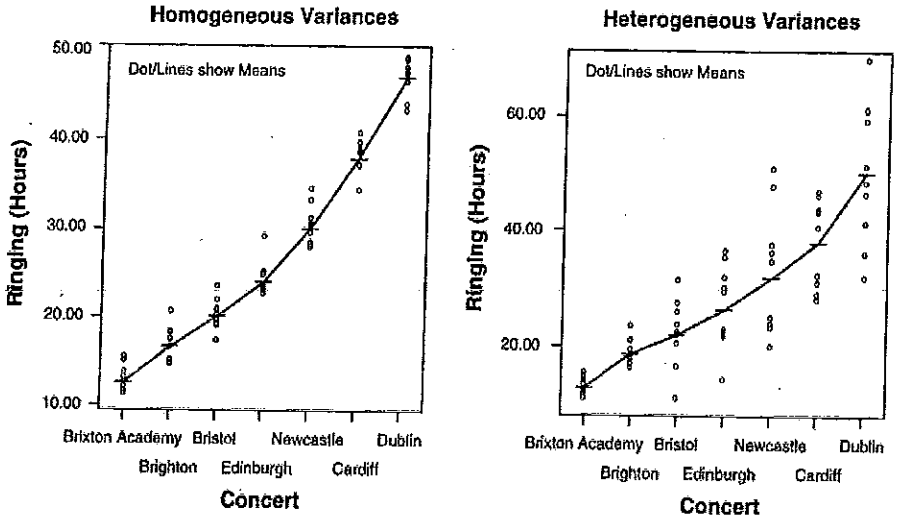

الشكل 16.3 المخططات البيانية التي توضح تجانس التباين (إلى اليسار) وتنوع التباين (إلى اليمين) للبيانات

بعد أن تعرفنا على معنى تجانس التباين، سننتقل لكيفية تنفيذ الاختبار من أجله. لبعض الإجرائيات الإحصائية طريقتها الوحيدة الخاصة بها للبحث عن تجانس التباين، ففي التحليل الارتباطي للتراجع نميل إلى استخدام المخططات البيانية (انظر الفقرة 7.8.5) ومن أجل مجموعات البيانات نلجأ لاستخدام اختبار يدعى اختبار Levene (Levene's test). يختبر اختبار Levene فرضية أن التباينات في المجموعات متساوية (أي أن الفرق بين التباينات يساوي الصفر). لذلك إذا كان اختبار Levene ذو دلالة عند $p \leq 0.05$ فيمكننا الاستنتاج بأن فرضية العدم غير صحيحة وأن التباينات مختلفة بشكل كبير، ولذلك فإن فرضية تجانس التباين لم تُحترم. إذا كان اختبار Levene بلا أهمية (أي أن $p > 0.05$) فعلينا أن نقبل فرضية العدم بأن الفرق بين التباينات يساوي الصفر، فالتباينات متساوية تقريباً ويمكن اعتماد الفرضية. ومع أنه يمكن اختيار هذا الاختبار كواحد من الخيارات في عدد من الاختبارات الإحصائية التي تتطلبه، فمن الممكن اختباره عند استكشاف البيانات (ونقول بشكل دقيق أنه من المفضل اختباره في هذه المرحلة بدلاً من الانتظار إلى مرحلة التحليل الأساسي).

وكما في حالة الاختبار K-S (وغيره من اختبارات الطبيعية) فعندما يكون حجم العينة كبيراً، فإن الفروق الصغيرة في تباينات المجموعة يمكن أن تعطي نتيجة مفادها أن اختبار Levene ذو دلالة (لأنه، كما رأينا في الفصل 1، قد تم البرهان على قوة الاختبار). هناك تحقق مضاعف يمكن تنفيذه وذلك بالنظر إلى نسبة التباين (variance ratio). وهذه النسبة هي نسبة التباينات بين المجموعة ذات التباين الأكبر والمجموعة ذات التباين الأصغر. لذلك إذا نظرت إلى التباينات في المجموعات المختلفة، فيمكنك البحث عن القيمة الأعلى ثم تقوم بقسمتها على القيمة الأصغر. إذا كانت نسبة التباينات (نتيجة القسمة) أقل من 2 فيمكنك بشكل مضمون افتراض تجانس التباين.

يمكننا الوصول لاختبار Levene باستخدام القائمة explore التي استخدمناها في الفقرة السابقة. من أجل هذا المثال، فإننا سنستخدم بيانات امتحان SPSS الذي استخدمناه في المثال السابق (الموجود في الملف SPSSExam.sav). بعد تحميل البيانات، نستخدم أمر القائمة Analyze ⇒ Descriptive Statistics ⇒ Explore... لفتح مربع الحوار المبين في الشكل 17.3. وللمحافظة على بساطة الأشياء فإننا ننظر إلى علامات امتحان SPSS وعلامات المهارات الرياضية في هذا الملف، لذلك ننقل هذين المتحولين من اللائحة في القسم الأيسر من مربع الحوار إلى حيز النص المسمى Dependent List بنقر زر السهم بجانب هذا الحيز. وبما أننا نريد فصل الخرج بمتحول التجميع لمقارنة التباينات، فإننا نختار المتحول uni وننقله إلى حيز النص المسمى Factor List بنقر الزر المناسب. ننقر بعد ذلك الزر Plots... لفتح مربع الحوار الآخر في (الشكل 17.3). للوصول إلى اختبار Levene علينا تحديد أحد الخيارات في حيز الخيارات المسمى Spread vs. Level with Levene Test. إذا نقرنا الخيار Untransformed فإن اختبار Levene سيتم تنفيذه على البيانات غير المعالجة (مكان جيد للبدء). على كل حال، إذا اتضح أن التباينات كانت غير متساوية فيمكنك تصحيح هذا التفاوت باستخدام أحد التحويلات التي ناقشناها سابقاً في هذا الفصل. في مربع الحوار ذاته، إذا نقرت الخيار Transformed فستصبح القائمة المنسدلة فعّالة (انظر الشكل 17.3)، وإذا اخترنا أحد التحويلات من هذه القائمة ونفذنا عملية التحليل فإن برنامج SPSS سيقوم بحساب اختبار Levene كما لو أننا قمنا بتحويل البيانات باستخدام تلك الطريقة. ويمكن لهذا الخيار توفير الوقت اللازم لتجريب التحويلات المختلفة. لذلك، وللبدء ننقر الخيار Untransformed وننفذ عملية التحليل، ثم نعود إلى مربع الحوار Explore: Plots ونعيد تنفيذ عملية التحليل بعد تحديد الخيار Transformed (يمكن اختيار التحويل اللوغاريتمي كبداية). عند الانتهاء من استخدام مربع الحوار، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي Explore ثم انقر الزر OK لتنفيذ عملية التحليل.

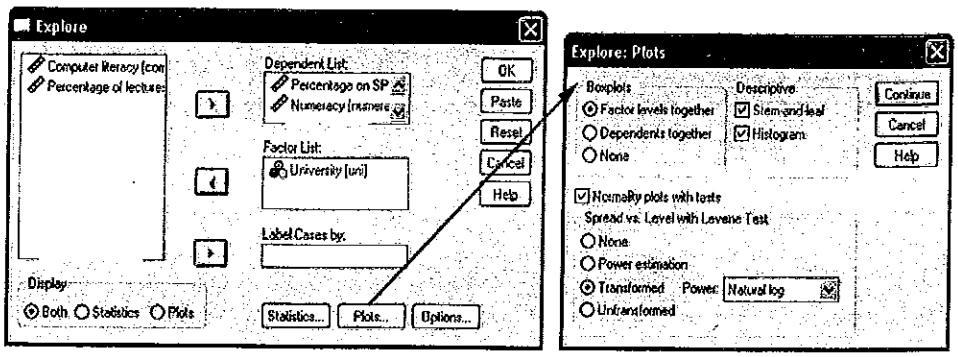

الشكل 17.3 استكشاف مجموعات من البيانات والحصول على اختبار Levene

يعرض الخرج 5.3 جدول اختبار Levene عند تنفيذ التحليل بعد تحديد الخيار Untransformed، ثم عند تنفيذ التحليل بعد تحديد الخيار Transformed واختيار التحويل اللوغاريتمي الطبيعي Natural log.

Test of Homogeneity of Variance

		Levene Statistic	df1	df2	Sig.
Percentage on SPSS exam	Based on Mean	2.584	1	98	.111
	Based on Median	2.089	1	98	.152
	Based on Median and with adjusted df	2.089	1	94.024	.152
	Based on trimmed mean	2.523	1	98	.115
Numeracy	Based on Mean	7.368	1	98	.008
	Based on Median	5.366	1	98	.023
	Based on Median and with adjusted df	5.366	1	83.920	.023
	Based on trimmed mean	6.766	1	98	.011

Test of Homogeneity of Variance

		Levene Statistic	df1	df2	Sig.
Percentage on SPSS exam	Based on Mean	25.055	1	98	.000
	Based on Median	24.960	1	98	.000
	Based on Median and with adjusted df	24.960	1	64.454	.000
	Based on trimmed mean	25.284	1	98	.000
Numeracy	Based on Mean	.211	1	98	.647
	Based on Median	.279	1	98	.598
	Based on Median and with adjusted df	.279	1	97.664	.598
	Based on trimmed mean	.238	1	98	.627

الخرج 5.3

يجب قراءة الإحصائيات المعتمدة على المتوسط. فمن أجل البيانات غير المعالجة، يبدو أن اختبار Levene بدون دلالة من أجل علامات امتحان SPSS (القيم في العمود المسمى .Sig هي أكبر من 0.05) مما يدل على أن التباينات ليست مختلفة بشكل كبير (أي أنها متشابهة، وفرضية تجانس التباين مقبولة). أما من أجل علامات المهارات الرياضية فإن اختبار Levene ذو دلالة (القيم في العمود المسمى .Sig هي أصغر من 0.05) مما يدل على أن التباينات مختلفة بشكل كبير (أي أنها ليست متساوية، وفرضية تجانس التباين غير مقبولة). وهذا يعطينا سبباً وجيهاً لتجريب تحويل ما على علامات المهارات الرياضية. لنر ماذا يحدث عندما نجرب ذلك. من أجل العلامات المحوَّلة باللوغاريتم الطبيعي، تصبح المشكلة معكوسة، فاختبار Levene يصبح ذا دلالة من أجل علامات امتحان SPSS (القيم في العمود المسمى .Sig هي أصغر من 0.05)، ولكنه لم يعد كذلك بالنسبة

لعلامات المهارات الرياضية (القيم في العمود المسمى .Sig هي أكبر من 0.05). في هذه الحالة، ونظراً لأننا نقارن الجامعتين من حيث علامات المهارات الرياضية وعلامات امتحان SPSS بشكل منفصل، فإن علينا تحويل علامات المهارات الرياضية، وعدم تحويل علامات امتحان SPSS. يمكن ترميز اختبار Levene بالحرف F مع وجود عددين مختلفين من درجات الحرية. وهكذا يمكن أن تكون الصيغة العامة بالشكل .Sig، F(df1,df2)=value. فمن أجل علامات امتحان SPSS يمكننا القول بأن التباينات متساوية ns، F(1,98)=2.584، أما بالنسبة لعلامات المهارات الرياضية فإن التباينات مختلفة بشكل واضح P<0.01، F(1,98)=7.368. حاول كتابة النتائج للعلامات المحوَّلة باللوغاريتم الطبيعي.

7.3 رسم قيم المتوسطات

بعد أن أنجزنا استكشاف البيانات، فقد ترغب برسم بعض المخططات البيانية لقيم المتوسطات. تعرض هذه الفقرة كيفية استخدام بعض إجرائيات الرسم في برنامج SPSS لإنشاء مخططات قيم المتوسطات (وهذا مفيد خاصة عند إعداد مراجعة للبيانات أو تقديمها للآخرين). وتعتمد طريقة إعداد هذه المخططات في برنامج SPSS بشكل كبير على كيفية جمع البيانات (هل تستخدم أشخاصاً مختلفين، أم أنك تستخدم نفس الأشخاص لقياس مستويات مختلفة من متحول ما). ولكي نبدأ، تخيل أن مدير شركة سينمائية كان مهتماً بمعرفة فيما إذا كان هناك شيء يدعى chick flick (فيلم يستهوي النساء أكثر من الرجال). لذلك قام بإحضار 20 رجلاً و 20 امرأة، وعرض على نصف العينة من كل جنس فيلماً يُفترض أن يكون chick flick (كفيلم Bridget Jones' Diary)، وعرض على النصف الآخر من كل عينة فيلماً غير مصنف في فئة chick flick (كفيلم Memento). وقام في جميع الحالات بقياس الإثارة الفيزيولوجية كمؤشر على استمتاعهم بالفيلم. يحوي الملف ChickFlick.sav على القرص المضغوط المرفق البيانات الخاصة بهذا المثال. حمّل هذا الملف حالاً ولنبدأ العمل.

لرسم مخطط لقيم المتوسطات، سنستخدم المخططات التفاعلية في برنامج SPSS. الميزة الأساسية لهذه المخططات أنها تسمح بوضع أعمدة الخطأ على المخطط البياني (انظر الفصل 8) ويمكن تحديثها حتى إذا كان ملف البيانات مغلقاً (انظر المربع 4.3). يمكنك أيضاً رسم المخططات البيانية باستخدام إجرائيات الرسم غير التفاعلية في برنامج SPSS، ولكن حرصاً منا على توفير الورق (وبالتالي الأشجار) فقد قمنا بوضع طريقة العمل في الملف Answers(Chapter 3).pdf على القرص المضغوط المرفق وفي الفصل 4. لنبدأ بمخطط بياني بسيط، اختر أولاً أمر القائمة Graphs ⇒ Interactive ⇒ Bar... لتفعيل مربع الحوار المبين في الشكل 18.3. لاحظ أن هناك تمثيلاً رمزياً للمحاور الأفقية والشاقولية مع وجود حيز في كل منهما لإدخال اسم المتحول من اللائحة في القسم الأيسر من مربع الحوار. يجب أن يكون المتحول على المحور الشاقولي y-axis هو المتحول

التابع، أو المتحول الذي قمت بقياسه، أو بشكل أبسط الشيء الذي تريد إظهار قيمة المتوسط له. في هذا المثال سيكون المتحول arousal، لذلك ينبغي عليك اختياره من اللائحة في القسم الأيسر ونقله إلى الحيز على المحور الشاقولي. أما المتحول على المحور الأفقي x-axis فيجب أن يكون المتحول الذي نفصل على أساسه بيانات الإثارة (arousal). وللمحافظة على البساطة سنرسم قيم المتوسطات من أجل الفيلمين. ولذلك نختار المتحول film من اللائحة في القسم الأيسر وننقله إلى الحيز على المحور الأفقي (ولذلك فمن الضروري أن يكون نوع المتحول اسمياً nominal). هناك قسم في الجزء السفلي من حيز الحوار يحمل التسمية ...Bars represents ويصبح هذا القسم فعّالاً بعد تحديد المتحول على المحور الشاقولي (ولذلك يقال: تمثل الأعمدة قيم الإثارة Bars Represent Arousal لأننا حددنا المتحول arousal على المحور الشاقولي). بشكل افتراضي، ستمثل الأعمدة قيمة المتوسط (وهذا ما نريده بالضبط)، ولكن إذا نقرت زر السهم في طرف القائمة المنسدلة فإنك ترى أن بإمكانك رسم الإحصائيات الوصفية الأخرى كمؤشرات المنحى المركزي (كالوسط والمنوال)، وقياسات الانتشار (كالتباين والانحراف المعياري)، وقياسات عدم التناظر والتدبب.

إذا أردت إضافة أعمدة الخطأ (انظر الفقرة 7.3)، فيجب عليك نقر صفحة التبويب Error Bars في القسم العلوي من مربع الحوار ثم تحديد الخيار Display Error Bars. يقوم برنامج SPSS بشكل افتراضي بإظهار مجال الثقة للمتوسط (انظر الفقرة 2.6.1)، ولكن إذا اخترت القائمة المنسدلة بنقر الزر الموجود بجانب التسمية Units فيمكنك اختيار رسم الانحراف المعياري (انظر الفقرة 1.4.1) أو الخطأ المعياري (انظر الفقرة 6.1) للمتوسط. وأخيراً، فإن برنامج SPSS يرسم أعمدة الخطأ التي تخترق جانبي المتوسط. ولكن يمكنك اختيار طريقة عرض مختلفة وذلك بنقر أحد الأزرار الأربعة في القسم السفلي من مربع الحوار (تحت التسمية Direction).

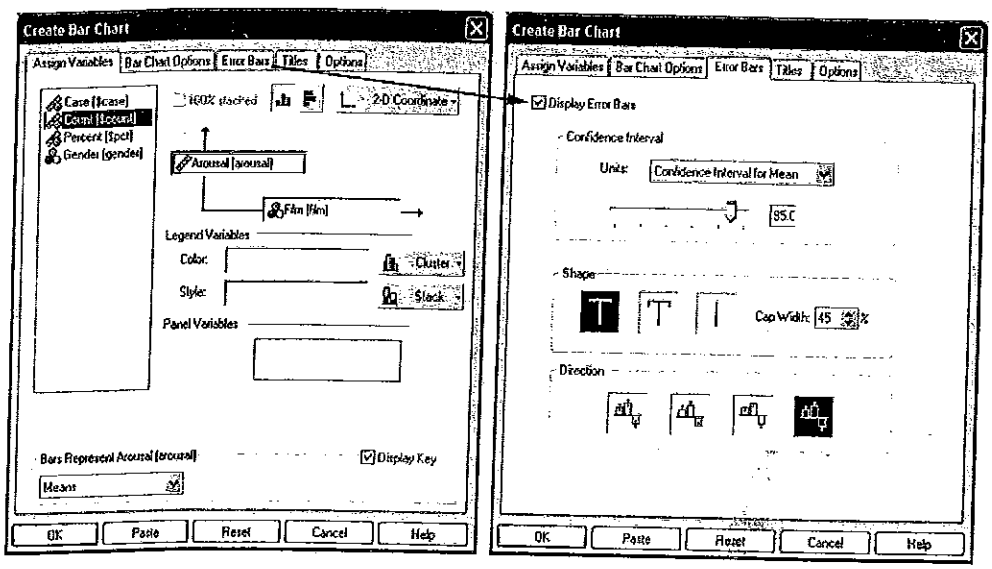

الشكل 18.3 مربعات الحوار لرسم مخطط الأعمدة التفاعلي مع أعمدة الخطأ

يعرض (الشكل 19.3) مخطط الأعمدة الناتج. ويبين المتوسط (ومجال الثقة لهذه المتوسطات). ويوضح هذا المخطط البياني أن الأشخاص قد تأثروا بفيلم Memento أكثر من تأثرهم بفيلم Bridget Jones' Diary.

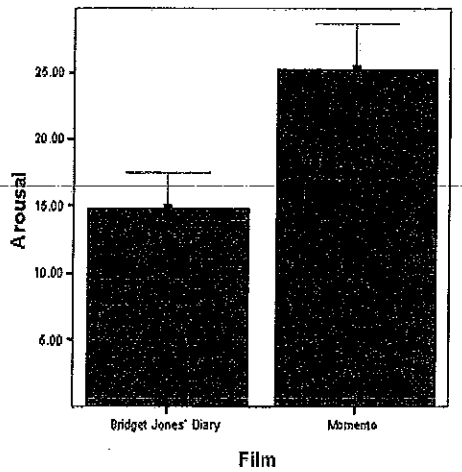

الشكل 19.3 مخطط الأعمدة لمتوسط الإثارة لكل من الفيلمين

على كل حال، لقد أردنا منذ البداية البحث عن الآثار حسب الجنس، وكما نرى فإن هذا المخطط لا يفيدنا بشيء عما نريد معرفته. إن المخطط الذي نريده هو المخطط المجمع (clustered graph) ويمكن إنشاؤه بسهولة وذلك باستخدام مربع الحوار السابق (انظر الشكل 18.3)، مع تحديد متحول آخر (في هذه الحالة سيكون gender) في حيز النص المسمى Color تحت التسمية Legend Variables. اسحب المتحول gender من اللائحة في القسم الأيسر إلى حيز النص Color. يبدو مربع الحوار بشكله النهائي كما في (الشكل 20.3)، أما مخطط الأعمدة الناتج فيظهر في (الشكل 21.3). يعرض هذا المخطط معلومات أكثر، فيدلنا كما فعل المخطط السابق على أن الإثارة الكلية لفيلم Momento هي أعلى من فيلم Bridget Jones' Diary، ولكنه يفصّل هذه النتائج حسب الجنس. لننظر أولاً على متوسط الإثارة لفيلم Bridget Jones' Diary، ويبدو جلياً أن الذكور كانوا أكثر تأثراً من الإناث خلال هذا الفيلم. وهذا يدل على استمتاعهم بهذا الفيلم أكثر من الإناث. وفي المقابل، فإن مستويات الإثارة عند الذكور والإناث كانت متقاربة خلال فيلم Momento. وهذه النتيجة تعارض فكرة chick flick، حيث يبدو عملياً أن الرجال يستمتعون بأفلام chick flick أكثر من النساء.

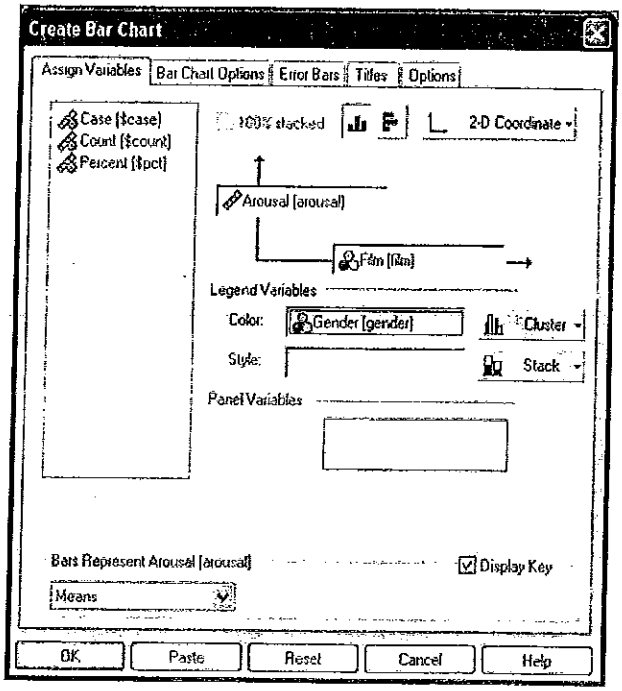

الشكل 20.3 مربع الحوار لإنشاء مخطط أعمدة مجمع بشكله النهائي

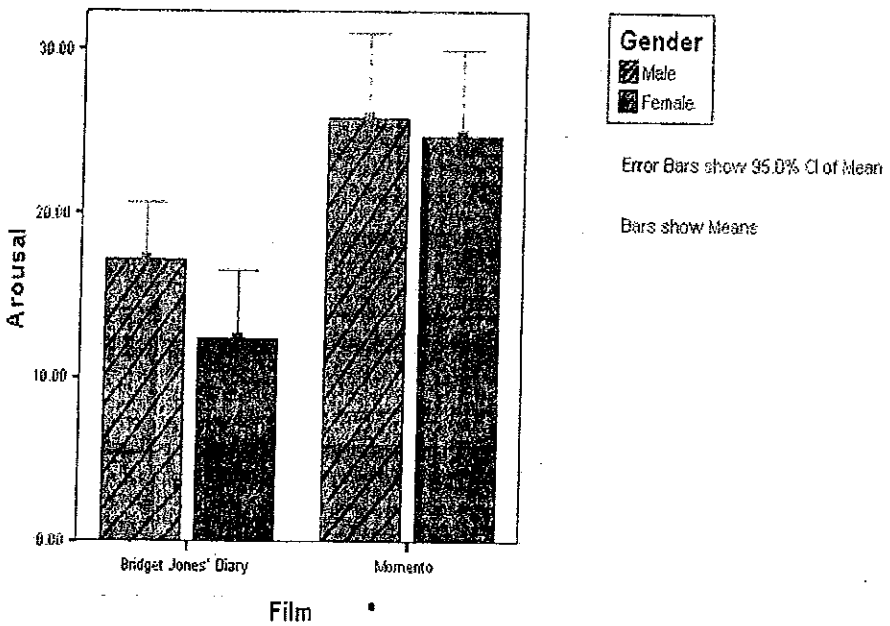

الشكل 21.3 يظهر مخطط الأعمدة المجمع متوسط الإثارة خلال الفيلمين لكل من الذكور والإناث

يمكنك تحرير معظم السمات للمخطط البياني وذلك بنقر المخطط نقرة مزدوجة ثم نقر الشيء الذي تريد تعديله. يمكننا تغيير لون الأعمدة وتسميات المحاور والمقياس لكل من المحورين وغيرها. يمكنك أيضاً تنفيذ بعض الأعمال الأخرى كجعل الأعمدة ثلاثية الأبعاد. ولكن استخدام الإظهار ثلاثي الأبعاد في هذا المثال لا يفيد بشيء سوى بتعقيد قراءتها.

المربع 4.3 جعل المخططات التفاعلية تفاعلية

إن الفائدة الكبرى لاستخدام المخططات التفاعلية في برنامج SPSS (مقارنة بالمخططات غير التفاعلية) أنه يمكن تحديث المخططات حتى إذا كان ملف البيانات مغلقاً. ولكي يتم ذلك، يجب تفعيل الإمكانية التفاعلية. استخدم أمر القائمة Edit ⇒ Options... للوصول إلى مربع الحوار Options لضبط الخيارات، حيث تجد صفحة التبويب Interactive. انقر صفحة التبويب السابقة وانقر الخيار Save data with the chart ليتم حفظ البيانات مع المخطط البياني. بذلك تصبح المخططات التفاعلية تفاعلية. إذا استخدمت ملفات بيانات كبيرة فقد تجد أنه من الأفضل إبطال هذا الخيار وإعادة رسم المخطط عند تحديث البيانات.

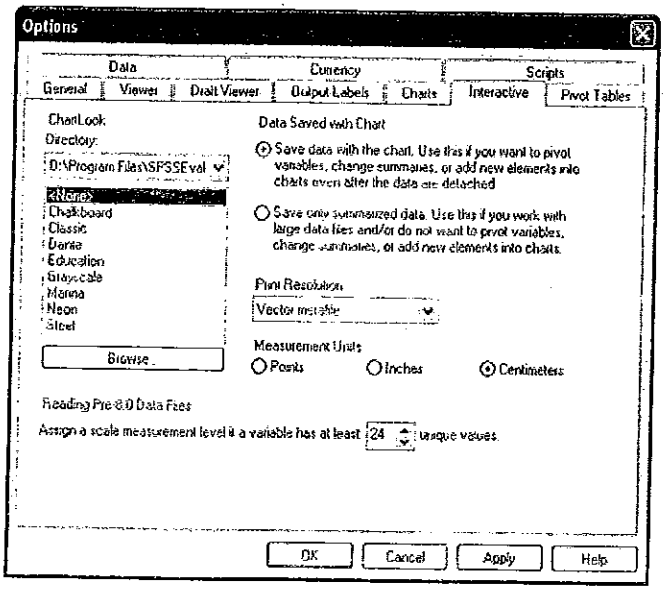

8.3 ما الذي اكتشفناه عن الإحصاء؟

تم في هذا الفصل تغطية مجموعة من المواضيع بشكل سريع جداً. لقد أوضحنا أهمية تدقيق البيانات بشكل صحيح قبل البدء بالعمليات الإحصائية الرئيسية. وعند البدء يجب النظر إلى توزيع البيانات ومحاولة اكتشاف أية أخطاء في إدخال البيانات، أو وجود قيم منعزلة. إذا لم يكن التوزيع طبيعياً فيجب البحث في إمكانية تحويل البيانات لتصحيح المشكلة أو البحث في استبدال القيم المنعزلة. إذا

كنت تنظر إلى البيانات التي تقارن المجموعات المختلفة فانظر عندئذ إلى التوزيعات ضمن كل مجموعة. يمكننا أيضاً تطبيق الاختبارات الإحصائية لمعرفة فيما إذا كانت البيانات طبيعية (اختبار Kolmogorov-Smirnov)، والنظر إلى المخططات البيانية الأخرى كمخطط Q-Q. كما اكتشفنا في هذا الفصل بعض استخدامات التعليمة transform والتعليمة split file في برنامج SPSS. وأخيراً تعرفنا بشكل مختصر على كيفية رسم مخططات قيم المتوسطات باستخدام المخططات التفاعلية.

9.3 المصطلحات الأساسية التي اكتشفناها

ثنائي المنوال	(Bimodal)
رسم الصندوق	(Boxplot)
تجانس التباين	(Homogeneity of variance)
الاستقلال	(Independence)
المجال بين الربعيين الحديين	(Interquartile range)
اختبار K-S	(Kolmogorov-Smirnov test)
اختبار Levene	(Levene's test)
الوسط	(Median)
متعدد المنوال	(Multimodal)
بيانات موزعة طبيعياً	(Normally distributed data)
قيمة منعزلة	(Outlier)
اختبار بارامتري	(Parametric test)
اختبار Shapiro-Wilk	(Shapiro-Wilk test)
التحويل	(Transformation)
نسبة التباين	(Variance ratio)

10.3 مهمات يجب إنجازها

- باستخدام البيانات في الفصل 2 (التي كان من المفترض أن تحفظها، وإلا فإن عليك إدخالها مجدداً من الجدول 1.2) ارسم بعض المخططات البيانية لمتوسط عدد الأصدقاء، واستهلاك الكحول، والدخل السنوي، ومستوى العصبية لكل من الطلاب والمحاضرين. مَن لديه أصدقاء أكثر، ومَن يشرب أكثر، ومَن لديه دخل أكبر، ومَن هو الأكثر عصبية؟

- باستخدام ملف البيانات ChickFlick.sav، تحقق من التوزيعات لكل من الفيلمين (بإهمال الجنس)، وهل هي موزعة طبيعياً؟
- باستخدام ملف البيانات SPSSExam.sav (تذكر أن علامات المهارات الرياضية تبدو إيجابية الميلان، انظر الشكل 10.3)، استخدم أحد التحويلات التي تم شرحها في هذا الفصل لتحويل هذه البيانات، هل تصبح البيانات طبيعية؟

يمكن العثور على بعض الأجوبة المختصرة في الملف Answers(Chapter3).pdf على القرص المضغوط المرفق.

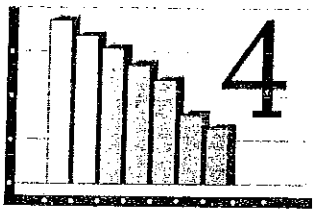

الارتباط

1.4 بماذا يخبرنا هذا الفصل

يهتم الباحثون غالباً بمعرفة العلاقة بين متحولين أو أكثر، وذلك في حال وجودها. والارتباط هو مقياس للعلاقة الخطية بين المتحولات. فعلى سبيل المثال قد أكون مهتماً بمعرفة وجود علاقة بين كمية الوقت التي يصرفها شخص ما في قراءة هذا الكتاب والمعرفة التي يحصل عليها في علم الإحصاء وبرنامج SPSS. هناك عدة أشكال يمكن أن تربط بين هذين المتحولين:

- ارتباط طردي أو إيجابي، ويعني أنه مع زيادة الوقت الذي يمضيه شخص ما في قراءة هذا الكتاب يزداد فهمه للإحصاء ولبرنامج SPSS.
- لا يوجد ارتباط بين المتحولين، ويعني أن فهم الشخص لعلم الإحصاء ولبرنامج SPSS يبقى على حاله مهما كان الوقت الذي يقضيه في قراءة هذا الكتاب.
- ارتباط عكسي أو سلبي، ويعني أن كلما قضى الشخص وقتاً أطول في قراءة هذا الكتاب، ساءت معرفته وفهمه لعلم الإحصاء ولبرنامج SPSS.

كيف يمكننا أن نعرف بوجود ارتباط بين متحولين؟ يبحث هذا الفصل أولاً في كيفية التعبير عن العلاقات بين المتحولات إحصائياً وذلك بالنظر إلى معيارين: التباين المشترك (covariance) ومعامل الارتباط (correlation coefficient). ننتقل بعد ذلك للبحث في كيفية تمثيل العلاقات بيانياً، وذلك قبل اكتشاف كيفية تنفيذ الارتباطات في SPSS وتفسيرها. وينتهي الفصل بالبحث في القياسات الأكثر تعقيداً للعلاقات، بحيث تكون تمهيداً للفصل الخاص بالتراجع المتعدد.

2.4 كيف نقيس العلاقات

1.2.4 جولة في عالم التباين المشترك

إن أبسط طريقة للبحث فيما إذا كان متحولان مرتبطين هي معرفة فيما إذا كان يتغيران معاً. ولفهم معنى التباين المشترك (covariance)، يجب أن نعود أولاً إلى مفهوم التباين (variance) الذي صادفناه في الفصل 1. تذكّر أن التباين لمتحول واحد يمثل المقدار الوسطي لتغير البيانات عن قيمة

المتوسط. وعددياً يمكن وصف ذلك بالعلاقة التالية:

$$\text{variance } (s^2) = \frac{\Sigma(x_i - \bar{x})^2}{N-1} = \frac{\Sigma(x_i - \bar{x})(x_i - \bar{x})}{N-1} \qquad (1.4)$$

يمثل $\bar{x}$ متوسط العينة، و x_i نقطة البيانات، و N عدد النقاط المشاهدة (انظر الفقرة 1.4.1). إذا كنا مهتمين بمعرفة فيما إذا كان متحولان مرتبطين، فإننا نهتم بمعرفة إذا كانت تغيرات أحدهما تُقابل بتغيرات مشابهة في المتحول الآخر. ولذلك عندما يبتعد أحد المتحولين عن قيمته المتوسطة فإننا نتوقع أن ينحرف المتحول الآخر عن قيمته المتوسطة بصورة مشابهة. ولتوضيح ما نقصده، تخيل أننا أخذنا 5 أشخاص وعرضنا عليهم عدداً معيناً من الإعلانات الترويجية لبعض أنواع الحلويات، ثم قسنا عدد علب الحلويات التي اشتراها كل منهم خلال الأسبوع اللاحق. يوضح (الجدول 1.4) هذه البيانات مع قيمة المتوسط والانحراف المعياري لكل من المتحولين.

	1	2	3	4	5	المتوسط	الانحراف المعياري s
عدد الاعلانات المشاهدة	5	4	4	6	8	5.4	1.67
عدد العلب المشتراة	8	9	10	13	15	11.0	2.92

الجدول 1.4

إذا كانت هناك علاقة بين هذين المتحولين، فإنه عند ابتعاد أحدهما عن قيمته المتوسطة، يجب أن ينحرف المتحول الآخر عن قيمته المتوسطة بنفس الاتجاه أو بالاتجاه المعاكس مباشرة. يبين الشكل 1.4 البيانات لكل مشترك (تمثل المربعات عدد العلب المشتراة، بينما تمثل الدوائر عدد الإعلانات المشاهدة)، ويمثل الخط المتقطع العدد الوسطي للعلب المشتراة، أما الخط المستمر فيمثل العدد المتوسط للإعلانات المشاهدة. تمثل الخطوط الشاقولية الفروق بين القيم المشاهدة والمتوسط للمتحول المقصود. إن أول ما يمكن ملاحظته في الشكل 1.4 أن هناك نمطاً متماثلاً للفروق لكلا المتحولين. بالنسبة للمشتركين الثلاثة الأوائل فإن القيم المشاهدة أدنى من المتوسط لكلا المتحولين، وبالنسبة للمشتركَين الباقيين فإن القيم المشاهدة أعلى من المتوسط لكلا المتحولين. إن هذا النمط دالّ على العلاقة المحتملة بين المتحولين (لأنه كما يبدو إذا كانت العلامة لشخص ما أدنى من المتوسط لأحد المتحولين فإن علامته ستكون أدنى من المتوسط بالنسبة للمتحول الآخر).

كيف يمكننا إذاً حساب التشابه الدقيق بين نمط الفروق للمتحولين الممثلين في الشكل 1.4؟ هناك إمكانية لحساب المقدار الكلي للفرق، ولكننا سنصل لنفس المشكلة التي صادفناها في حالة المتحول الوحيد (انظر الفقرة 1.4.1). وإذا قمنا بإضافة الفروق فإننا سنصل لصورة بسيطة عن العلاقة بين المتحولين. في حالة المتحول الوحيد، قمنا بتربيع الفروق بهدف إلغاء مشكلة الفروق السالبة والموجبة التي تلغي بعضها البعض. أما في حالة وجود متحولين، فبدلاً من تربيع كل من الفروق يمكننا ضرب الفرق لأحد المتحولين بالفرق المقابل للمتحول الآخر. إذا كان كل من الخطأين

موجباً أو سالباً فإن ذلك يعطي قيمة موجبة (مما يدل على أن الأخطاء تقع بجهة واحدة)، ولكن إذا كان أحد الأخطاء موجباً و الآخر سالباً فإن نتيجة الجداء ستكون سالبة (مما يدل على أن الأخطاء تقع بجهات متعاكسة).

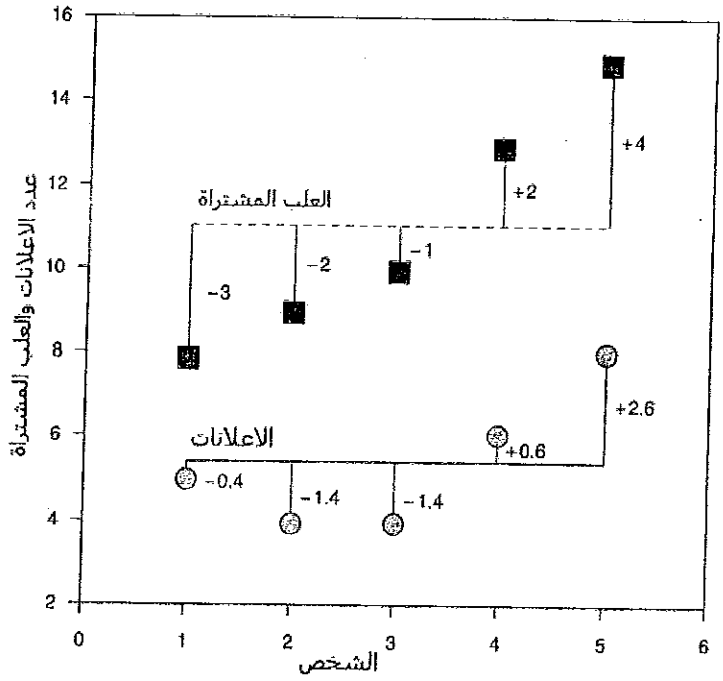

الشكل 1.4 الإظهار البياني للفروق بين البيانات المشاهدة والمتوسط لكل من المتحولين

عندما نقوم بضرب الفروق لأحد المتحولين بالفروق المقابلة للمتحول الآخر فإننا نحصل على ما يسمى بانحرافات الجداء المتصالب (cross-product deviations). وكما في حالة التباين، إذا أردنا القيمة المتوسطة للفروق المركبة للمتحولين فيجب علينا التقسيم على عدد النقاط المشاهدة (وعملياً نقسم على N-1). ويعرف متوسط المجموع للفروق المركبة باسم التباين المشترك (covariance). يمكننا كتابة هذا المتوسط بشكل علاقة كما يلي:

$$\text{cov}(x, y) = \frac{\Sigma(x_i - \bar{x})(y_i - \bar{y})}{N - 1}$$

نلاحظ أن هذه المعادلة شبيهة بمعادلة التباين ولكن بدلاً من تربيع الفروق نقوم بضرب الفروق للمتحول الأول بمقابلاتها للمتحول الثاني. فمن أجل البيانات في الجدول 1.4 ومن الشكل 1.4 فإننا نصل إلى القيمة التالية:

$$\text{cov}(x,y) = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{N-1}$$
$$= \frac{(-0.4)(-3) + (-1.4)(-2) + (-1.4)(-1) + (0.6)(2) + (2.6)(4)}{5-1} \qquad (2.4)$$
$$= 4.25$$

يسمح حساب التباين المشترك بتقييم فيما إذا كان متحولان مرتبطين ببعضهما البعض. وتشير القيمة الموجبة للتباين المشترك إلى أن انحراف أحد المتحولين عن قيمة المتوسط يعني انحراف المتحول الآخر عن قيمته المتوسطة بنفس الاتجاه. أما القيمة السالبة فتدل على أن انحراف أحد المتحولين عن قيمة المتوسط باتجاه ما (كالزيادة مثلاً) يعني انحراف المتحول الآخر عن قيمته المتوسطة بالاتجاه المعاكس (النقصان).

ولكن استخدام التباين المشترك كمقياس للعلاقة بين المتحولات يطرح مشكلة تتمثل باعتماده على وحدات القياس المستخدمة. ولذلك فإنه مقياس غير معياري. فعلى سبيل المثال، إذا استخدمنا البيانات السابقة وافترضنا أنها تمثل متحولين يقاس كل منهما بالميل فإن التباين المشترك سيكون 4.25 (كما تم حسابه سابقاً). ولكن إذا حوّلنا هذه البيانات إلى الكيلومترات (وذلك بضرب جميع الأرقام بالمقدار 1.609) وأعدنا حساب قيمة التباين المشترك فإننا نجد أنها أصبحت تساوي 11. ويعتبر هذا الاعتماد على وحدات القياس مشكلة لأن ذلك يعني أنه لا يمكننا مقارنة التباين المشترك بطريقة موضوعية، لذلك لا يمكننا أن نحدد فيما إذا كانت قيمته كبيرة أو صغيرة مقارنة مع مجموعة بيانات أخرى ما لم تستخدم مجموعتا البيانات وحدات القياس ذاتها.

2.2.4 التوحيد القياسي ومعامل الارتباط

للتغلب على مشكلة الاعتماد على وحدات القياس يجب علينا تحويل التباين المشترك إلى مجموعة قياسية من الوحدات. تدعى هذه العملية بالتوحيد القياسي (Standardization). إن الشكل الأساسي للتوحيد القياسي يتطلب أن تستخدم جميع الاختبارات نفس المجموعة من وحدات القياس (كالمتر مثلاً) وبذلك يمكن مقارنة جميع النتائج مع بعضها البعض بسهولة. ولكن ماذا يحدث إذا أردنا قياس وجهات النظر أو المواقف، سيكون من الصعب قياسها بالمتر. لذلك فإننا نحتاج لوحدة قياس يمكن تحويل جميع وحدات القياس إليها. إن وحدة القياس التي سنستخدمها هي الانحراف المعياري (standard deviation). لقد مررنا بهذا المقياس في الفقرة 1.4.1، ورأينا أنه كالتباين، مقياس للانحراف الوسطي عن المتوسط. إذا قسمنا أي بعد عن المتوسط على الانحراف المعياري فإننا نحصل على ذلك البعد مقدراً بالانحراف المعياري. فعلى سبيل المثال، من أجل البيانات في الجدول 1.4 تبلغ قيمة الانحراف المعياري لعدد علب الحلوى المشتراة 2.92. وفي الشكل 1.4 وجدنا أن القيمة المشاهدة للمشترك الأول كانت أقل من المتوسط 3 علب (أي أن هناك خطأ بمقدار 3- علبة حلوى). إذا قسمنا هذا الانحراف على قيمة الانحراف المعياري (القريبة من 3) فإننا نحصل القيمة 1-.

وهذا يدل على أن الفرق بين علامة المشترك الأول والمتوسط هي 1- انحرافاً معيارياً. لذلك يمكننا التعبير عن الانحراف لمشترك ما عن قيمة المتوسط بوحدات قياسية وذلك بتقسيم الانحراف المراقب على الانحراف المعياري.

وينتج عن هذا المنطق أنه إذا أردنا التعبير عن التباين المشترك بوحدات قياسية فإنه يكفي تقسيمه على الانحراف المعياري. ولكن لدينا متحولان، وبالتالي انحرافان معياريان. عندما نحسب التباين المشترك فإننا نقوم عملياً بحساب انحرافين (انحراف واحد لكل متحول) ثم نضرب الانحرافين ببعضهما البعض. ولذلك فإننا نقوم بنفس العملية من أجل الانحرافات المعيارية، نقسم على حاصل جداء الانحرافين المعياريين. يدعى التباين المشترك بعد عملية التوحيد القياسي بمعامل الارتباط (correlation coefficient) ويعرّف رياضياً بالعلاقة التالية:

$$r = \frac{cov_{xy}}{s_x s_y} = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{(N-1)s_x s_y} \qquad (3.4)$$

حيث يمثل s_x الانحراف المعياري للمتحول الأول x، وs_y الانحراف المعياري للمتحول الثاني y (وبقية الرموز هي نفس الرموز المستخدمة في تعريف التباين المشترك). يُعرف المعامل r المعرف بالعلاقة السابقة بمعامل Pearson للارتباط[1] (Pearson's correlation coefficient). إذا نظرنا مرة أخرى على (الجدول 1.4) فإننا نجد أن الانحراف المعياري لعدد الإعلانات المشاهدة يبلغ s_x=1.67، والانحراف المعياري لعدد علب الحلوى المشتراة يبلغ s_y=2.92. إذا ضربنا هاتين القيمتين فإننا نحصل على 1.67×2.92=4.88. والآن يمكننا تقسيم التباين المشترك (الذي تم حسابه سابقاً وبلغت قيمته 4.25) على حاصل جداء الانحرافين المعياريين السابق فنحصل على معامل الارتباط r=4.25/4.88=0.87 (وهي نفس القيمة التي سنجدها لاحقاً في الخرج 1.4).

مع التوحيد القياسي للتباين المشترك وصلنا إلى قيمة تقع بين الحدين 1- و1+ (إذا حصلت على قيمة لمعامل الارتباط أكبر من 1+ أو أصغر من 1- فتأكد أن هناك خطأ ما في عملية الحساب). تشير القيمة 1+ لمعامل الارتباط إلى أن المتحولين مرتبطان طردياً بشكل تام، فإذا ازداد أحد المتحولين فإن المتحول الآخر سيزداد بمقدار متناسب معه. وبالعكس تشير القيمة 1- لمعامل الارتباط لعلاقة عكسية تماماً بين المتحولين، فإذا ازداد أحد المتحولين فإن المتحول الآخر سينخفض بمقدار متناسب معه. أما القيمة 0 لمعامل الارتباط فتدل على عدم وجود أي ارتباط خطي بين المتحولين، فإذا تغير أحد المتحولين فإن المتحول الآخر يبقى على حاله. ورأينا في الفقرة 4.8.1 أن الارتباط الخطي هو مقياس معياري للأثر المراقب لذلك يستخدم عادة لمقياس لحجم الأثر وأن القيم 0.1± تمثل أثراً صغيراً، والقيم 0.3± تمثل أثراً متوسطاً، والقيم 0.5± تمثل أثراً كبيراً.

---

1 يستخدم الحرف r كرمز لمعامل الارتباط لـPearson، ولكنك تجد أحياناً أننا نستخدم الحرف R وذلك عند العمل في التراجع، لأنه يمثل عندئذ معامل الارتباط المتعدد. ولسبب ما فقد نستخدم الحرف R للدلالة على مربع المعامل r كما ستجد في الفقرة 3.5.4.

أفكار مفيدة

- يعتبر التباين المشترك (covariance) مقياساً خشناً للعلاقة بين التباينات.
- إذا قمنا بتوحيد قياسي لهذه القيمة فإننا نحصل على معامل Pearson للارتباط r.
- تنحصر قيم معامل الارتباط في المجال بين 1- و 1+.
- تدل القيمة 1+ على علاقة طردية تماماً، وتدل القيمة 1- على علاقة عكسية تماماً، بينما تدل القيمة 0 على عدم وجود أي ارتباط خطي.
- يستخدم معامل الارتباط لقياس حجم الأثر: تمثل القيم 0.1± أثراً صغيراً، وتمثل القيم 0.3± أثراً متوسطاً، وتمثل القيم 0.5± أثراً كبيراً.

3.4 إدخال البيانات لتحليل الارتباط في SPSS

يعتبر إدخال البيانات من أجل تحليل الارتباط أو التراجع أو التراجع المتعدد عملية مباشرة حيث يتم إدخال كل متحول في عمود مستقل. لذلك يجب عليك إنشاء متحول في محرر البيانات لكل من المتحولات التي تقوم بقياسها، وإعطائه اسماً ثم إدخال العلامات لكل مشترك في صف من صفوف محرر البيانات. قد توجد هناك حالات تستخدم فيها المتحولات الفئوية (كالجنس مثلاً)، يمكنك إدخال كل متحول من هذه المتحولات في عمود مستقل، ولا تنس تعريف التسميات المناسبة للقيم. وكمثال سنقوم بحساب معامل الارتباط بين المتحولين في الجدول 1.4 فنقوم أولاً بإدخال هذه البيانات كما في (الشكل 2.4).

1 : adverts

	adverts	packets
1	5.00	8.00
2	4.00	9.00
3	4.00	10.00
4	6.00	13.00
5	8.00	15.00
6		

الشكل 2.4 إدخال البيانات لتحليل الارتباط. يبين محرر البيانات أن المشترك الأول قد شاهد 5 إعلانات ترويجية، واشترى 8 علب من الحلوى

سنقوم في هذا الفصل بتحليل مجموعة من البيانات مستندة لأداء الطلاب في الامتحان. وقد تم تخزين البيانات لعدد من الأمثلة في ملف بيانات واحد يحمل اسم ExamAnxiety.sav. إذا أردت فتح هذا الملف فإنك سترى هذه البيانات متوضعة في أعمدة مستقلة في محرر البيانات وقد تم ترميز المتحول gender بشكل مناسب. وسنكتشف دلالة كل متحول من المتحولات أثناء تقدمنا في هذا الفصل.

4.4 الرسم البياني للعلاقات: المخطط المبعثر

يعتبر رسم المخطط المبعثر للبيانات أمراً أساسياً قبل البدء بأي تحليل للارتباط وذلك لمعرفة المنحى العام للبيانات. والمخطط المبعثر هو مخطط يتم فيه رسم كل علامة من علامات الشخص لمتحول واحد مقابل علامته للمتحول الآخر (ويمكن رسم علامته لمتحول ثالث عند التعامل مع المخطط المبعثر ثلاثي الأبعاد). ويخبرنا المخطط المبعثر بعدة أشياء عن البيانات مثل: هل هناك علاقة بين المتحولات، ما نوع هذه العلاقة، وما هي الحالات المختلفة عن بقية الحالات. تدعى الحالة المختلفة بشكل كبير عن المنحى العام بالنقطة المنعزلة، ويمكن لمثل هذه الحالات أن تؤثر بشكل كبير على معامل الارتباط (انظر المربع 1.3 في الفصل 3 والفقرة 1.1.6.5). يمكننا استخدام المخطط المبعثر لاستكشاف وجود النقاط المنعزلة.

إن رسم المخطط المبعثر في برنامج SPSS سهل للغاية. يمكنك رسمه باستخدام قائمة المخططات التفاعلية، أو المخططات اللاتفاعلية. وسنستخدم هذين النوعين بسبب وجود بعض المخططات المبعثرة المفيدة التي لا يمكن إنجازها إلا بالمخططات اللاتفاعلية.

1.4.4 المخطط المبعثر البسيط

يستخدم هذا النوع من المخططات المبعثرة من أجل متحولين فقط. على سبيل المثال، يهتم أحد علماء النفس بآثار الإرهاق في فترة الامتحانات على الأداء في الامتحان. لذلك قام بابتكار استبيان لتقييم حالة القلق المرتبطة بالامتحانات وسماه استبيان قلق الامتحانات EAQ. وينتج عنه مقياس للقلق تحسب علاماته من 100. وتم قياس القلق قبل امتحان ما، واستخدمت العلامة المئوية لكل طالب في الامتحان لتقييم الأداء في الامتحان. وقبل أن يعرف فيما إذا كانت هذه المتحولات مرتبطة، سيقوم عالم النفس برسم المخطط المبعثر للمتحولين (البيانات متوفرة في الملف ExamAnxiety.sav، ويجب أن تقوم بتحميل هذا الملف في برنامج SPSS). لرسم المخطط المبعثر لهذين المتحولين يمكنك استخدام المخططات التفاعلية وذلك باختيار أمر القائمة Graphs ⇒ Interactive ⇒ Scatterplot... لفتح مربع الحوار المبين في الشكل 3.4. يحوي القسم الأيسر من مربع الحوار جميع المتحولات المعرفة في محرر البيانات، وهناك عدة حيزات فارغة في القسم الأيمن من مربع الحوار. يمكنك نقر متحول ما في اللائحة اليسرى ونقله إلى الحيز المناسب في القسم الأيمن. يعرف المحور الشاقولي بمحور التراتيب y-axis (ordinate) للمخطط. يجب أن يكون هذا المتحول تابعاً (أي النتيجة التي تم قياسها)، وفي المثال المعتبر سيكون المتحول exam (وتسميته Exam performance (%)). أما المحور الأفقي فيعرف باسم محور الفواصل x-axis (abscissa) للمخطط. يجب أن يكون هذا المتحول مستقلاً، وفي هذا المثال سيكون المتحول anxiety (وتسميته Exam anxiety). يحوي (الشكل 3.4) تمثيلاً رمزياً للمحورين الشاقولي y-axis (سهماً يشير للأعلى) والأفقي x-axis (سهماً يشير لليمين)، ويحوي كل منهماً فراغاً لإدخال اسم المتحول.

لتحديد هذين المتحولين نقوم بسحب المتحول Exam performance (%) [exam] من اللائحة اليسرى إلى الفراغ على المحور الشاقولي، والمتحول Exam anxiety [anxiety] إلى الفراغ على المحور الأفقي.

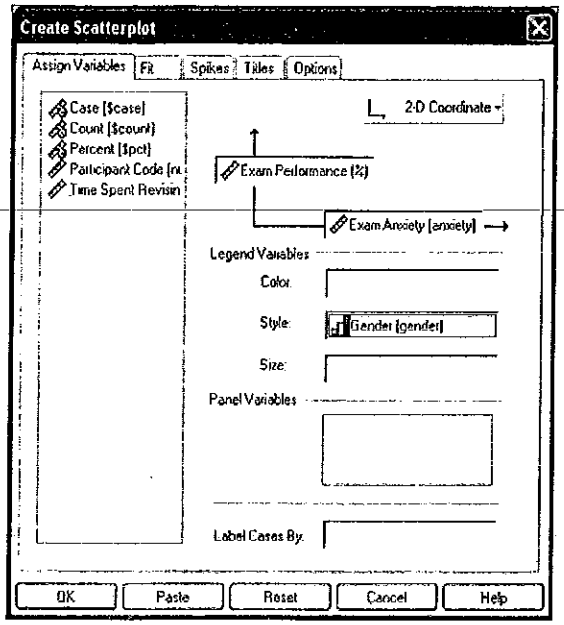

الشكل 3.4 مربع الحوار لرسم المخطط المبعثر البسيط

يحوي القسم السفلي من مربع الحوار عدداً من الفراغات الأخرى، حيث يمكنك وضع المتحولات الأخرى. يمكنك استخدام متحول التجميع لتعريف فئات مختلفة في المخطط المبعثر (حيث يقوم بإظهار كل فئة باستخدام لون أو نمط أو رسم مختلف). وهذه التعليمة مفيدة للبحث عن العلاقة بين متحولين لمجموعات من الناس. في المثال الحالي، لدينا بيانات متعلقة بجنس الطالب، لذلك يمكننا استخدام الخيارات الأخرى بالطرق التالية:

- **اللون (Color):** إذا اخترت المتحول Gender [gender] من اللائحة وسحبته إلى هذا الفراغ فإن المخطط المبعثر الناتج سيعرض نقاط البيانات للذكور بلون مختلف عن اللون المستخدم لبيانات الإناث.
- **النمط (Style):** إذا اخترت المتحول Gender [gender] من اللائحة وسحبته إلى هذا الفراغ فإن المخطط المبعثر الناتج سيعرض نقاط البيانات للذكور برمز مختلف عن الرمز المستخدم لبيانات الإناث. وقد استخدمنا هذا الخيار في مربع الحوار في (الشكل 3.4).
- **الحجم Size:** حجم النقاط المستخدمة لتمثيل بيانات الذكور سيكون مختلفاً عن حجم النقاط المستخدمة لتمثيل بيانات الإناث في المخطط المبعثر الناتج.

- **متحولات اللوحة (Panel Variables):** إذا اخترت المتحول [gender] Gender من اللائحة وسحبته إلى هذا الفراغ فإن برنامج SPSS سيعطي مخططين مبعثرين متجاورين أحدهما لبيانات الذكور والآخر لبيانات الإناث.
- **حالات التسمية حسب (Label Cases By):** إذا اخترت المتحول [gender] Gender من اللائحة وسحبته إلى هذا الفراغ فإن برنامج SPSS سيضع تسمية بجانب كل نقطة من البيانات على المخطط المبعثر الناتج للإشارة على مصدر تلك النقطة (من بيانات الذكور أو الإناث). عند وجود عدد كبير من نقاط البيانات ستصبح قراءة المخطط عسيرة. يمكن الإستفادة من هذا الخيار إذا كان أحد المتحولات يمثل اسم المشترك أو رمزاً معيناً، في هذه الحالة تسمى كل نقطة على المخطط المبعثر برمز معرّف للشخص، مما يساعد في تحديد النقاط المنعزلة وسبرها كل على حدا.

يحوي القسم العلوي من مربع الحوار عدة صفحات تبويب تسمح بالوصول إلى خيارات أخرى. إذا نقرت صفحة التبويب Titles مثلاً فإن مربع الحوار يعطي فراغاً لإعطاء تسمية للمخطط المبعثر. قد تكون صفحة التبويب Fit أكثر فائدة (وخاصة بعد قراءة الفصل القادم). في صفحة التبويب Fit (انظر الشكل 4.4) يمكنك أن ترسم خطاً باختيار طريقة ما من القائمة المنسدلة Method. إذا اخترت طريقة التراجع (Regression) فإن برنامج SPSS سيستخدم الخط المستقيم الذي يمثل بأفضل صورة العلاقة بين المتحولين في المخطط المبعثر (انظر الفصل 5). إذا اخترت طريقة المتوسط (Mean) فإن برنامج سيرسم خطاً أفقياً يمثل قيمة المتوسط، وإذا اخترت طريقة الأنعم (Smoother) فإن البرنامج سيرسم الخط المنحني الذي يصف بأفضل شكل العلاقة بين المتحولات في المخطط المبعثر. إذا حددت الخيار Total في القسم المسمى Fit lines for فإن برنامج SPSS سيرسم هذه الخطوط للبيانات الإجمالية، وإذا حددت الخيار Subgroups فإن البرنامج سيرسم خطوطاً منفصلة للمجموعات المختلفة المحددة تبعاً لمتحولات التجميع المستخدمة في مربع الحوار الأصلي لرسم المخطط المبعثر. في المثال الحالي، استخدمنا المتحول gender كمتحول تجميع ولذلك نحصل على خط للذكور وآخر للإناث. في الوقت الحاضر لن نستخدم أياً من هذه الخيارات، ولكن عندما ستقرأ الفصل 5، تذكّر كيف يمكنك رسم خط التراجع في المخطط المبعثر.

يعرض (الشكل 5.4) المخطط المبعثر الناتج. ويبين أن معظم الطلاب يعانون من مستويات عالية من القلق (هناك عدد قليل من الحالات التي ينخفض مستوى القلق فيها عن 60). ولا تبدو هناك نقاط منعزلة واضحة، إذ تظهر معظم النقاط بجوار بعضها البعض. وتظهر بعض ملامح المنحى العام للبيانات كارتباط المستوى المرتفع للقلق غالباً بالعلامات المنخفضة في الامتحان، وارتباط المستوى المنخفض للقلق مع العلامات المرتفعة في الامتحان. تبين مؤشرات الجنس بأن القلق يؤثر على الذكور والإناث بنفس الطريقة (لأن الرمزين المختلفين متوزعان بشكل متشابه تقريباً). وهناك توجه ملحوظ أيضاً في هذه البيانات يتمثل بعدم وجود حالات ذات مستوى منخفض من القلق مع علامات منخفضة في الامتحان، لأننا نرى أن معظم البيانات موزعة في القسم العلوي من مقياس القلق.

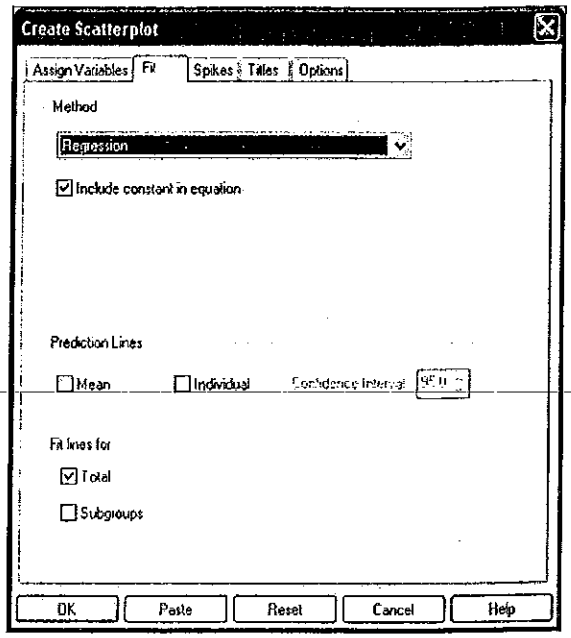

الشكل 4.4 مربع الحوار لرسم خط التراجع

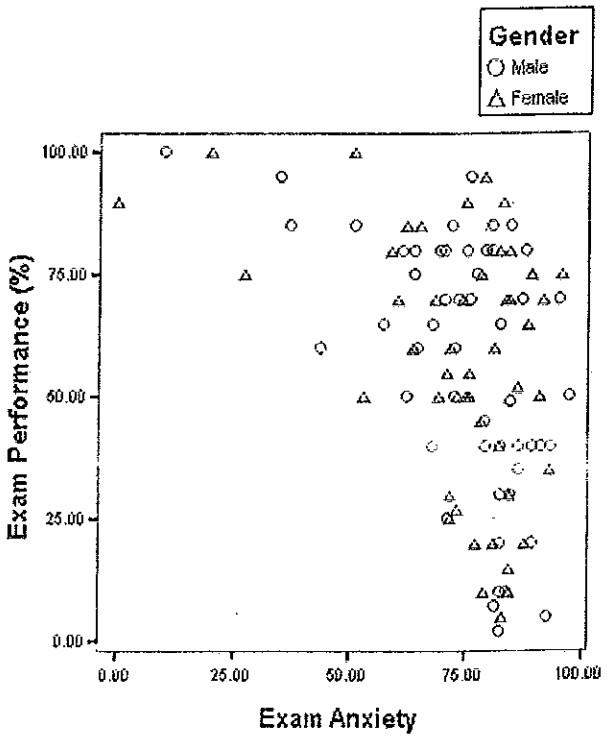

الشكل 5.4 المخطط المبعثر للأداء في الامتحان مقابل القلق في الامتحان

عندما لا تتوافق بعض بيانات المشتركين مع المنحى العام فإن من الضروري عندئذ محاولة معرفة فيما إذا كان هناك سبب قوي لاستجابة هؤلاء المشتركين بهذه الصورة المختلفة. وتنتج النقاط المنعزلة في بعض الأحيان عن خطأ في إدخال البيانات، ولذلك يجب تدقيق البيانات في محرر البيانات بحثاً عن أية حالات غير طبيعية. إذا لم تكن النقطة المنعزلة ناتجة عن خطأ في إدخال البيانات فمن المهم عندئذ معرفة فيما إذا كانت ناتجة عن متحول ثالث يؤثر على علامات المشترك المقصود. فعلى سبيل المثال، قد يكون الشخص قد عانى من القلق لسبب ما (غير الامتحان)، وكانت إجاباته في الاستبيان قد أشارت لهذا القلق، ولكنه قد يكون قلقاً معيناً بشأن الامتحان قد تداخل مع الأداء. ولذلك فإن القلق غير المرتبط لهذا الشخص لا يؤثر على أدائه، ولكنه تسبب بعلامة قلق مرتفعة. إذا كان هناك سبب مقنع لاستجابة شخص معين بشكل مختلف عن بقية المشتركين فيمكنك حذف هذا المشترك من التحليل بهدف بناء نموذج دقيق. على كل حال، لا ينبغي حذف بيانات المشترك لأنها لا توافق الفرضيات التي تضعها، وإنما لوجود مبرر قوي لسلوكها الغريب.

2.4.4 المخطط المبعثر ثلاثي الأبعاد

تستخدم المخططات ثلاثية الأبعاد بشكلٍ قليل، وسنعرض في هذه الفقرة إحدى الحالات التي يكون استخدام المخطط ثلاثي الأبعاد ضرورياً. يُستخدم المخطط المبعثر ثلاثي الأبعاد 3-D scatterplot لإظهار العلاقة بين ثلاثة متحولات. والسبب المبرر لاستخدام المخطط ثلاثي الأبعاد هو أن البعد الثالث يخبرنا بمعلومات مفيدة. وكمثال لنتخيل أن صديقنا عالم النفس قرر أن قلق الامتحانات ليس العامل الوحيد المؤثر على الأداء في الامتحان. لذلك طلب من المشتركين أن يحتفظوا بيوميات عن دراستهم حيث يمكن أن يحسبوا منها عدد الساعات التي قضوها في المراجعة للامتحانات. وأراد البحث في العلاقات بين تلك المتحولات بنفس الوقت. لإنشاء مخطط مبعثر ثلاثي الأبعاد نستخدم مربع الحوار المبين في الشكل 3.4 السابق. في القسم الأيمن العلوي من مربع الحوار هناك زر يحمل التسمية 2-D Coordinate مع قائمة منسدلة. انقر السهم الموجود على الطرف الأيمن لهذا الزر ثم انقر الخيار الثاني 3-D Coordinate. يتغير التمثيل الرمزي للمخطط بحيث يحوي محوراً ثالثاً z-axis. استخدم الشكل 3.4 كدليل، وأكمل مربع الحوار كما سبق (ضع متحول الجنس gender في حيز اللون Color هذه المرة) ثم اسحب المتحول Time spent revising [revise] وضعه في الفراغ على المحور Z. يبين الشكل 6.4 المخطط المبعثر الناتج.

وعادة يكون تفسير المخططات ثلاثية الأبعاد صعباً جداً، وتصبح فائدتها في استكشاف البيانات محدودة، ومع ذلك تبقى مفيدة في إظهار البيانات بطريقة مختصرة. إذا نقرت المخطط نقرة مزدوجة يصبح بإمكانك تدوير المحاور للحصول على فكرة أفضل عن العلاقات بين المتحولات الثلاثة، وهذه طريقة مفيدة، ولكن في نهاية الأمر يجب عليك اختيار الزاوية التي تظهر العلاقة بشكل أفضل عند وضع المخطط على ورقة ثنائية الأبعاد.

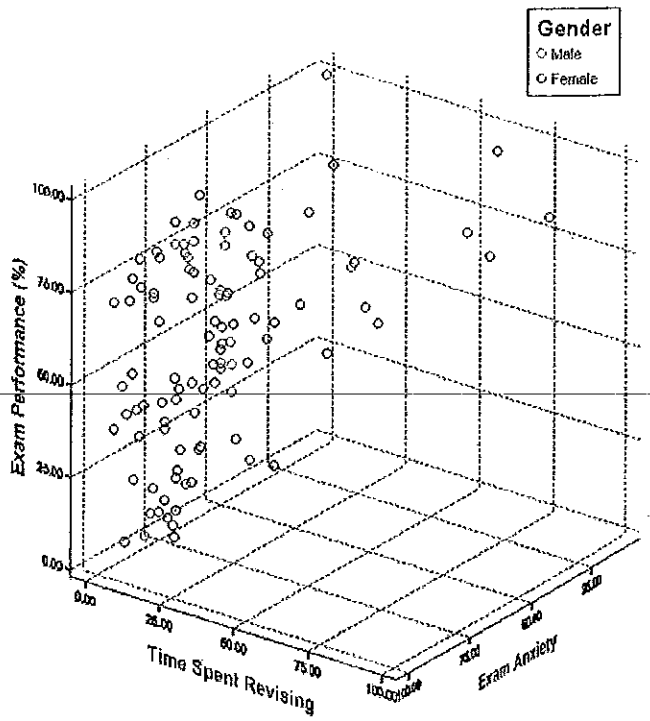

الشكل 6.4 مخطط مبعثر ثلاثي الأبعاد للأداء في الامتحان مقابل قلق الامتحانات والزمن المنقضي في المراجعة

3.4.4 المخطط المبعثر المنضد

هناك نوعان من المخططات المبعثرة التي لا يمكن إنجازها باستخدام المخططات التفاعلية: المخطط المبعثر المنضد (overlay sactterplot)، ومصفوفة المخططات المبعثرة. وكلاهما مفيد ويستحق أن نتعرف عليه. في المخطط المبعثر المنضد يمكننا رسم عدة أزواج من المتحولات على نفس المحاور. تخيل أن صديقنا عالم النفس أراد البحث عن أثر كل من قلق الامتحانات وزمن المراجعة على الأداء في الامتحان (وليس العلاقة بين قلق الامتحانات والمراجعة). من المفيد في هذه الحالة، رسم العلاقة بين زمن المراجعة والأداء في الامتحان، وكذلك العلاقة بين قلق الامتحانات والأداء بنفس الوقت. للحصول على أفضل استخدام لهذا النوع من المخططات المبعثرة، حافظ على أحد المتحولات ثابتاً وارسمه بدلالة بقية المتحولات. في المثال الحالي، حيث نهتم بدراسة أثر كل من قلق الامتحانات وزمن المراجعة على الأداء في الامتحان، فإنه يجب أن نرسم المتحول anxiety على المحور X مقابل المتحول exam على المحور Y ثم ننضد المتحول revise على المحور X مقابل المتحول exam على المحور Y.

لرسم هذا التركيب من المخططات، نستخدم أمر القائمة Graphs ⇒ Scatter Dot... حيث يتم فتح مربع الحوار المبين في (الشكل 7.4) الذي يعطي 4 خيارات تمثل الأنواع المتوفرة من المخطط المبعثر. يتم اختيار المخطط المبعثر البسيط (Simple) بشكل افتراضي، حيث يتم وضع إطار أسود حول

صورته في مربع الحوار. إذا أردت رسم نوع مختلف من المخططات المبعثرة انقر صورة المخطط المطلوب ثم انقر الزر Define.

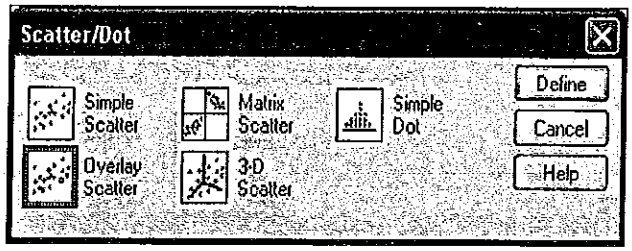

الشكل 7.4 مربع الحوار الرئيسي لرسم المخطط المبعثر

لرسم المخطط المبعثر المنضد انقر الصورة الموجودة على يسار التسمية Overlay (انظر الشكل 7.4) فيظهر مربع الحوار المبين في (الشكل 8.4). لاختيار زوج من المتحولات، انقر المتحول الأول (فيظهر في القسم السفلي من مربع الحوار تحت التسمية Current Selections اسم المتحول الأول بجانب التسمية Variable 1 ثم اختر المتحول الثاني (فيظهر بجانب التسمية Variable 2). انقل هذين المتحولين (أو هذا الزوج من المتحولات) إلى القسم الأيمن تحت التسمية X-Y Pairs وذلك بنقر زر السهم الموجود بين القسمين. يرتبط ترتيب المتحولات بالمحور الذي سيتم رسمها عليه، لذلك فإن المتحول exam في (الشكل 8.4) سيظهر على المحور Y بينما يظهر المتحول anxiety على المحور X. يجب نقل الزوج الثاني من المتحولات exam وrevise إلى القسم X-Y Pairs حيث يكون ترتيب المتحول exam في البداية (ولذلك يتم رسمه على المحور Y) يليه المتحول revise (لذلك يتم رسمه على المحور X). إذا ظهر خطأ في ترتيب زوج المتحولات بعد نقله فيمكنك تبديل ترتيب المتحولات (وبالتالي المحاور التي يتم رسمها عليها) وذلك بنقر الزر Swap Pair.

من الواضح في (الشكل 9.4) الارتباط العكسي بين القلق والأداء في الامتحان، وكذلك الارتباط الطردي بين الأداء في الامتحان وزمن المراجعة. لذلك فمع ازدياد زمن المراجعة يتحسن الأداء في الامتحان، ولكنه ينخفض عند ازدياد القلق. ويعرض المخطط المبعثر المنضد هذه العلاقات المختلفة بشكل واضح.

4.4.4 مصفوفة المخططات المبعثرة

بدلاً من رسم عدة متحولات على نفس المحاور على مخطط مبعثر ثلاثي الأبعاد (والذي يصعب تفسيره بوجود عدة أزواج من المتحولات)، فمن الممكن رسم مصفوفة من المخططات المبعثرة. يسمح هذا النوع بمعرفة العلاقة بين جميع التراكيب لعدد من الأزواج المختلفة من المتحولات. وللحصول على مصفوفة من المخططات المبعثرة لنفس البيانات المستخدمة سابقاً مع المخطط المبعثر المنضد، علينا تحديد الخيار Matrix في مربع الحوار الرئيسي لرسم المخطط المبعثر (انظر الشكل 7.4).

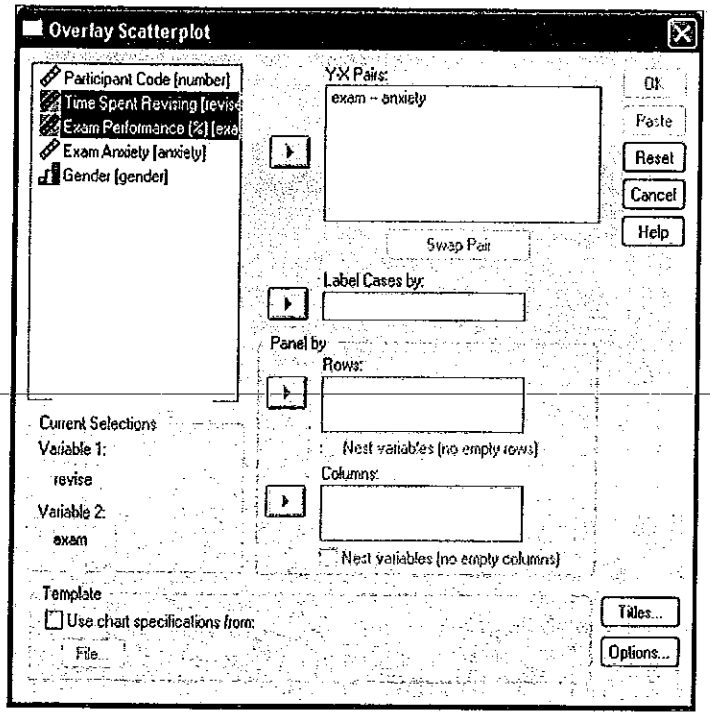

الشكل 8.4 مربع الحوار لإنشاء المخطط المبعثر المنضد. تم تحديد الزوج الأول من المتحولات، وتم اختيار الزوج الثاني ولكن لم يتم نقله بعد

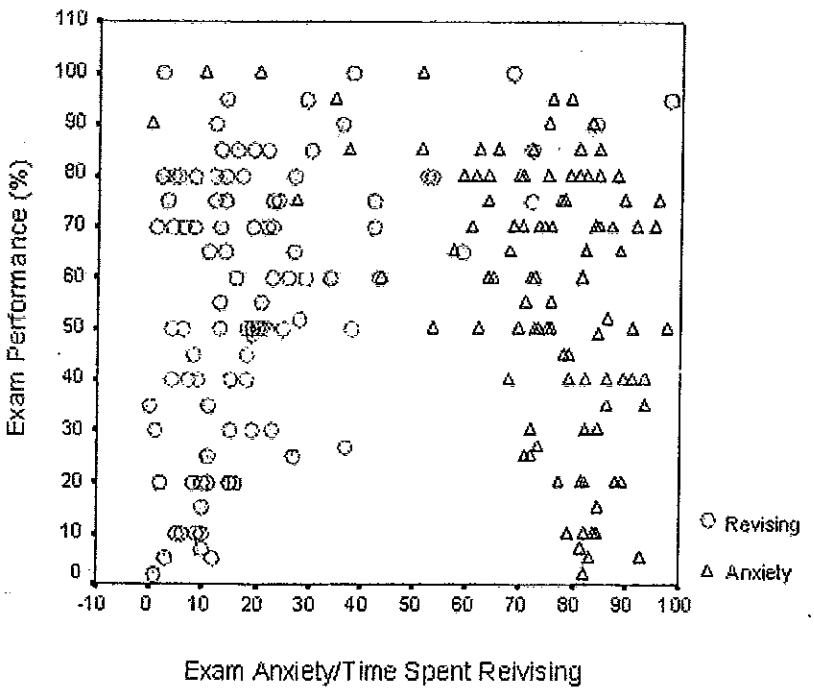

الشكل 9.4 المخطط المبعثر لعلامات الامتحان مقابل قلق الامتحان وزمن المراجعة

يبين (الشكل 10.4) الصورة النهائية لمربع الحوار المكتمل، فالمتحولات التي نرغب برسمها (exam وanxiety وrevise) قد تم نقلها من القسم الأيسر إلى الحيز المسمى Matrix Variables باستخدام زر السهم بين القسمين. وكما في حالة المخطط المبعثر البسيط فإن هناك خياراً لفصل المخطط المبعثر بمتحول تجميع (Set Marker by...)، ولكن ليس هناك حاجة لاستخدام هذا الخيار من أجل البيانات التي نتعامل معها.

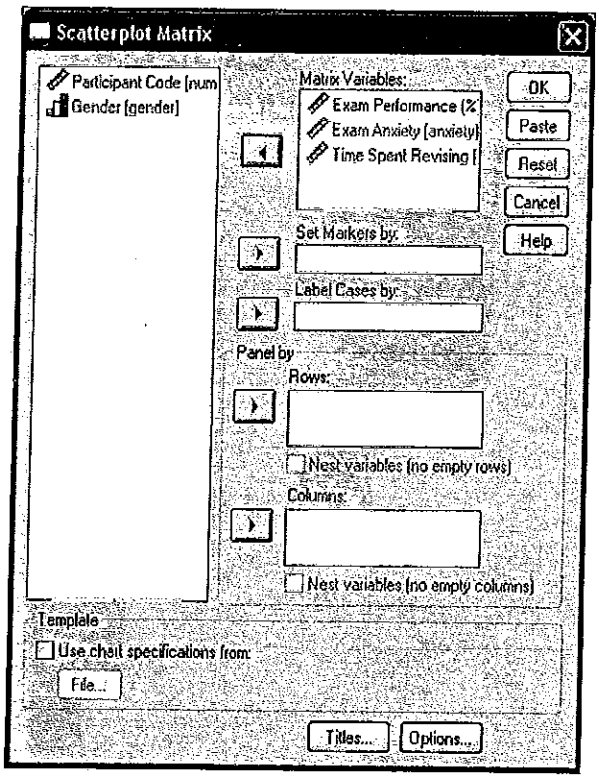

الشكل 10.4 مربع الحوار لرسم مصفوفة المخططات المبعثرة

يبين (الشكل 11.4) المخطط المبعثر الناتج الأداء في الامتحان مقابل قلق الامتحانات وزمن المراجعة. ويحوي 6 مخططات مبعثرة تمثل التراكيب المختلفة لكل متحول مع بقية المتحولات. وبذلك فإن مراجع الشبكة تمثل المخططات التالية:

- **المخطط B1:** يمثل الأداء (على المحور الشاقولي) مقابل القلق (على المحور الأفقي).
- **المخطط C1:** يمثل الأداء (على المحور الشاقولي) مقابل زمن المراجعة (على المحور الأفقي).
- **المخطط A2:** يمثل القلق (على المحور الشاقولي) مقابل الأداء (على المحور الأفقي).
- **المخطط C2:** يمثل القلق (على المحور الشاقولي) مقابل زمن المراجعة (على المحور الأفقي).

- **المخطط A3:** يمثل زمن المراجعة (على المحور الشاقولي) مقابل الأداء (على المحور الأفقي).
- **المخطط B3:** يمثل زمن المراجعة (على المحور الشاقولي) مقابل القلق (على المحور الأفقي).

وهكذا فإن المخططات المبعثرة الواقعة تحت القطر الرئيسي للمصفوفة (وعددها 3) هي مناظرة للمخططات الواقعة فوق القطر الرئيسي مع تبديل المحاور. من هذه المصفوفة يمكننا أن نرى أن زمن المراجعة والقلق مرتبطان عكسياً (فكلما ازداد زمن المراجعة انخفض مستوى القلق عند المشترك حول الامتحان). وفي المخطط المبعثر لزمن المراجعة مقابل القلق (المخططات C2 و B3) تبدو هناك نقطة منعزلة واحدة، حيث أن مشتركاً واحداً قضى زمناً قصيراً في المراجعة ولا يعاني إلا من قلق خفيف حول الامتحان. نرى أيضاً أن جميع المشتركين الذين كان مستوى القلق لديهم منخفضاً قد حققوا علامات مرتفعة في الامتحان، ويمكننا أن نستنتج أن ذلك الشخص قد أجاد أيضاً في الامتحان. يمكننا أن ندقق هذه الحالة بشكل أقرب إذا اعتقدنا بأن سلوك الأشخاص نتج عن عامل خارجي. تناسب مصفوفة المخططات المبعثرة لفحص أزواج من العلاقات بين المتحولات. على كل حال، من غير المفضل رسم مصفوفة المخططات المبعثرة لأكثر من 3 أو 4 متحولات لأنها تصبح مشوشة جداً.

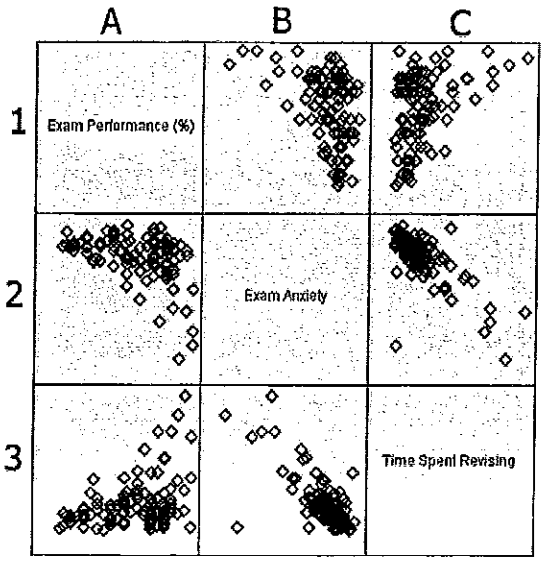

الشكل 11.4 مصفوفة المخططات المبعثرة للأداء والقلق وزمن المراجعة. تمت إضافة مراجع الشبكة للتوضيح فقط.

5.4 الارتباط ثنائي المتغيرات

بعد أن ألقينا نظرة أولية على البيانات، ننتقل الآن لإجراء تحليل الارتباط. ومن أجل هذا البحث المؤقت حول الارتباط سنعود للبيانات الموجودة في الجدول 1.4، وذلك لمعرفة هل هناك علاقة بين

عدد الإعلانات المشاهدة وعدد علب الحلوى المشتراة بعد ذلك. ننشئ عمودين في محرر البيانات لإدخال هذه البيانات (ويمكن للكسالى أن يستخدموا الملف Advert.sav على القرص المضغوط المرفق).

هناك نوعان من الارتباط: الارتباط ثنائي المتغيرات (bivariate correlation) والارتباط الجزئي (partial correlation). والارتباط ثنائي المتغيرات هو ارتباط بين متحولين (كما تم وصفه في بداية هذا الفصل)، بينما يبحث الارتباط الجزئي عن العلاقة بين متحولين مع التحكم بالأثر الناتج عن أحد المتحولات الإضافية أو عن عدد منها. ويعتبر معامل Pearson للارتباط (الذي تم وصفه سابقاً)، والمعامل Spearman's rho (انظر الفقرة 4.5.4) من الأمثلة عن معاملات الارتباط ثنائي المتغيرات. لدراسة الارتباط ثنائي المتغيرات ينبغي عليك العثور على الخيار Correlate في القائمة Analyze. يعرض (الشكل 12.4) مربع الحوار الرئيسي الذي يتم الوصول إليه عبر أمر القائمة Analyze ⇒ Correlate ⇒ Bivariate... باستخدام مربع الحوار يصبح من الممكن اختيار إحدى إحصائيات الارتباط الثلاث المتوفرة والتي ترغب بتنفيذها. الإعداد الافتراضي هو ارتباط Pearson، ولكن يمكنك حساب ارتباط Spearman وارتباط Kendall، وسنرى الفروق بين معاملات الارتباط السابقة خلال هذا البحث. بالإضافة لذلك يمكن تحديد فيما إذا كان الاختبار وحيد الطرف أو ثنائي الطرف (انظر الفقرة 2.8.1). يجب اختيار الاختبار وحيد الطرف عندما تتوفر فرضية توجيهية (مثال "كلما شاهد الشخص إعلانات أكثر، ازداد عدد علب الحلوى التي يشتريها"). أما الاختبار ثنائي الطرف (الافتراضي) فيجب اختياره عندما لا يمكن التنبؤ بطبيعة العلاقة (مثال "لست متأكداً من أن مشاهدة مزيد من الإعلانات سيكون مرتبطاً بازدياد أو نقصان عدد علب الحلوى التي يشتريها شخص ما").

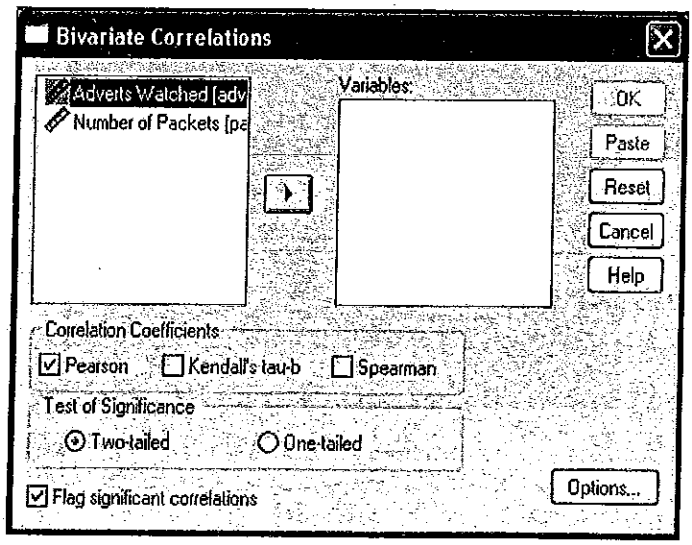

الشكل 12.4 مربع الحوار الرئيسي لتنفيذ الارتباط ثنائي المتغيرات

بعد الوصول إلى مربع الحوار الرئيسي، ستجد أن المتحولات المعرفة في محرر البيانات موجودة في القسم الأيسر من مربع الحوار (الشكل 12.4). هناك حيز نص فارغ يسمى المتحولات Variables في القسم الأيمن. يمكنك اختيار أي عدد من المتحولات في القسم الأيسر ونقلها إلى حيز المتحولات بنقر زر السهم الموجود بين القسمين. يقوم برنامج SPSS بإنشاء جدول لمعاملات الارتباط لجميع التراكيب المحتملة للمتحولات. يدعى هذا الجدول بمصفوفة الارتباط (correlation matrix). من أجل المثال الحالي، اختر المتحولين Number of Adverts Watched [adverts] و Number of Packets Bought [packets] وانقلهما إلى حيز المتحولات. يمكنك الآن الاختيار بين ثلاثة معاملات ارتباط: Pearson و Kendall و Spearman، وذلك بالنقر على مربع الاختيار الموجود بجانبه.

إذا نقرت الزر ...Options يظهر مربع الحوار المبين في الشكل 13.4 والذي يوفّر خيارين للتعامل مع القيم المفقودة (Missing Values). يتم تمكين الخيارين في القسم Statistics عند اختيار ارتباط Pearson فقط، وذلك لأن لهذين الخيارين معنى عند التعامل مع البيانات البارامترية فقط، ويتم استخدام ارتباط Pearson مع هذه الأنواع من البيانات. إذا اخترت مربع الخيار المسمى Means and standard deviations فإن برنامج SPSS سيعطي قيم المتوسط والانحراف المعياري لجميع المتحولات المحددة من أجل الارتباط. إذا تم تفعيل الخيار المسمى Cross-product deviations and covariances فإن برنامج SPSS سيعطي قيم مجموع الجداءات لمتحولات المتوسط المصححة، وهو البسط (النصف العلوي) في المعادلة (2.4). يعطي الخيار covariances التباينات المشتركة، والتي يمكن حسابها يدوياً من العلاقة (2.4). وهذه القيم هي حاصل الجداء المتصالب للانحرافات مقسوماً على العدد (N-1) وتمثل معامل الارتباط بدون التوحيد القياسي. وفي معظم الحالات، لا نحتاج لاستخدام هذه الخيارات، ولكنها مفيدة في بعض الأحيان.

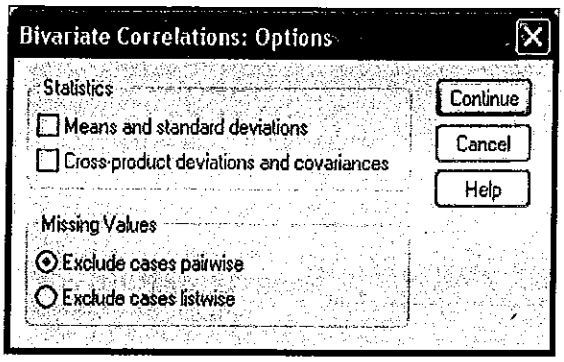

الشكل 13.4 مربع الحوار لخيارات الارتباط ثنائي المتغيرات

لتوضيح ما يمكن لهذه الخيارات عمله، اختر بعضاً منها لبيانات المثال الحالي. لنترك الخيارات الافتراضية في مربع الحوار الرئيسي دون تغيير، فيكون الخرج الناتج عن برنامج SPSS كما هو

موضح في الخرج 1.4. يبين القسم المسمى Sum of Squares and Cross-products (مجموع المربعات والجداءات المتصالبة) قيمة الجداء المتصالب (17 في هذا المثال) التي حسبناها من العلاقة (2.4)، ومجموع المربعات لكل متحول. يتم حساب مجموع المربعات من البسط (النصف العلوي) للمعادلة (1.4). إن قيمة التباين المشترك هي 4.25 وهي نفس القيمة التي حسبناها سابقاً باستخدام العلاقة (2.4). إن قيمة التباين المشترك ضمن كل متحول هي نفسها قيمة التباين لكل متحول (لذلك فإن التباين لعدد الإعلانات المشاهدة هو 2.8، والتباين لعدد العلب المشتراة هو 8.5). يمكن حساب هذه التباينات يدوياً من المعادلة (1.4). لاحظ أن معامل Pearson للارتباط بين المتحولين هو0.871، وهي نفس القيمة التي حسبناها في الفقرة 2.2.4.

Correlations

		Adverts Watched	Number of Packets
Adverts Watched	Pearson Correlation	1	.871
	Sig. (2-tailed)	.	.054
	Sum of Squares and Cross-products	11.200	17.000
	Covariance	2.800	4.250
	N	5	5
Number of Packets	Pearson Correlation	.871	1
	Sig. (2-tailed)	.054	.
	Sum of Squares and Cross-products	17.000	34.000
	Covariance	4.250	8.500
	N	5	5

الخرج 1.4 الخرج الذي يعطيه برنامج SPSS عند تنفيذ إجرائية الارتباط.

1.5.4 معامل Pearson للارتباط

تم وصف معامل Pearson للارتباط (Pearson's correlation coefficient) بشكل كامل في بداية هذا الفصل. وبالنسبة للأشخاص الذين لا يعرفون أسس علم الإحصاء، فإن الحديث عن المتوسطات دون وجود بيانات مقاسة على مستوى المجال أو النسبة يكون بدون معنى (انظر المربع 1.2 في الفصل 2). يتطلب معامل Pearson أن تكون البيانات مقاسة على المجال ليكون مقياساً دقيقاً للعلاقة الخطية بين متحولين. على كل حال، إذا أردت معرفة فيما إذا كان معامل الارتباط ذا معنى فهذا يتطلب مجموعة أخرى من الفرضيات: لكي تكون إحصائية الاختبار صحيحة يجب أن تكون البيانات موزعة طبيعياً. ومع أننا نرغب أن يكون كلا المتحولين موزعان طبيعياً فهناك استثناء واحد لهذه القاعدة: يمكن أن يكون أحد المتحولات متحولاً فئوياً يسمح بوجود فئتين فقط (إذا نظرت إلى الفقرة 6.5.4 فإنك ترى أن هذا يكافئ تماماً إجراء الاختبار t). وفي جميع الحالات، إذا كانت البيانات غير موزعة طبيعياً (انظر الفصل 3) أو لم تكن مقاسة على مستوى المجال فإنه لا يمكنك اختيار معامل Pearson (الشكل 14.4).

الشكل 14.4 Karl Pearson

أعد تحميل البيانات من الملف ExamAnxiety.sav بحيث يمكننا حساب الارتباط بين الأداء في الامتحان وزمن المراجعة وقلق الامتحان. إن البيانات من دراسة الأداء في الامتحان هي بارامترية ولذلك يمكن تطبيق ارتباط Pearson. استخدم أمر القائمة Analyze ⇒ Correlate ⇒ Bivariate... لفتح مربع الحوار Bivariate Correlations الرئيسي، وانقل المتحولات exam وanxiety وrevise إلى حيز المتحولات المسمى Variables (انظر الشكل 15.4). يسمح مربع الحوار بتحديد فيما إذا كنت تريد اختباراً وحيد الطَرف أو اختباراً ثنائي الطَرف. يجب استخدام الاختبارات وحيدة الطَرف عند اختبار اتجاه معين للفرضية، أما الاختبارات ثنائية الطَرف فيجب استخدامها عند توقّع وجود علاقة ما دون التنبؤ باتجاه هذه العلاقة. يتوقع الباحث أنه عند المستويات العليا للقلق فإن الأداء في الامتحان يكون ضعيفاً. ولذلك فإن الاختبار لهذه المتحولات يجب أن يكون وحيد الطرف، لأن الباحث يتوقع نوعاً معيناً من العلاقة وذلك قبل أن يقوم بجمع البيانات. وقد توقّع الباحث أيضاً وجود علاقة طردية بين زمن المراجعة والأداء في الامتحان، لذلك فإن الاختبار وحيد الطرف يجب أن يستخدم هنا أيضاً. وللتأكد من أن الخرج يعرض قيم الدلالة وحيدة الطرف يجب تحديد الخيار One-tailed ثم نقر الزر OK.

يعرض (الخرج 2.4) مصفوفة لمعاملات الارتباط للمتحولات الثلاثة. وتحت كل واحد من معاملات الارتباط تظهر قيمة الدلالة للارتباط وحجم العينة (N) المستندة إليها. ويظهر بشكل بديهي أن كل متحول مرتبط بنفسه، وقيمة r=1 على طول القطر الرئيسي للمصفوفة. يرتبط الأداء في الامتحان عكسياً بقلق الامتحان حيث تبلغ قيمة معامل Pearson للارتباط r=-0.441، وهناك احتمال أقل من 0.001 بأن يحدث معامل الارتباط هذا بالصدفة في عينة يبلغ حجمها 103 أشخاص (كما تظهره الحاشية السفلية (**) بجانب قيمة معامل الارتباط). تشير قيمة الدلالة إلى أن احتمال وجود هذا الارتباط بالصدفة هي منخفضة جداً (قريبة من الصفر عملياً). لذلك يمكننا أن

نكون على ثقة بأن العلاقة بين الأداء في الامتحان والقلق هي علاقة حقيقية. وعادة يقبل علماء الاجتماع قيم الاحتمال الأدنى من 0.05 كقيم ذات معنى إحصائياً، ولذلك يتم النظر إلى قيم الاحتمال الأدنى من 0.05 كمؤشر على أثر حقيقي (يشير برنامج SPSS إلى أي معامل ارتباط ذو دلالة عند هذا المستوى بنجمة (*)). يبين الخرج أيضاً أن الأداء في الامتحان مرتبط طردياً بزمن المراجعة، وتبلغ قيمة معامل الارتباط r=0.397 وهي قيمة ذات دلالة عند p<0.001. أخيراً يبدو قلق الامتحان مرتبطاً عكسياً بزمن المراجعة (قيمة معامل الارتباط r=-0.709 عند p<0.001).

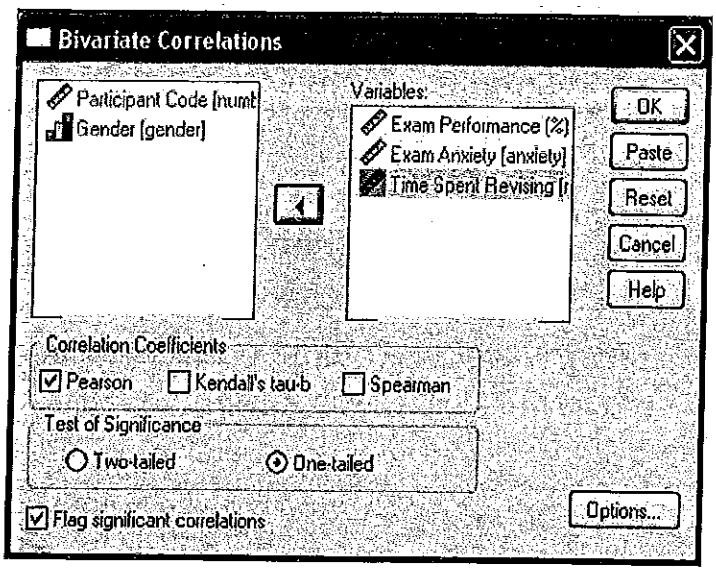

الشكل 15.4 مربع الحوار المكتمل لبيانات الأداء في الامتحان

Correlations

		Exam Performance (%)	Exam Anxiety	Time Spent Revising
Exam Performance (%)	Pearson Correlation	1	-.441**	.397**
	Sig. (1-tailed)	.	.000	.000
	N	103	103	103
Exam Anxiety	Pearson Correlation	-.441**	1	-.709**
	Sig. (1-tailed)	.000	.	.000
	N	103	103	103
Time Spent Revising	Pearson Correlation	.397**	-.709**	1
	Sig. (1-tailed)	.000	.000	.
	N	103	103	103

**. Correlation is significant at the 0.01 level (1-tailed).

الخرج 2.4 الخرج من برنامج SPSS لارتباط Pearson

وبمصطلحات علم النفس فإن كل ذلك يعني أنه مع ارتفاع القلق حول الامتحان تنخفض العلامة التي يتم الحصول عليها في الامتحان. وبالعكس كلما زاد زمن المراجعة كانت العلامة في الامتحان أعلى. وأخيراً فإنه مع زيادة زمن المراجعة ينخفض قلق الطالب حول الامتحان. وبالتالي فإن هناك علاقة تبادلية معقدة بين المتحولات الثلاثة.

2.5.4 تحذير حول التفسير: السببية

يجب الحذر بشكل كبير عند تفسير معاملات الارتباط لأنها لا تعطي مدلولاً عن اتجاه السببية. ففي مثالنا، ومع أنه يمكننا أن نستنتج أن الأداء في الامتحان ينخفض عند ارتفاع القلق حول ذلك الامتحان، فإنه لا يمكننا القول بأن القلق المرتفع يسبب أداءً سيئاً في الامتحان. ولهذا الحذر سببان:

- **مشكلة المتحول الثالث:** لا يمكن في علاقات الارتباط ثنائي المتغيرات افتراض السببية بين متحولين لأنه ربما كانت هناك متحولات أخرى مقاسة أو غير مقاسة تؤثر على النتائج. تعرف هذه المشكلة بمشكلة المتحول الثالث (third-variable problem) أو المنطقة الرمادية (tertium quid). ففي مثالنا يمكننا أن نرى أن زمن المراجعة يرتبط بشكل ذي دلالة بكل من الأداء و القلق، ولكن ليست هناك وسيلة لمعرفة أي من المتحولين المستقلين يسبب تغير الأداء في الامتحان. لذلك إذا قسنا قلق الامتحان والأداء في الامتحان فقط فيمكننا أن نفترض أن قلق الامتحان المرتفع يسبب الأداء المنخفض في الامتحان. على كل حال، من الواضح أن الأداء الضعيف في الامتحان يمكن تفسيره أيضاً بقلة المراجعة. قد تكون هناك عدة متحولات إضافية تؤثر على المتحولات المرتبطة، ولكن الباحث لم يقم بقياس هذه المتحولات. لذلك قد يكون هناك متحول آخر لم يتم قياسه، ويؤثر على كل من زمن المراجعة وقلق الامتحان. فعلى سبيل المثال، هناك مثال عن نتيجة Broca حول وجود علاقة قوية بين الجنس وحجم الدماغ، فحجم دماغ المرأة بشكلٍ عام أصغر من حجم دماغ الرجل. وقد استخدمت هذه النتيجة كدليل على أن المرأة أقل ذكاءً من الرجال. المشكلة البديهية كانت أن هذه النتيجة لا تأخذ بعين الاعتبار حجم الجسم، فالأشخاص ذوي الأجسام الضخمة يملكون دماغاً كبيراً بغض النظر عن مقدراتهم الفكرية. وقد قام Gould (1981) بإعادة تحليل بيانات Broca وبرهن أن العلاقة القوية بين الجنس وحجم الدماغ تختفي عندما نأخذ حجم الجسم بعين الاعتبار.
- **اتجاه السببية:** لا تحدد معاملات الارتباط المتحول المسبب لتغير المتحول الآخر. وحتى لو استطعنا إهمال مشكلة المتحول الثالث، وافترضنا أن المتحولات المرتبطة هي المتحولات الهامة الوحيدة، فإن معامل الارتباط لا يشير إلى الاتجاه الذي تعمل فيه السببية. لذلك ومع أن الحدس يدفعنا لاستنتاج أن قلق الامتحان يسبب تغيّر الأداء في الامتحان، فليس هناك سبب إحصائي لتبرير لماذا لا يمكن للأداء في الامتحان أن يغيّر قلق الامتحان. ومع أن النتيجة الأخيرة لا تعني شيئاً من الناحية الإنسانية (لأن قياس القلق تم قبل قياس الأداء في الامتحان) فإن الارتباط لا يخبرنا عن أن ذلك غير صحيح.

3.5.4 استخدام R^2 للتفسير

مع أنه لا نستطيع القيام باستنتاج مباشر حول السببية، فإنه يمكننا الاستفادة من معامل الارتباط في التقدم خطوة إلى الأمام وذلك بتربيعه. يعرف مربع معامل الارتباط بمعامل التحديد (Coefficient of determination) R^2 وهو مقياس لمقدار التغايرية لمتحول ما التي يفسرها المتحول الآخر. لننظر على سبيل المثال إلى العلاقة بين قلق الامتحان والأداء في الامتحان. يتغير الأداء في الامتحان من شخص إلى آخر لعدة أسباب (الاختلاف في القدرات، مستويات التحضير المختلفة وغيرها). إذا أضفنا لكل ذلك التغايرية (كما فعلنا عند حساب مجموع المربعات في الفقرة 1.4.1) فإنه يكون لدينا تقدير لمدى وجود التغايرية في الأداء في الامتحان. يمكننا بعد ذلك حساب R^2 ليدلنا على مدى تأثير هذه التغايرية على قلق الامتحان. لهذين المتحولين معامل ارتباط قدره 0.441- وتكون قيمة R^2 هي $R^2=(-0.441)^2=0.194$. تخبرنا هذه القيمة بمقدار التغايرية في الأداء في الامتحان الذي يمكن تفسيره بقلق الامتحان. إذا حولنا هذه القيمة إلى نسبة مئوية (بضربها بالعدد 100) فإنه يمكننا أن نقول أن قلق الامتحان يعتبر مسؤولاً عن 19.4% من التغايرية في الأداء في الامتحان. لذلك، ومع الارتباط الوثيق لقلق الامتحان مع الأداء في الامتحان، فإنه يعتبر مسؤولاً عن 19.4% فقط من التباين في علامات الامتحان. ولإبراز هذه القيمة، يمكن القول أن 80.6% من التغايرية يكون ناتجاً عن متحولات أخرى. يمكن الإشارة هنا إلى أنه وعلى الرغم من فائدة R^2 كمقياس لأهمية أثر ما، فلا يمكن استخدامه لاستنتاج العلاقات السببية. وعلى الرغم من أننا نتكلم عادة بمصطلحات "التباين في y الناتج عن x" أو أن التغاير في متحول ما الذي يفسره متحول آخر، فإن هذا لا يعني شيئاً حول الطريقة التي تعمل بها السببية. لذلك وعلى الرغم من أن قلق الامتحان يعتبر مسؤولاً عن 19.4% من التغاير في نتائج الامتحان فليس من الضروري أن يسبب هذا التغاير.

4.5.4 معامل Spearman للارتباط

عامل Spearman للارتباط r_s (Spearman's correlation coefficient) هو إحصائية لابارامترية ولذلك يمكن استخدامه عندما لا تلتزم البيانات بفرضية البارامترية كأن تكون غير موزعة طبيعياً (انظر الفصل 3). ويعمل اختبار Spearman على ترتيب البيانات أولاً ثم يطبق معادلة Pearson (المعادلة 3.4) على هذه التراتيب. ويهتم المحاضر في علم الإحصاء دائماً بالعوامل التي تحدد مدى نجاح الطالب في دروس الإحصاء. من العوامل الهامة المحتملة خبرة الطلاب السابقة في الرياضيات. لنتخيل أننا أخذنا 25 طالباً ونظرنا إلى علاماتهم في مادة الإحصاء في نهاية سنتهم الجامعية الأولى. في المملكة المتحدة يمكن أن يحصل الطالب على علامة الدرجة الأولى، أو الدرجة الثانية العليا، أو الدرجة الثانية الدنيا، أو الدرجة الثالثة، أو مقبول أو راسب. وهذه الدرجات هي فئات ذات ترتيب (فالثانية العليا أفضل من الثانية الدنيا). كما يمكن أن نسأل الطلاب عن علاماتهم في امتحانات الرياضيات في الشهادة الثانوية العامة (GCSE). ففي مدارس التعليم الثانوي العام في

المملكة المتحدة تكون علامات الطلاب عند سن 16 سنة مرتبة بالشكل A وB وC وD وE وF. وهذه العلامات هي فئات مرتبة حسب أهميتها أيضاً فالعلامة A هي أفضل من بقية العلامات. وعندما يمكن ترتيب الفئات بطريقة ذات مغزى يمكن القول عن البيانات بأنها تراتيبة (Ordinal). إن البيانات غير موزعة على مجالات متساوية، فعلامة الدرجة الأولى تضم مجالاً قدره 30% من العلامات (70-100%) بينما تغطي علامة الدرجة الثانية العليا مجالاً قدره 10% فقط (60-70%). عندما تقاس الدرجات على المجال التراتبي فقط نقول عنها أنها لابارامترية، ويصبح ارتباط Pearson غير مناسباً. لذلك يستخدم معامل Spearman للارتباط. إن البيانات لهذا المثال موجودة في الملف grades.sav على القرص المضغوط المرفق. البيانات موجودة في عمودين يحمل أحدهما الاسم stats والآخر gcse. تم ترميز الفئات الموصوفة سابقاً باستخدام قيمة عددية. وفي كلتا الحالتين، أخذت الدرجة العليا (علامة الدرجة الأولى و العلامة A) القيمة 1، وأخذت الفئات التالية القيم 2 و3 وهكذا. لاحظ أننا أعطينا تسمية لكل من القيم العددية (تماماً كما فعلنا عند التعامل مع متحولات الترميز).

تتم إجرائية Spearman للارتباط (الشكل 16.4) بنفس الطريقة التي تمت فيها إجرائية Pearson باستثناء أننا حددنا الخيار Spearman في مربع الحوار Bivariate Correlations (انظر الشكل 15.4) وألغينا تحديد الخيار Pearson. في هذه المرحلة يجب أن نحدد نوع الاختبار، هل هو أحادي الطَرف أو ثنائي الطَرف. وبما أننا نتوقع أن العلامات العليا في امتحانات الرياضيات في المرحلة الثانوية gcse ستكون مرتبطة مع أفضل العلامات في مادة الاحصاء stats، فإن هذه الفرضية توجيهية ولذلك نختار الاختبار أحادي الطَرف.

الشكل 16.4 Charles Spearman

يعرض الخرج 3.4 الخرج لارتباط Spearman بين المتحولين stats و gcse. يشبه الخرج إلى حد كبير ما وجدناه في ارتباط Pearson: تعرض المصفوفة معامل الارتباط بين المتحولين (0.455)، وتحته قيمة الدلالة لهذا المعامل (0.011) وأخيراً حجم العينة (25). إن قيمة الدلالة لمعامل الارتباط أقل من 0.05 لذلك يمكن الاستنتاج أن هناك علاقة هامة أو ذات دلالة بين علامات الطالب في

امتحانات الرياضيات في الثانوية وعلاماته في امتحان مادة الإحصاء. الارتباط طردي بحد ذاته، لذلك يمكن أن نستنتج أنه كلما تحسنت علامات امتحان الرياضيات في الثانوية فإن هناك تحسناً موافقاً في علامات الامتحان في مادة الإحصاء. وهكذا فقد تم إثبات الفرضية. وأخيراً، من الضروري التحقق أن القيمة N توافق عدد المشاهدات التي تم إنجازها. إذا لم يكن ذلك صحيحاً فقد يكون البرنامج قد قام باستثناء بعض البيانات لسبب ما.

Correlations

			Statistics Grade	GCSE Maths Grade
Spearman's rho	Statistics Grade	Correlation Coefficient	1.000	.455*
		Sig. (1-tailed)	.	.011
		N	25	25
	GCSE Maths Grade	Correlation Coefficient	.455*	1.000
		Sig. (1-tailed)	.011	.
		N	25	25

*. Correlation is significant at the .05 level (1-tailed).

الخرج 3.4

5.5.4 ارتباط Kendall (اللابارامتري)

ارتباط (τ) Kendall tau هو ارتباط لابارامتري آخر، ويجب استخدامه بدلاً من معامل Spearman إذا كانت هناك مجموعة صغيرة من البيانات مع عدد كبير من التراتيب المرتبطة. وهذا يعني أنه إذا قمت بترتيب كافة العلامات، وكان عدد كبير من العلامات يملك نفس الترتيب فإن عليك استخدام ارتباط Kendall. ومع أن إحصائية Spearman هي الأكثر شعبية بين هذين المعاملين فإن هناك الكثير ممن يقترحون أن إحصائية Kendall تعطي عملياً أفضل تقدير للارتباط في المجتمع. وهكذا يمكننا استنتاج تعميم أدق عن إحصائية Kendall مما يمكن أن تعطيه إحصائية Spearman. ولتنفيذ ارتباط Kendall على البيانات الخاصة بعلامات مادة الإحصاء نتبع نفس الخطوات كما فعلنا في ارتباط Pearson وارتباط Spearman، ولكننا نحدد هذه المرة الخيار Kendall's tau-b ونلغي تحديد الخيار Pearson. والخرج سيكون شبيهاً بما يعطيه ارتباط Spearman.

تلاحظ من الخرج 4.4 أن القيمة الفعلية لمعامل الارتباط أقل من ارتباط Spearman (فقد انخفضت من 0.455 إلى 0.354). وعلى الرغم من الاختلاف في قيمة معاملات الارتباط فإنه ما يزال بإمكاننا تفسير هذه النتائج كعلاقة طردية ذات دلالة عالية (لأن قيمة الدلالة 0.015 أقل من 0.05). على كل حال، إن قيمة Kendall هي مؤشر أكثر دقة على ما سيكون عليه الارتباط في المجتمع. وكما في حالة ارتباط Pearson فإنه لا يمكننا افتراض أن علامات امتحان الرياضيات في الثانوية العامة تسبب الحصول على علامات أفضل في امتحان مادة الإحصاء.

Correlations

			Statistics Grade	GCSE Maths Grade
Kendall's tau_b	Statistics Grade	Correlation Coefficient	1.000	.354*
		Sig. (1-tailed)	.	.015
		N	25	25
	GCSE Maths Grade	Correlation Coefficient	.354*	1.000
		Sig. (1-tailed)	.015	.
		N	25	25

*. Correlation is significant at the .05 level (1-tailed).

الخرج 4.4

6.5.4 الارتباط ثنائي التسلسل و ثنائي التسلسل النقطي

يختلف معاملاً الارتباط ثنائي التسلسل (biserial correlation) وثنائي التسلسل النقطي (point-biserial correlation) بفرق مبدئي واحد مع أن حساباتهما الإحصائية مختلفة تماماً. ويُستخدم هذان المعاملان عندما يكون أحد المتحولين ثنائياً (أي أنه فئوي مع فئتين فقط). من الأمثلة على المتحول الثنائي نذكر حالة الحمل، فالمرأة إما أن تكون حاملاً أو غير حامل. وغالباً يكون التحقق من العلاقات بين المتحولين ضرورياً وذلك عندما يكون أحد المتحولين ثنائياً. إن الفارق بين استخدام المعاملان ثنائي التسلسل وثنائي التسلسل النقطي يعتمد على المتحول الثنائي هل هو متقطع أم مستمر. وهذا الفارق دقيق جداً. إن الانقسام المتقطع أو الحقيقي هو الانقسام الثنائي الذي لا يوجد فيه استمرار بين الفئات. كمثال على ذلك يمكن أن نذكر مسألة الحياة أو الموت لشخص ما، فالشخص إما أن يكون حياً أو أن يكون ميتاً. ومع أنه يمكنك وصف شخص ما بأنه نصف ميت ولكن من الواضح أنه ما زال حياً طالما أنه يتنفس. لذلك لا يوجد استمرار بين الفئتين. على كل حال، من الممكن أن نجد انقساماً بشكل ثنائي حيث الاستمرار موجود. وكمثال على ذلك نذكر حالة النجاح أو الفشل في اجتياز امتحان مادة الإحصاء، فبعض الأشخاص يفشلون فقط في الامتحان بينما يفشل البعض الآخر وبهامش كبير، وكذلك يجتاز بعض الأشخاص الامتحان بشق الأنفس بينما يتفوق البعض الآخر بجدارة. لذلك ومع أن الأشخاص ينقسمون ضمن فئتين فقط، فمن الواضح وجود طبقة مستمرة تحوي هؤلاء الأشخاص. يُستخدم معامل الارتباط ثنائي التسلسل النقطي r_{pb} (point-biserial correlation coefficient) عندما يكون أحد المتحولات ثنائياً متقطعاً (كحالة الحمل مثلاً)، بينما يُستخدم معامل الارتباط ثنائي التسلسل rb (biserial correlation coefficient) عندما يكون أحد المتحولات ثنائياً مستمراً (كحالة النجاح أو الفشل في الامتحان). لا يمكن حساب معامل الارتباط ثنائي التسلسل في برنامج SPSS بشكل مباشر، لذلك يجب حساب معامل الارتباط ثنائي التسلسل النقطي أولاً ثم استخدام معادلة معينة للحصول على ذلك المعامل.

تخيل أننا نهتم بالعلاقة بين جنس القط والزمن الذي تقضيه بعيداً عن المترل. لقد سمعت أن القطط الذكور تختفي لفترات طويلة في جولات في جوار المترل، بينما تفضل القطط الإناث البقاء في المترل. وبعد جولة على عدد من الأصدقاء بحجة هذه الدراسة، طلبنا منهم أن يدونوا جنس القط وعدد الساعات التي يقضيها خارج المترل أسبوعياً. من الواضح أن يقاس الزمن المنقضي خارج المترل على مستوى المجال، ولنفترض أنه يحقق الفرضيات الأخرى للبيانات البارامترية، بينما يكون جنس القط متحولاً ثنائياً متقطعاً. يجب في هذه الحالة حساب الارتباط ثنائي التسلسل النقطي، وهو ببساطة ارتباط Pearson عندما يتم ترميز المتحول الثنائي المتقطع بالرمز 0 من أجل فئة معينة، وبالرمز 1 من أجل الفئة الأخرى (وعملياً يمكنك استخدام القيم التي تريدها لأن برنامج SPSS سيقوم بتغيير القيمة الدنيا إلى 0 والقيمة العليا إلى 1 عند إجراء الحسابات). لذلك ومن أجل تنفيذ هذا الارتباط في برنامج SPSS استخدم الترميز الموضح في الفقرة 4.4.2 لترميز متحول الجنس gender (تم في البيانات المحفوظة استخدام الرمز 1 للذكر والرمز 0 للأنثى). أما المتحول time فيأخذ عدد الساعات وتم تعريفه كطبيعي normal. وتجد هذه البيانات في الملف pbcorr.sav على القرص المضغوط المرفق. نفّذ ارتباط Pearson كما في الفقرة 1.5.

يعرض (الخرج 5.4) مصفوفة الارتباط للمتحولين time و gender. ونجد قيمة معامل الارتباط ثنائي التسلسل النقطي $r_{pb}=0.378$ التي تكون ذات دلالة أحادية الطرف بقيمة 0.001. إن اختبار الدلالة لهذا الارتباط يتم عملياً بنفس طريقة اختبار t لعينات مستقلة على البيانات (انظر الفصل 7). وتعتمد إشارة الارتباط (هل العلاقة طردية أم عكسية) بشكل كامل على الطريقة المستخدمة لترميز المتحول المقسم ثنائياً. ولبرهان ذلك، فقد وضعنا متحولاً إضافياً يدعى recode في ملف البيانات pbcorr.sav، وهو شبيه بالمتحول gender ولكن ترميز الجنس أصبح معكوساً (الذكر = 0، الأنثى = 1). أعد تنفيذ ارتباط Pearson باستخدام المتحول recode بدلاً من المتحول gender، ستجد أن معامل الارتباط أصبح 0.378-. تعتمد إشارة المعامل بشكل كامل على الرمز المعطي لكل فئة، ولذلك يجب إهمال جميع المعلومات المتعلقة باتجاه العلاقة. ولكن ما زال بإمكاننا تفسير معامل التحديد R^2 كما سبق. في هذا المثال لدينا $R^2=(0.378)^2=0.143$. ولذلك يمكن أن نستنتج أن لجنس القط مساهمة تبلغ 14.3% في التغايرية للزمن الذي يقضيه القط خارج المترل.

تخيل أننا نريد الآن تحويل معامل الارتباط ثنائي التسلسل النقطي (r_{pb}) إلى معامل الارتباط ثنائي التسلسل (r_b). يجب استخدام المعادلة (4.4)، وفيها يمثل P_1 نسبة الحالات التي تقع في الفئة الأولى (عدد القطط الذكور) ويمثل P_2 نسبة الحالات التي تقع في الفئة الثانية (عدد القطط الإناث)، أما y فيمثل الترتيب في التوزيع الطبيعي للنقطة التي تكون فيها نسبة P_1 من المساحة في طرف معين ونسبة P_2 في الطرف الآخر (سيغدو ذلك أوضح إذا أجرينا مثالاً):

$$r_b = \frac{r_{pb}\sqrt{(P_1P_2)}}{y} \qquad (4.4)$$

Correlations

		Time away from home (hours)	Gender of cat
Time away from home (hours)	Pearson Correlation	1	.378**
	Sig. (1-tailed)	.	.001
	N	60	60
Gender of cat	Pearson Correlation	.378**	1
	Sig. (1-tailed)	.001	.
	N	60	60

**. Correlation is significant at the 0.01 level (1-tailed).

الخرج 5.4

لحساب P_1 وP_2 نستخدم أمر القائمة Analyze ⇒ Descriptive Statistics ⇒ Frequencies ونختار المتحول gender. لا داعي لنقر أي خيار آخر لأن الخيارات الافتراضية تعطينا ما نريده (وهو النسب المئوية للقطط الذكور والإناث). بعد ذلك نحصل على أن 53.3% من العينة هي إناث (وهي قيمة P_2) بينما النسبة الباقية 46.7% هي الذكور (وهي قيمة P_1). لحساب y نستخدم هذه القيم مع قيم التوزيع الطبيعي الموضحة في الملحق A1. نبحث عن الترتيب الذي ينقسم عنده المنحني الطبيعي بنسبة 0.467 للقسم الأصغر، ونسبة 0.533 للقسم الأكبر (نستخدم القيم الأقرب لهذه القيم، وهي 0.4681 و 0.5319). إن قيمة الترتيب هي 0.3977. إذا عوضنا هذه القيم في المعادلة (4.4) فإننا نحصل على:

$$r_b = \frac{r_{pb}\sqrt{(P_1P_2)}}{y} = \frac{0.378\sqrt{0.533 \times 0.467}}{0.3977} = 0.475$$

وهي قيمة أعلى بكثير من قيمة معامل الارتباط ثنائي التسلسل النقطي (0.378). ولذلك فإن اختيار معامل الارتباط يمكن أن يعطي فرقاً كبيراً في النتيجة. يجب عليك إذاً توخي الحذر عند اعتماد المتحول الثنائي ومعرفة فيما إذا كان متصلاً أم أنه متقطع فعلياً.

6.4 الارتباط الجزئي وشبه الجزئي

1.6.4 النظرية خلف الارتباط الجزئي

لقد ذكرنا سابقاً أن هناك نوعاً من الارتباط يمكن أجراؤه بحيث يسمح بالنظر للعلاقة بين متحولين عندما تكون آثار المتحول الثالث ثابتة. لنأخذ على سبيل المثال تحليل بيانات قلق الامتحان (الموجودة في الملف ExamAnxiety.sav) الذي يبين أن الأداء في الامتحان مرتبط عكسياً بقلق الامتحان، ومرتبط طردياً بزمن المراجعة، ولكن زمن المراجعة ذاته مرتبط عكسياً بقلق الامتحان.

إن هذا السيناريو معقد، ولكن نعلم أن زمن المراجعة مرتبط بكل من قلق الامتحان والأداء في الامتحان، ولذلك إذا أردنا قياساً صرفاً للعلاقة بين قلق الامتحان والأداء في الامتحان فعلينا أن نأخذ بعين الاعتبار تأثير زمن المراجعة. لنستخدم قيم معامل التحديد R^2 لهذه العلاقات، نعلم أن قلق الامتحان يساهم بنسبة 19.4% من التباين في أداء الامتحان، ويساهم زمن المراجعة بنسبة 15.7% من التباين في أداء الامتحان، كما يساهم زمن المراجعة بنسبة 50.2% من التباين في قلق الامتحان. إذا كان زمن المراجعة يساهم بنصف التباين في قلق الامتحان، فيبدو مقبولاً عملياً أن جزءً على الأقل من النسبة 19.4% للتباين في أداء الامتحان الناتجة عن القلق هو ذاته التباين الناتج عن زمن المراجعة. وكذلك فإن بعض التباين في أداء الامتحان والذي اعتبرناه ناتجاً عن قلق الامتحان ليس وحيداً ويمكن اعتبار زمن المراجعة مساهماً فيه. يدعى الارتباط بين متحولين ارتباطاً جزئياً (partial correlation) إذا بقيت آثار المتحولات الأخرى ثابتة.

يوضح (الشكل 17.4) مبدأ الارتباط الجزئي. في القسم 1 من المخطط هناك مربع يدعى قلق الامتحان ويمثل التغاير الكلي في علامات الامتحان (وهذه القيمة هي التباين لأداء الامتحان). هناك مربع آخر يمثل التغاير في قلق الامتحان (وهذه القيمة هي التباين لهذا المتحول). نعلم سابقاً أن قلق الامتحان و الأداء في الامتحان يشتركان بمقدار 19.4% من تغايرهما (وهذه القيمة هي مربع معامل الارتباط)، ولذلك فإن التغايرين لهذين المتحولين ينطبقان مشكلين مربعاً ثالثاً (الجزء المهشر بالخطوط المائلة). يمثل الجزء المتطابق بين المربعين الأصليين الممثلين لقلق الامتحان والأداء في الامتحان ما يسمى بالتباين التشاركي (common variance). وبشكل مشابه، يوضح القسم 2 من المخطط التغاير التشاركي بين الأداء في الامتحان وزمن المراجعة. يشترك زمن المراجعة بمقدار 15.7% من التغاير في علامات الامتحان. وقد تم تمثيل التغاير التشاركي بمنطقة التطابق (المهشرة بخطوط مائلة). نعلم أيضاً أن زمن المراجعة وقلق الامتحان يشتركان بمقدار 50.2% من التغاير، لذلك فمن المحتمل جداً أن يكون بعض التغاير في أداء الامتحان المشترك مع قلق الامتحان هو نفس التباين التشاركي مع زمن المراجعة.

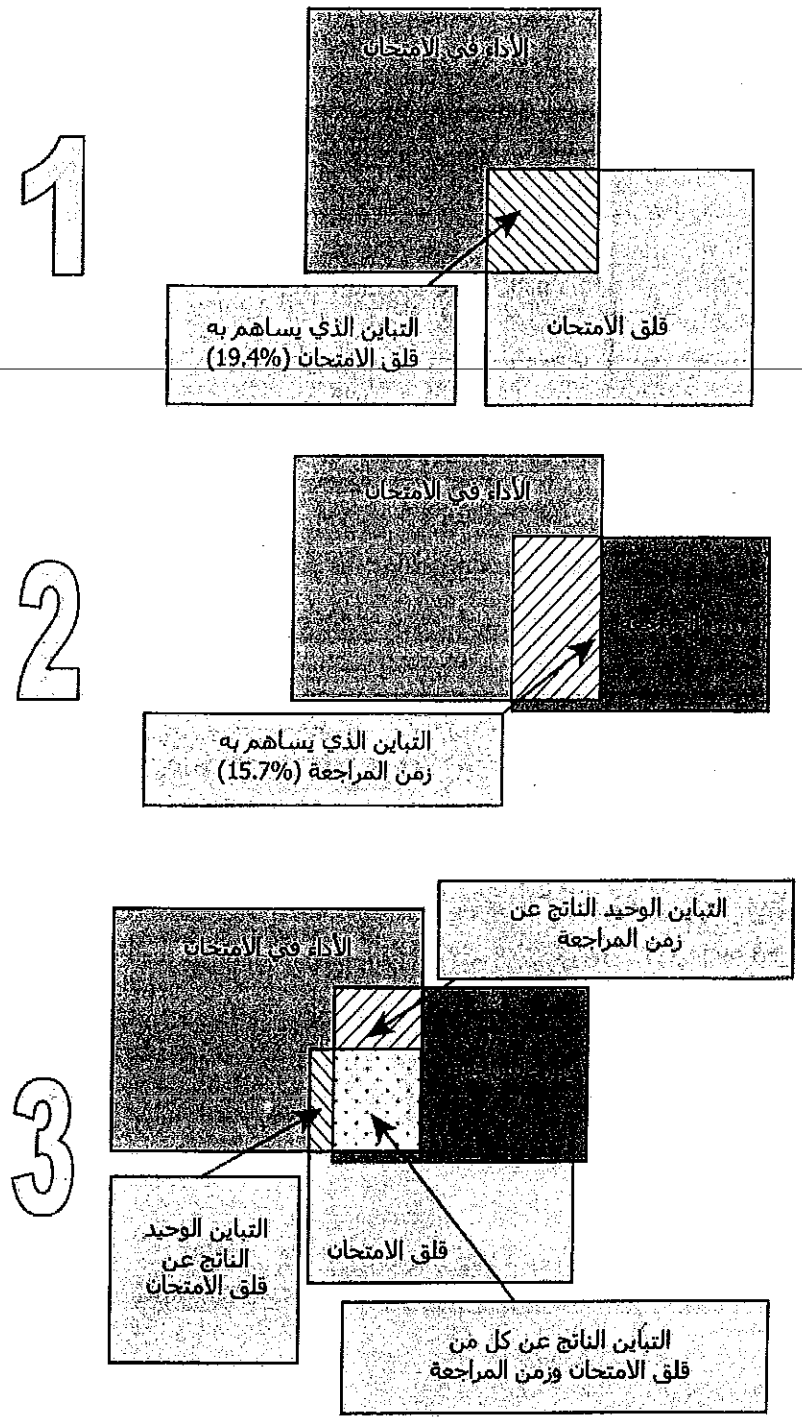

الشكل 17.4 مخطط توضيحي لمبدأ الارتباط الجزئي

يوضح القسم 3 من المخطط الصورة الكاملة. إن أول ما يجب ملاحظته هو أن المربعات الممثلة لقلق الامتحان وزمن المراجعة تملك منطقة تطابق كبيرة (وذلك لأنهما يشتركان بنسبة 50% من تغايرهما). والأهم من ذلك، عندما ننظر إلى مساهمة زمن المراجعة وقلق الامتحان في الأداء في الامتحان فإننا نرى أن هناك جزءً من أداء الامتحان مشترك مع كل من قلق الامتحان وزمن المراجعة (المنطقة المنقّطة). على كل حال، مازالت هناك أجزاء كبيرة من التباين في أداء الامتحان وحيدة لكل من المتحولين الآخرين. لذلك وعلى الرغم من أن قلق الامتحان يشترك بجزء كبير من التغاير في أداء الامتحان (القسم 1 في المخطط) فإن جزءً من منطقة التطابق مشترك مع زمن المراجعة. إذا حذفنا الجزء من التغاير التشاركي مع زمن المراجعة فإننا نحصل على قياس للعلاقة الوحيدة بين الأداء في الامتحان وقلق الامتحان. يمكننا استخدام الارتباط الجزئي لإيجاد حجم القسم الوحيد من التباين. ولذلك يمكننا تنفيذ الارتباط الجزئي بين قلق الامتحان والأداء في الامتحان مع التحكم بأثر زمن المراجعة. وبشكل مشابه يمكننا تنفيذ الارتباط الجزئي بين زمن المراجعة والأداء في الامتحان مع التحكم بآثار قلق الامتحان.

2.6.4 الارتباط الجزئي باستخدام SPSS

لتنفيذ الارتباط الجزئي على بيانات الأداء في الامتحان نختار أمر القائمة Analyze ⇒ Correlate ⇒ Partial حيث يظهر مربع الحوار المبين في الشكل 18.4. يسرد القسم الأيسر من مربع الحوار جميع المتحولات المعرفة في محرر البيانات، وفي القسم الأيمن هناك حيز علوي سيحوي المتحولات التي ستتم دراسة الارتباط بينها، ويحمل التسمية Variables، وحيز سفلي سيحوي المتحولات التي نريد التحكم بأثرها. في المثال الحالي، نريد البحث عن الأثر الوحيد لقلق الامتحان على الأداء في الامتحان، ولذلك نريد دراسة الارتباط بين المتحولين exam وanxiety مع التحكم بالمتحول revise.

يبين (الشكل 18.4) الشكل المكتمل لمربع الحوار. إذا نقرت الزر ...Options يظهر مربع حوار جديد لضبط الخيارات كما في الشكل 19.4. وهذه الخيارات الإضافية شبيهة بخيارات الارتباط ثنائي المتغيرات إلا أنه يمكنك اختيار عرض الارتباطات من المرتبة صفر. الارتباطات من المرتبة صفر (Zero-order correlations) هي معاملات الارتباط ثنائية المتغيرات دون التحكم بأي من المتحولات الأخرى (هي معاملات Pearson للارتباط). لذلك نجد في مثالنا أنه إذا حددنا الخيار Zero-order correlations فإن برنامج SPSS سيعطي مصفوفة الارتباط للمتحولات anxiety وexam وrevise. إذا لم تقم بتنفيذ أي ارتباط ثنائي المتغيرات قبل الارتباط الجزئي فإن هذا الخيار مفيد لمقارنة الارتباطات التي لم يتم التحكم بها مع الارتباطات التي يتم التحكم بها. وتعطي هذه المقارنة نظرة على مساهمة المتحولات المختلفة. حدد إذاً الخيار Zero-order correlations واترك بقية الخيارات بحالتها الافتراضية.

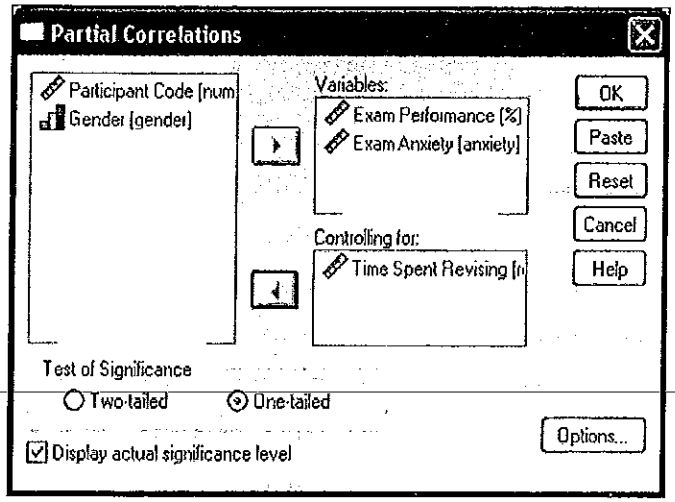

الشكل 18.4 مربع الحوار الرئيسي لتنفيذ الارتباط الجزئي

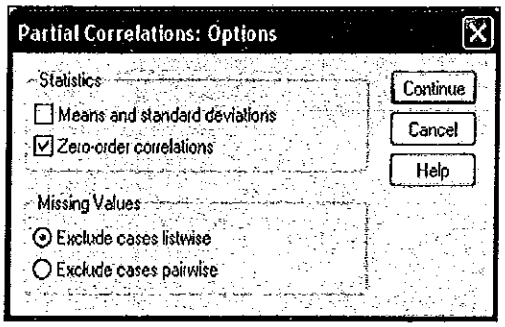

الشكل 19.4 الخيارات للارتباط الجزئي

يعرض (الخرج 6.4) الخرج الذي يعطيه برنامج SPSS من أجل الارتباط الجزئي بين قلق الامتحان والأداء في الامتحان مع التحكم بزمن المراجعة. إن أول ما يجب ملاحظته هو مصفوفة الارتباطات من المرتبة صفر التي طلبنا إظهارها عبر الخيار المحدد في مربع الحوار Options للارتباط الجزئي. ونرى أن هذه الارتباطات مماثلة لما حصلنا عليه عند تنفيذ ارتباط Pearson (قارن هذه المصفوفة مع الخرج 2.4). وتحت الارتباطات من المرتبة صفر نجد مصفوفة الارتباطات للمتحولين anxiety وexam مع التحكم بأثر زمن المراجعة. لقد قمنا في هذه المرحلة بالتحكم بمتحول واحد ولذلك يدعى الارتباط بالارتباط الجزئي من المرتبة الأولى (first-order partial correlation). من الممكن التحكم بآثار متحولين بنفس الوقت (فيكون الارتباط جزئياً من المرتبة الثانية) أو التحكم بثلاثة متحولات (فيكون الارتباط جزئياً من المرتبة الثالثة) وهلم جرا. لاحظ أن الارتباط الجزئي بين الأداء في الامتحان وقلق الامتحان يبلغ 0.247- وهو أقل بكثير من الارتباط عند عدم التحكم بزمن المراجعة (r=-0.4410). في الواقع، تصل قيمة الارتباط إلى نصف قيمتها السابقة.

Correlations

Control Variables			Exam Performance (%)	Exam Anxiety	Time Spent Revising
-none- [a]	Exam Performance (%)	Correlation	1.000	-.441	.397
		Significance (1-tailed)	.	.000	.000
		df	0	101	101
	Exam Anxiety	Correlation	-.441	1.000	-.709
		Significance (1-tailed)	.000	.	.000
		df	101	0	101
	Time Spent Revising	Correlation	.397	-.709	1.000
		Significance (1-tailed)	.000	.000	.
		df	101	101	0
Time Spent Revising	Exam Performance (%)	Correlation	1.000	-.247	
		Significance (1-tailed)	.	.006	
		df	0	100	
	Exam Anxiety	Correlation	-.247	1.000	
		Significance (1-tailed)	.006	.	
		df	100	0	

a. Cells contain zero-order (Pearson) correlations.

الخرج 6.4 الخرج لعملية الارتباط الجزئي

ومع أن هذا الارتباط مازال ذو دلالة إحصائية (ما تزال قيمة p أدنى من 0.05) فإنه قد انخفض بشكل كبير. وبمصطلح التباين فإن قيمة معامل التحديد R^2 للارتباط الجزئي هي 0.06 وهذا يعني أن قلق الامتحان يساهم بمقدار 6% فقط من التباين في أداء الامتحان. عندما لم يتم التحكم بزمن المراجعة كان قلق الامتحان مشتركاً بمقدار 19.4% من التباين في علامات الامتحان، ولذلك فإن وجود زمن المراجعة خفض بشكل كبير مقدار التباين في علامات الامتحان المشترك مع القلق. وهكذا حصلنا على القياس الأصح لدور قلق الامتحان. إن تنفيذ هذا التحليل قد أظهر أن قلق الامتحان لوحده قادر على تبرير جزء كبير من التغاير في علامات الامتحان، وقد اكتشفنا العلاقة المعقدة بين القلق وزمن المراجعة التي كان من المحتمل إهمالها. وعلى الرغم من السببية ما تزال غير أكيدة لأن المتحولات ذات الصلة قد تم تضمينها، فإن مشكلة المتحول الثالث قد تم تصحيحها بشكل ما على الأقل.

يمكن تنفيذ الارتباطات الجزئية عندما تكون المتحولات ثنائية. لذلك فمن أجل المثال عن نتيجة Broca يمكننا فحص العلاقة بين حجم الدماغ والجنس (وهو متحول ثنائي) والتحكم بحجم الجسم. وإذا كان المتحول الثالث ثنائياً فإن ذلك أفضل.

3.6.4 الارتباط شبه الجزئي

في الفصل القادم سنعرض شكلاً آخر من الارتباط يدعى الارتباط شبه الجزئي (part or semi-partial correlation). ولكننا فضّلنا أن نقوم في هذه الفقرة بتوضيح الفرق بين هذا النوع من الارتباط والارتباط الجزئي. عند تنفيذ الارتباط الجزئي بين متحولين فإننا نتحكم

بآثار المتحول الثالث. وخاصة الأثر الذي يملكه المتحول الثالث على كلا المتحولين الآخرين في الارتباط. أما في الارتباط شبه الجزئي فإننا نتحكم بأثر المتحول الثالث الذي يملكه على واحد من المتحولات في الارتباط فقط. يوضح الشكل 20.4 هذا المبدأ على بيانات الامتحان. إن الارتباط الجزئي الذي قمنا بحسابه لم يأخذ بعين الاعتبار أثر زمن المراجعة على الأداء في الامتحان فقط، بل على القلق أيضاً. إذا أردنا حساب الارتباط شبه الجزئي لنفس البيانات فإننا سنتحكم بأثر المراجعة على الأداء في الامتحان فقط (أما أثر المراجعة على قلق الامتحان فيكون مهملاً). ويكون الارتباط الجزئي أكثر فائدة في البحث عن العلاقة الوحيدة بين متحولين بعد إقصاء المتحولات الأخرى. أما الارتباط شبه الجزئي فيكون مفيداً عند محاولة تبرير التباين في متحول معين (من الخرج) الناتج عن مجموعة من المتحولات المتنبئة. تقودنا هذه الفكرة بشكل جميل نحو الفصل 5.

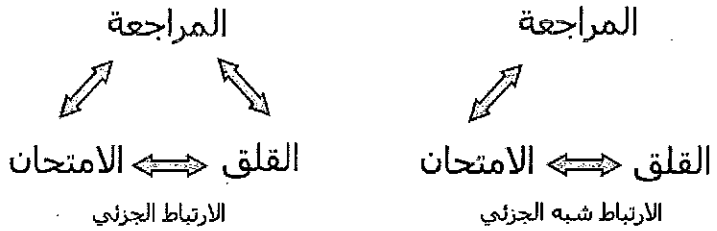

الشكل 20.4 الفرق بين الارتباط شبه الجزئي والارتباط الجزئي

7.4 كيفية تقديم معاملات الارتباط

يعتبر تقديم معاملات الارتباط عملية سهلة جداً، إذ يكفي إعطاء قيمة معامل الارتباط وتحديد مستوى دلالته (مع أن قيمة الدلالة ليست بهذه الأهمية لأن معامل الارتباط هو حجم الأثر بحد ذاته). يجب الانتباه إلى الأمور التالية: (1) إذا كنت تقدم احتمالاً وحيد الطرف فيجب الإشارة إلى ذلك. (2) يتم تمثيل كل معامل من معاملات الارتباط بحرف مختلف (بعضها بالأحرف اليونانية). (3) هناك معايير قياسية للاحتمالات التي نستخدمها (0.05 و0.01 و0.001). لنأخذ بعض الأمثلة من هذا الفصل:

* كانت هناك علاقة هامة بين عدد الإعلانات المشاهدة وعدد علب الحلوى المشتراة، $p(\text{one-tailed})<0.05$، $r=0.87$.
* كان الأداء في الامتحان مرتبطاً بشكل وثيق بقلق الامتحان، $r=-0.44$، وبزمن المراجعة $r=0.40$، كما كان زمن المراجعة مرتبطاً بقلق الامتحان، (all ps<0.001) $r=-0.71$.
* كانت هناك علاقة طردية بين علامات شخص ما في مادة الإحصاء، وعلاماته في امتحان الرياضيات في الشهادة الثانوية، $p<0.05$، $r_s=0.46$.
* كانت هناك علاقة طردية بين علامات شخص ما في مادة الإحصاء، وعلاماته في امتحان الرياضيات في الشهادة الثانوية، $p<0.05$، $\tau=0.35$ (لاحظ أننا قدمنا ارتباط Kendall هنا).

* إن جنس القط مرتبط بشكل وثيق بالزمن الذي يقضيه القط خارج المنزل، $r_{pb}=0.38$ ،$p<0.01$.

النقطة الأخيرة التي يجب ملاحظتها في علوم الاجتماع أن هناك عدة مستويات قياسية للدلالة الإحصائية. إن أهم معيار هو أن تكون قيمة الدلالة أقل من 0.05 إذا كانت قيمة الدلالة الدقيقة أقل من ذلك بكثير فيمكن أن نكون أكثر ثقة بما يخص قوة الأثر التجريبي. في مثل هذه الحالات قد نقيم احتفالاً لأن نتائجنا ليست ذات دلالة عند مستوى 0.05 وحسب، وإنما ذات دلالة عند مستويات أدنى من ذلك أيضاً. وعادة نستخدم القيم 0.05 و0.01 و0.001 و0.0001 ونادراً ما يمكن تقديم أثر على أنه ذو دلالة عند مستوى أدنى من 0.0001!

8.4 ما الذي اكتشفناه عن الإحصاء

بحث هذا الفصل في طرق دراسة العلاقات بين المتحولات. وقد بدأنا بالنظر لكيفية قياس العلاقات إحصائياً وذلك بتطوير ما عرفناه سابقاً باسم التباين (انظر الفصل 1) للبحث عن التباين المشترك بين المتحولات. ويعرف التباين المشترك بين المتحولات باسم (covariance). تعلمنا بعد ذلك كيفية تمثيل العلاقات بيانياً باستخدام المخططات المبعثرة (Scatterplots). وترسم هذه المخططات بشكلها الأبسط قيم أحد المتحولات مقابل المتحول الآخر. ويمكنك رسم أكثر من متحولين على مخطط مبعثر ثلاثي الأبعاد، أو مخطط مبعثر منضد. من الممكن أيضاً تمييز المجموعات من الناس على مخطط مبعثر باستخدام رموز أو ألوان مختلفة. اكتشفنا بعد ذلك أنه عندما تكون البيانات بارامترية فيمكننا قياس قوة العلاقة باستخدام معامل Pearson للارتباط r. وعندما لا تلتزم البيانات بفرضية الاختبارات البارامترية فيمكننا استخدام معامل Spearman للارتباط r_s، أما من أجل المجموعات الصغيرة من البيانات فإن معامل Kendall τ يكون أكثر دقة. رأينا كذلك أنه يمكن حساب الارتباطات بين المتحولات عندما يكون أحد هذه المتحولات ثنائياً (أي أنه يحوي فئتين فقط)، وعندما لا يوجد استمرار بين الفئتين فإنه يمكننا استخدام الارتباط ثنائي التسلسل النقطي r_{pb} ولكن عند وجود استمرار بين الفئتين فإننا نستخدم الارتباط ثنائي التسلسل r_b. وأخيراً بحثنا في الفرق بين أنواع الارتباط الجزئي حيث تقاس العلاقة بين متحولين مع التحكم بأثر المتحولات الأخرى على هذين المتحولين، والارتباط شبه الجزئي حيث تقاس العلاقة بين متحولين مع التحكم بأثر المتحولات الأخرى على أحد هذين المتحولين فقط.

9.4 المصطلحات الأساسية التي اكتشفناها

الارتباط ثنائي التسلسل	(Biserial correlation)
الارتباط ثنائي المتغيرات	(Bivariate correlation)
معامل التحديد	(Coefficient of determination

التباين المشترك	(Covariance)
انحرافات الجداء المتصالب	(Cross-product deviations)
معامل Kendall للارتباط	(Kendall's tau)
الارتباط الجزئي	(Partial correlation)
معامل Pearson للارتباط	(Pearson's correlation coefficient)
الارتباط ثنائي التسلسل النقطي	(Point-biserial correlation)
المخطط المبعثر	(Scatterplot)
الارتباط شبه الجزئي	(Semi-partial correlation)
معامل Spearman للارتباط	(Spearman's correlation coefficient)
التوحيد القياسي	(Standardization)

10.4 مهمات يجب إنجازها

يمكن العثور على الإجابات لهذه المهمات ضمن الملف Answers(Chapter4).pdf.

- اهتم أحد الطلاب باحتمال وجود علاقة طردية بين الزمن المنقضي في كتابة مقالة ما والعلامة التي تحصل عليها. وقام بدراسة 45 من أصدقائه، حيث قاس عدد الساعات الذي يقضونه في كتابة المقالة (المتحول hours) والعلامة التي يحصلون عليها للمقالة كنسبة مئوية (المتحول essay). قام أيضاً بتحويل هذه العلامات إلى التصنيف المعتمد، الدرجة الأولى، الثانية العليا، الثانية الدنيا، الثالثة (المتحول grade). باستخدام البيانات المتوفرة في ملف البيانات EssayMarks.sav على القرص المضغوط المرفق، بيّن ما هي العلاقة بين زمن تحضير المقالة والعلامة التي يتم الحصول عليها كنسبة مئوية ثم كتصنيف علامات (ارسم المخطط المبعثر أيضاً).
- باستخدام ملف البيانات ChickFlick.sav من الفصل 3، هل هناك علاقة بين الجنس والتأثر العاطفي؟ باستخدام نفس البيانات، هل هناك علاقة بين الفيلم المشاهد والتأثر العاطفي؟

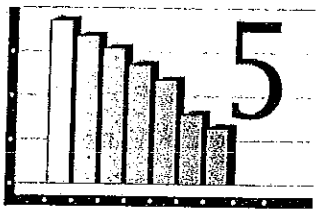

التراجع

1.5 بماذا يخبرنا هذا الفصل

بحثنا في الفصل السابق كيفية قياس (ورسم) العلاقات بين متحولين. ويمكننا أن نتقدم خطوة أخرى للأمام ونبحث في توقّع متحول ما اعتماداً على المتحول الآخر. وكمثال بسيط يمكنك أن تتوقّع مستويات الإجهاد أو الإرهاق انطلاقاً من الوقت المتبقي لكي تلقي خطاباً أو كلمة. ستتوقع أن تكون العلاقة عكسية (كلما قصر الوقت المتبقي لإلقاء الكلمة ازداد القلق). سنقوم بعد ذلك بتوسيع هذه العلاقة الأساسية للإجابة على سؤال مثل "إذا بقيت 10 دقائق لكي يلقي شخص ما خطاباً، فإلى أي حد سيكون قلقاً؟". هذا هو الأساس في تحليل التراجع، إنه طريقة لتوقّع نتيجة معينة اعتماداً على متحول أو عدّة متحولات تنبؤية. يبحث هذا الفصل في تحليل التراجع بشيء من العمق، حيث يبدأ بمقدمة عن المبادئ الأساسية في التراجع باستخدام مثال عن توقع نتيجة ما من متحول تنبؤي وحيد (التراجع البسيط (Simple regression)). وبذلك سنشرح ماهية نموذج التراجع، وكيفية تقديره، وكيفية تقييم مدى توافقه مع البيانات، وكيفية تنفيذ كل ذلك في برنامج SPSS، وكيفية تفسير الخرج الذي يعطيه برنامج SPSS. ننظر بعد ذلك في الحالة الأكثر تعقيداً حيث يتم توقّع نتيجة ما اعتماداً على عدة متحولات تنبؤية (التراجع المتعدد (Multiple regression)). ومع أننا لن ندخل في كيفية تقدير النموذج، فإننا سنعطي وصفاً له وللطرق المختلفة المعتمدة لتحديد المتحولات الداخلة في النموذج. ستجد أيضاً بعض الأمور التي يمكن أن تؤثر على دقة النموذج، وكيفية تقييمها قبل الانتقال لتنفيذ التحليل في برنامج SPSS، وتفسير الخرج، وإيجاد مدى توافق النموذج مع البيانات وكيفية تعميمه. وينتهي الفصل بالبحث في كيفية دمج المتحولات الفئوية في تحليل التراجع باستخدام ما يدعى المتحولات الزائفة.

2.5 مدخل إلى التراجع

يمكن أن يشكل الارتباط أداة بحثية مفيدة جداً ولكنه لا يخبرنا أي شيء عن القدرة التنبؤية للمتحولات. في تحليل التراجع (regression analysis) نجري توافقاً بين نموذج تنبؤي والبيانات المتوفرة لدينا، ثم نستخدم هذا النموذج لنتوقّع قيماً للمتحول التابع DV (dependent variable)

اعتماداً على متحول أو أكثر من المتحولات المستقلة[1] IVs (independent variables). يبحث التراجع البسيط (simple regression) في التنبؤ بمتحول النتيجة (outcome variable) من متحول تنبؤي (predictor variable) وحيد، بينما يبحث التراجع المتعدد (multiple regression) في التنبؤ بمتحول النتيجة من عدة متحولات تنبؤية. وهذه طريقة مفيدة جداً لأنها تسمح بالذهاب خطوة أبعد من البيانات التي نقوم بمعالجتها. لقد أدخلنا في الفقرة 1.4.1 فكرة أنه يمكننا التنبؤ بأية بيانات باتباع المعادلة العامة التالية:

$$Outcome_i = (Model_i) + error_i \qquad (1.5)$$

وهذا يعني أن النتيجة التي نحاول أن نتوقعها لشخص ما يمكن أن نتوقعها بما يعطيه النموذج المستخدم لملاءمة البيانات إضافة لنوع معين من الخطأ. في التراجع يكون النموذج المستخدم خطياً (ويعني النموذج الخطي (linear model) أنه نموذج يعتمد على خط مستقيم) ويمكنك أن تتخيله كمحاولة لتلخيص مجموعة من البيانات بخط مستقيم (انظر الشكل 11.1). ولذلك فإن كلمة نموذج Model في المعادلة السابقة يمكن استبدالها بشيء آخر يعرّف الخط المستخدم لملاءمة البيانات (انظر الفقرة التالية).

ومن أجل أية مجموعة من البيانات هناك عدة خطوط يمكن استخدامها لتلخيص المنحى العام، ولذلك فإننا نحتاج لطريقة ما لاختيار الخط المناسب من بين مجموعة الخطوط الممكنة. وبهدف استنتاج خلاصات دقيقة فإننا نرغب بأن يلائم النموذج البيانات بأفضل صورة ممكنة. هناك عدة طرق لملاءمة خط مستقيم للبيانات التي قمت بجمعها. وأبسط طريقة ستكون باستخدام عينيك للحكم على الخط الذي يبدو ملخِّصاً للبيانات بشكل أفضل. على كل حال، تبقى العين أداة غير موضوعية، ولا تضمن أن يكون النموذج المختار هو الأفضل. بدلاً من ذلك سنستخدم التقنية الرياضية لإقامة الخط الذي يصف البيانات المجمّعة بشكل أفضل. تدعى هذه الطريقة بطريقة المربعات الصغرى (method of least squares).

1.2.5 بعض المعلومات الهامة عن الخطوط المستقيمة

لقد ذكرنا سابقاً أنه سيتم استبدال كلمة نموذج Model في المعادلة العامة بشيء يعرّف الخط الذي يلائم البيانات. في الواقع، يمكن تعريف الخط المستقيم بشيئين: (1) ميل الخط ويرمز له عادة b_1، و(2) نقطة تقاطع المستقيم مع المحور الشاقولي ويرمز لها بالرمز b_0 (تسمى أيضاً الاعتراض

1 لسوء الحظ يسمي بعض الأشخاص (وكذلك برنامج SPSS) متحولات التراجع بالمتحولات التابعة والمتحولات المستقلة (كما في التجارب المضبوطة). على كل حال، تقوم أبحاث الارتباط بطبيعتها غالباً بالتحكم بالمتحولات المستقلة لقياس الأثر على متحول تابع. وتقاس المتحولات بآن واحد ودون تحكم صارم. لذلك فإن تسمية متحولات التراجع بهذه الطريقة غير دقيقة. ولهذا السبب سنعتمد مصطلح "متحول تنبؤي predictor" للمتحولات المستقلة، ومصطلح "النتيجة outcome" للمتحول التابع.

(intercept)). ويصبح النموذج العام ممثلاً بالمعادلة (2.5)، وفيها يرمز Y_i للنتيجة التي نريد توقّعها، و X_i لعلامة المشترك رقم i في المتحول التنبؤي. يمثل b_1 ميل الخط المستقيم الملائم للبيانات، و b_0 نقطة تقاطع ذلك المستقيم مع المحور الشاقولي. تعرف البارامترات b_1 وb_0 بمعاملات التراجع (regression coefficients) وستظهر مراراً وتكراراً في هذا الكتاب، وقد يشار إليها أحياناً بالحرف b (دون أي دليل سفلي) أو b_i (ويعني b مرتبطة مع المتحول i). وهناك الحد الباقي ε_i (residual) الذي يمثل الفرق بين العلامة المتوقعة من قِبَل الخط المستقيم للمشترك رقم i والعلامة الفعلية التي حصل عليها ذلك المشترك. ويتم تفسير هذه المعادلة غالباً بدون اعتبار القسم الباقي (لذلك يمكنك إهماله إذا أردت) ولكن من الأفضل معرفة أن هذا القسم يمثل حقيقةَ أن النموذج الذي اخترناه لن يلائم البيانات المجمعة بشكل تام:

$$Y_i = (b_0 + b_1 X_i) + \varepsilon_i \qquad (2.5)$$

ولكل خط اعتراض (نقطة تقاطع مع المحور الشاقولي) وميل محدد. يبين (الشكل 1.5) مجموعة من الخطوط التي لها نفس الاعتراض ولكنها تختلف بالميل، ومجموعة أخرى من الخطوط لها نفس الميل ولكنها تختلف بقيمة الاعتراض. يوضح (الشكل 1.5) نقطة هامة أخرى، وهي أن ميل الخط يخبرنا عن طبيعة العلاقة التي يتم وصفها. رأينا في الفصل 4 أن العلاقات يمكن أن تكون طردية أو عكسية. يصف الخط ذو القيمة الموجبة للميل علاقة طردية، بينما يصف الخط ذو القيمة السالبة للميل علاقة عكسية. لذلك إذا نظرت إلى (الشكل 1.5) (القسم الأيسر) فإن الخط السميك يمثل علاقة طردية بينما يمثل الخط الخفيف علاقة عكسية.

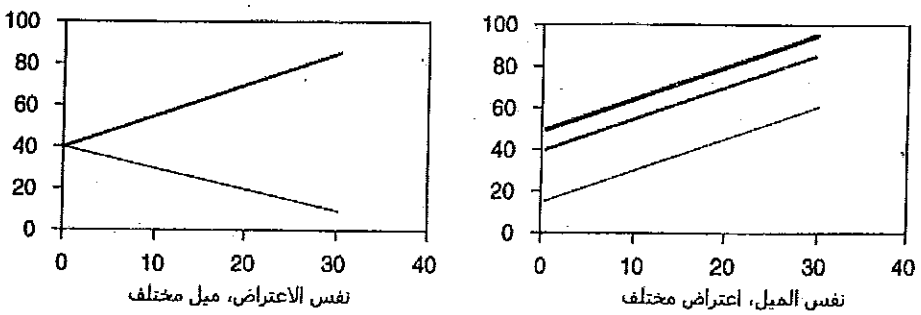

الشكل 1.5 خطوط تشترك بنفس الاعتراض وتختلف بقيم الميل، وخطوط أخرى لها نفس الميل وتختلف بالاعتراض

إذا كان ممكناً وصف الخط بمعرفة ميله واعتراضه فإنه يمكننا استخدام هذه القيم لوصف النموذج الذي نقترحه (لأن النموذج في التراجع الخطي هو عبارة عن خط مستقيم). لذلك فإن النموذج الذي نستخدمه لملاءمة البيانات في التراجع الخطي يمكن تفسيره كخط مستقيم معرّف رياضياً بالمعادلة (2.5). وفي تحليل التراجع فإننا نعمل بجهد لإيجاد الخط الذي يلاءم البيانات المجمعة بأفضل

شكل، ثم نقدِّر الميل والاعتراض لذلك الخط. بعد تحديد تلك القيم يمكننا إدخال قيم مختلفة من المتحول التنبؤي في النموذج لتقدير قيمة متحول النتيجة.

2.2.5 طريقة المربعات الصغرى

لقد أشرنا سابقاً إلى أن طريقة المربعات الصغرى (method of least squares) هي طريقة لإيجاد الخط الذي يلائم البيانات بأفضل شكل (أي إيجاد الخط الذي يمر عبر أكبر عدد ممكن من نقاط البيانات أو يكون قريباً منها). ويتم إيجاد هذا الخط الذي يضمن أفضل توافق مع البيانات بإيجاد الخط (من بين جميع الخطوط التي يمكن رسمها) الذي يعطي المقدار الأدنى من الفرق بين نقاط البيانات المشاهدة وهذا الخط. يبين الشكل 2.5 أنه عندما يوافق خط ما مجموعة من البيانات، فإن هناك فروقاً صغيرة بين القيم المتوقعة من الخط والبيانات المشاهدة فعلياً. ونحن نهتم بالفروق الشاقولية بين الخط والبيانات الفعلية لأننا نستخدم الخط للتنبؤ بقيم Y انطلاقاً من قيم المتحول X. ومع أن بعض نقاط البيانات تقع على الخط تماماً، فإن بعضها الآخر يقع فوق الخط أو تحته، مما يدل على وجود فرق بين النموذج المعتمد لملاءمة البيانات وقيم البيانات المشاهدة فعلياً. وتكون بعض الفروق موجبة (وذلك عندما تقع النقطة فوق الخط، مما يدل على أن النموذج يقدّرها بأقل من قيمتها) وتكون الفروق الأخرى سالبة (وذلك عندما تقع النقطة تحت الخط، مما يدل على أن النموذج يقدّرها بأعلى من قيمتها). تدعى هذه الفروق عادة بالبواقي (residuals). وفي مناقشتنا للتباين في الفقرة 1.4.1، قلنا أنه إذا قمنا بجمع الفروق الموجبة والفروق السالبة فإنها تميل لإلغاء بعضها بعضاً. ولتجنب هذه المشكلة نقوم بتربيع هذه الفروق قبل جمعها معاً. توفر مربعات الفروق مؤشراً لمدى تمثيل خط معين للبيانات، فإذا كانت مربعات الفروق كبيرة فإن الخط لا يمثل البيانات، أما إذا كانت مربعات الفروق صغيرة فإن الخط هو ممثل للبيانات. يمكن حساب مجموع مربعات الفروق (ورمزه SS) لأي خط ملائم لبيانات محددة، ويمكن مقارنة جودة التوافق (goodness-of-fit) لكل خط بعد حساب مجموع مربعات الفروق له. وتعمل طريقة المربعات الصغرى باختيار الخط الذي يكون مجموع المربعات له أقل ما يمكن (أي أنها تختار الخط الذي يمثل البيانات المشاهدة بأفضل شكل). ويمكن أن يتم تحديد الخط الأمثل بملاءمة جميع الخطوط المحتملة لمجموعة البيانات، وحساب مجموع مربعات الفروق لكل خط، ثم اختيار الخط الذي تكون فيه قيمة ذلك المجموع أصغر ما يمكن. ولكن هذه العملية تستغرق وقتاً طويلاً. ولحسن الحظ، هناك تقنية رياضية لإيجاد القيم العظمى والصغرى، وهذه التقنية هي حساب التكامل والتفاضل (calculus) وسنستخدمها لإيجاد الخط الذي يقلل مجموع مربعات الفروق للحد الأدنى. والنتيجة النهائية هي أنه يمكن تقدير قيمة الميل والاعتراض للخط الأكثر ملاءمة. ويسمي علماء الاجتماع عادة هذا الخط بخط التراجع (regression line).

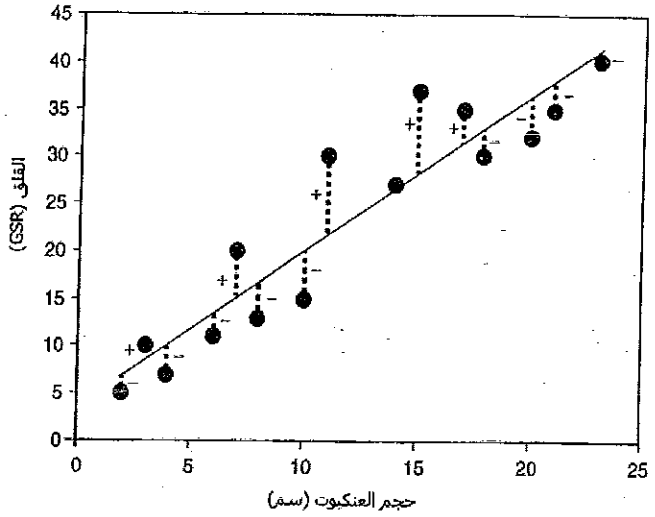

الشكل 2.5 يعرض هذا المخطط المبعثر بعض البيانات مع خط يمثل المنحى العام. تمثل الخطوط الشاقولية المتقطعة الفروق (أو البواقي) بين الخط والبيانات الفعلية

3.2.5 تقييم جودة التوافق: مجموع المربعات و R و R^2

بعد أن نجد الخط الأفضل يصبح من الضروري تقييم مدى توافق هذا الخط مع البيانات الفعلية (نقيّم جودة التوافق للنموذج). ونقوم بذلك حتى لو كان هذا الخط هو أفضل خط متوفر، إذ يمكن أن يكون التوافق مع البيانات ضعيفاً. وقد رأينا في الفقرة 1.4.1 أن أحد قياسات كفاية النموذج هو مجموع مربعات الفروق (أو بشكل أعمّ يمكننا تقييم النماذج باستخدام المعادلة (3.5)):

$$\text{deviation} = \Sigma(\text{observed} - \text{model})^2 \qquad (3.5)$$

إذا أردنا تقييم خط الملاءمة الأفضل فإن علينا مقارنته مع شيء ما، والشيء الذي نختاره هو النموذج الأولي الذي يمكن أن نعثر عليه. لذلك نستخدم المعادلة (3.5) لحساب التوافق للنموذج الأولي، ثم التوافق للنموذج الأفضل (خط التوافق الأفضل)، فإذا كان النموذج الأفضل جيداً فيجب أن يلائم البيانات بشكل أفضل من النموذج الأولي. ولتوضيح ذلك سنأخذ مثالاً، تخيل أننا نهتم بالتنبؤ بمبيعات الاسطوانات الموسيقية (Y)، انطلاقاً من كمية الأموال المنفقة في الحملات الإعلانية (X). إذا طلب مني المدير تقدير الكمية التي يمكن أن نبيعها من الاسطوانات الموسيقية إذا أنفقنا 100,000$ في الحملة الإعلانية، فماذا سيكون الرقم الذي أتوقعه؟ ربما يكون الجواب الأفضل الذي يمكن أن أعطيه هو العدد المتوسط للمبيعات من الاسطوانات الموسيقية (ولنقل 200,000 وحدة) لأننا نتوقع في المتوسط أن نبيع هذا العدد. وقد يكون هذا الجواب مقنعاً لمدير غبي. ولكن إذا سألني المدير عن الكمية التي يمكن أن نبيعها إذا أنفقنا 1$ في الحملة الإعلانية. وفي غياب أية معلومات دقيقة، فإن أفضل تخمين يمكن أن أقوم به هو إعطاء العدد المتوسط للمبيعات (أي 200,000 وحدة). وهنا تظهر المشكلة، مهما كانت الأموال المنفقة في الحملة الإعلانية فإن تنبؤي بمستوى

المبيعات يبقى ذاته. من الواضح تماماً أن المتوسط يكون عديم الفائدة كنموذج للعلاقة بين متحولين، ولكنه أبسط نموذج متوفر.

لذلك سنتبع الإستراتيجية الأساسية التالية للتنبؤ بالنتيجة، يمكننا أن نختار استخدام المتوسط لأنه (في المعدل) سيعطينا تخميناً جيداً لنتيجة ما. باستخدام المتوسط لنموذج يمكننا حساب الفروق بين القيم المشاهدة والقيم المتوقعة من قِبَل المتوسط (المعادلة (3.5)). لقد رأينا في الفقرة 1.4.1 أننا نقوم بتربيع جميع هذه الفروق للحصول على مجموع مربعات الفروق. يُعرف مجموع مربعات الفروق باسم المجموع الكلي للمربعات SS_T (total sum of squares) لأنه المجموع الكلي لمربعات الفروق الموجودة عند تطبيق النموذج الأولي على البيانات. تمثل هذه القيمة جودة المتوسط كنموذج للبيانات المشاهدة. إذا قمنا بملاءمة النموذج الأكثر تطوراً للبيانات، فإننا باستخدام المعادلة (3.5) نحصل على الفروق بين النموذج الجديد والبيانات المشاهدة. رأينا في الفقرة السابقة أن طريقة المربعات الصغرى تعثر على أفضل خط ممكن لوصف مجموعة من البيانات وذلك بتقليل الفروق بين النموذج والبيانات إلى الحد الأدنى. على كل حال، وبوجود النموذج الأمثل فما يزال هناك خطأ يتمثل بالفروق بين كل نقطة من البيانات المشاهدة والقيمة المتوقعة من قِبَل خط التراجع. وكما فعلنا سابقاً، يتم تربيع هذه الفروق قبل جمعها معاً بحيث لا تقوم اتجاهات هذه الفروق بإلغائها. تُدعى النتيجة بمجموع مربعات البواقي (sum of squared residuals) أو المجموع الباقي للمربعات SS_R (residual sum of squares). تمثل هذه القيمة درجة الخطأ (أو عدم الدقة) عند ملاءمة النموذج الأفضل للبيانات. يمكننا استخدام هاتين القيمتين لحساب مدى أفضلية خط التراجع على استخدام المتوسط كنموذج (ما مقدار أفضلية أفضل نموذج ممكن على أسوأ نموذج؟). ويتم حساب التحسن في التنبؤ الناتج عن استخدام نموذج التراجع بدلاً من المتوسط بحساب الفرق بين SS_T و SS_R. يبين هذا الفرق مقدار الانخفاض في عدم دقة النموذج والناتج عن ملاءمة نموذج التراجع للبيانات. يدعى هذا التحسن مجموع المربعات للنموذج SS_M (model sum of squares). يوضح (الشكل 3.5) كلاً من هذه المجاميع بشكل بياني.

إذا كانت قيمة SS_M كبيرة فإن نموذج التراجع مختلف جداً عن استخدام المتوسط للتنبؤ بمتحول النتيجة. وهذا يعني أن نموذج التراجع قد أدخل تحسيناً كبيراً لجودة التنبؤ بمتحول النتيجة. على كل حال، إذا كان SS_M صغيراً فإن استخدام نموذج التراجع أفضل بقليل من استخدام المتوسط. من هذه المجاميع للمربعات يظهر مقياس مفيد هو نسبة التحسن بفضل النموذج، ويتم حسابه بسهولة إذ يكفي تقسيم مجموع المربعات للنموذج على المجموع الكلي للمربعات فنحصل على القيمة R^2. وللتعبير عن هذه القيمة كنسبة مئوية نضرب القيمة بالعدد 100. ولذلك تمثل R^2 مقدار التباين في النتيجة الذي يفسره النموذج (SS_M) بالنسبة إلى مقدار التغاير المطلوب تبريره في المركز الأول (SS_T). لذلك، وكنسبة مئوية، فإنها تمثل النسبة المئوية للتغاير في النتيجة التي يمكن أن يفسرها النموذج:

$$R^2 = \frac{SS_M}{SS_T} \qquad (4.5)$$

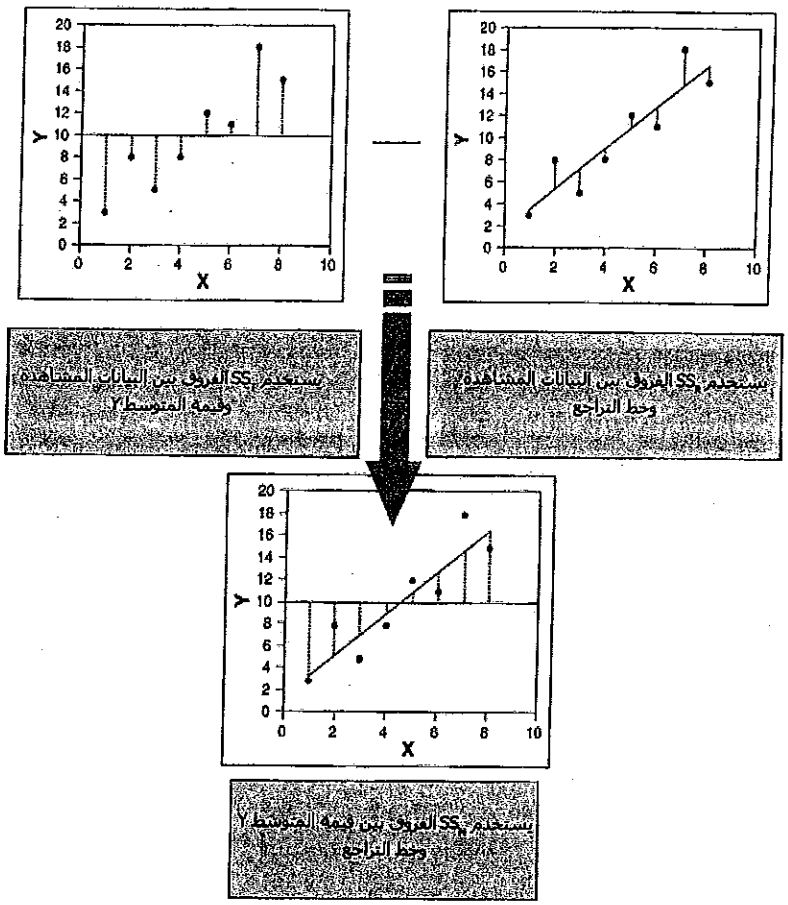

الشكل 3.5 يوضح المخطط طريقة اشتقاق مجاميع المربعات في التراجع

إن هذه القيمة هي نفس القيمة R^2 التي رأيناها في الفصل 4 (الفقرة 3.5.4) ويتم تفسيرها بنفس الطريقة. لذلك، وفي التراجع البسيط يمكننا أن نأخذ الجذر التربيعي لهذه القيمة لنحصل على معامل Pearson للارتباط. وهكذا فإن معامل الارتباط يزودنا بتقدير جيد للتلاؤم الكلي لنموذج التراجع، وتوفر القيمة R^2 مؤشراً جيداً للحجم الواقعي للعلاقة.

هناك استخدام آخر لمجاميع المربعات في تقييم النموذج وذلك من خلال الاختبار F. وسنتعرف على الاختبار F بشكل معمق في الفصل 8، ولكننا نقول هنا أنه اختبار يعتمد على نسبة التحسن بفضل النموذج (SS_M) إلى الفرق بين النموذج والبيانات المشاهدة (SS_R). وبدلاً من استخدام مجاميع المربعات بحد ذاتها فإننا نأخذ متوسط مجاميع المربعات (والذي يدعى متوسط المربعات MS (mean squares)). ولإيجاد متوسط مجاميع المربعات فمن الضروري التقسيم على عدد درجات الحرية (وهو مشابه لحساب التباين من مربعات المجاميع، انظر الفقرة 1.4.1). من أجل SS_M فإن عدد درجات الحرية هو ببساطة عدد المتحولات في النموذج، ومن أجل SS_R فإنه عدد النقاط

المشاهدة مطروحاً منه عدد البارامترات التي يتم تقديرها. وتكون النتيجة هي المربعات المتوسطة للنموذج MS_M والمربعات المتوسطة للباقي MS_R. وعند هذه المرحلة، ليس من الضروري أن نفهم كيفية اشتقاق المربعات المتوسطة (لأننا سنوضح ذلك في الفصل 8). ولكن من الضروري أن نفهم أن النسبة F (المعادلة (5.5)) هي مقياس لمدى التحسن الذي أدخله النموذج على التنبؤ بقيمة النتيجة مقارنة بمستوى الخطأ (أو عدم الدقة) للنموذج:

$$F = \frac{MS_M}{MS_R} \qquad (5.5)$$

إذا كان النموذج جيداً فإننا نتوقع أن يكون التحسن في التنبؤ بفضل النموذج كبيراً (أي أن MS_M سيكون كبيراً) والفرق بين النموذج والبيانات المشاهدة صغيراً (أي أن MS_R سيكون صغيراً). وباختصار فإنه في النموذج الجيد تكون قيمة النسبة F كبيرة (أكبر من 1 على الأقل) لأن البسط في المعادلة (5.5) سيكون أكبر من المقام. ويمكن تقييم المطال الدقيق للنسبة F باستخدام القيم الحرجة لدرجات الحرية الموافقة (انظر الملحق A3).

4.2.5 تقييم المتحولات التنبؤية المنفصلة

لقد رأينا أن المتحول التنبؤي في نموذج التراجع يملك معاملاً (b_1) يمثل في التراجع البسيط ميل خط التراجع. تمثل قيمة b التغير في النتيجة الذي ينتج عن تغير بمقدار وحدة للمتحول التنبؤي. إذا كان النموذج عديم الفائدة في توقّع النتيجة، وتغّيرت قيمة المتحول التنبؤي فماذا نتوقع أن يكون التغير في النتيجة؟ إذا كان النموذج سيئاً للغاية فإننا نتوقع أن يكون التغير في النتيجة معدوماً. بالعودة إلى (الشكل 3.5) وتدقيق اللوحة التي تمثل SS_T فإننا نرى أن استخدام المتوسط كان سيئاً جداً في التنبؤ بقيمة النتيجة. إن الخط الذي يمثل المتوسط هو أفقي، وهذا يعني أنه عندما تتغير قيمة المتحول التنبؤي فإن قيمة النتيجة لا تتغير (لأننا نتوقع أنه من أجل جميع مستويات المتحول التنبؤي فإن النتيجة ستكون مساوية لقيمة المتوسط). والنقطة الهامة هنا هي أن معاملات التراجع للمتحول التنبؤي في النموذج السيئ (كالمتوسط) تكون معدومة. وإذا كان معامل التراجع معدوماً فهذا يعني أن: (1) التغير بمقدار وحدة للمتحول التنبؤي ليس له تأثير على القيمة المتوقعة للنتيجة (لا تتغير القيمة المتوقعة للنتيجة أبداً) و(2) ميل خط التراجع يساوي الصفر، وهذا يعني أن خط التراجع أفقي. وينتج عن ذلك بشكل منطقي أنه إذا كان المتحول يتوقّع نتيجة ما بشكل جيد فيجب أن تكون قيم b مختلفة عن الصفر بشكل كبير. ويتم اختبار هذه الفرضية باستخدام الاختبار t (انظر الفصل 7). تختبر الإحصائية t (t-statistic) فرضية العدم التي تقول بأن قيم b تساوي الصفر، ولذلك إذا كانت ذات دلالة فإننا نقبل الفرضية بأن قيم b مختلفة عن الصفر بشكل كبير، وأن المتحول التنبؤي يساهم بشكل فعال في قدرتنا على تقدير قيم النتيجة.

عند اختبار مدى اختلاف قيم b عن الصفر تظهر المشكلة باعتماد مطال هذه القيم على وحدات القياس المستخدمة. ولذلك يتم حساب الاختبار t بأخذ الخطأ المعياري بعين الاعتبار. يخبرنا الخطأ المعياري بشيء ما عن عدد قيم b المختلفة إذا أخذنا عينات كثيرة من البيانات تتعلق بالمبيعات لمنتج ما وميزانية الإعلانات ثم حسبنا قيم b لكل عينة. يمكننا أن نرسم التوزيع التكراري لهذه العينات لنكتشف فيما إذا كانت قيم b لجميع العينات متشابهة نسبياً أو أنها مختلفة جداً (لنعد مرة أخرى إلى الفقرة 6.1). يمكننا استخدام الانحراف المعياري لهذا التوزيع (المعروف بالخطأ المعياري (standard error)) كمقياس للتشابه بين قيم b عبر العينات. إذا كان الخطأ المعياري صغيراً جداً فهذا يعني أن معظم العينات تملك قيم b مشابهة لقيمها في العينة المجمّعة (لأن هناك تغاير قليل بين العينات). يخبرنا الاختبار t فيما إذا كانت قيم b مختلفة عن الصفر مقارنة بالتغاير في قيم b للعينات المتشابهة. عندما يكون الخطأ المعياري صغيراً فإن أي انحراف صغير عن الصفر يمكن أن يعكس فرقاً مهماً لأن b ممثلة لغالبية العينات المحتملة.

تبين المعادلة (6.5) كيفية حساب الاختبار t وستجد شكلاً عاماً لهذه المعادلة في الفصل 7 (المعادلة (1.7)). إن قيمة $b_{expected}$ هي قيمة b التي نتوقع الحصول عليها إذا كانت فرضية العدم صحيحة. وقد أشرنا سابقاً إلى أن فرضية العدم هي أن قيم b تساوي الصفر ولذلك يمكن استبدال هذه القيمة بالصفر. يتبسط شكل المعادلة لتصبح حاصل قسمة القيمة المشاهدة لـــ b على الخطأ المعياري المرتبطة به:

$$t = \frac{b_{observed} - b_{expected}}{SE_b} = \frac{b_{observed}}{SE_b} \qquad (6.5)$$

ولقيم t توزيع خاص يختلف تبعاً لدرجات الحرية للاختبار. في التراجع يكون عدد درجات الحرية هو N-p-1، حيث N الحجم الكلي للعينة و p عدد المتحولات التنبؤية. في التراجع البسيط يكون لدينا متحول تنبؤي واحد فيصبح عدد درجات الحرية N-2. بعد أن حددنا توزيع t الذي نريد استخدامه، يمكننا مقارنة القيمة المشاهدة للاختبار t بالقيم التي سنتوقع الحصول عليها بالصدفة فقط: إذا كان t كبيراً جداً فمن غير المحتمل حصوله بالصدفة (يمكن إيجاد هذه القيم في الملحق A2). يوفر برنامج SPSS الاحتمال الصحيح بأن القيمة المشاهدة للاختبار t ستحدث إذا كانت قيمة b تساوي الصفر. وكقاعدة عامة، إذا كانت دلالة هذه المشاهدة أقل من 0.05 فإن علماء الاجتماع يقبلون أن b مختلفة عن الصفر بشكل كبير، وبطريقة أخرى، يساهم المتحول التنبؤي بشكل كبير في توقّع النتيجة (انظر الفصل 1).

3.5 إنجاز التراجع البسيط في برنامج SPSS

تعرفنا على المبادئ النظرية للتراجع، وبقينا في الحالة التي يكون فيها متحول تنبؤي واحد. وللمساعدة في توضيح ما تعلمناه حتى الآن فإننا سنأخذ مثالاً عن التراجع البسيط في برنامج SPSS.

لنعد إلى المثال الذي طلب فيه المدير تقدير مبيعات الاسطوانات الموسيقية بناءً على ميزانية الإعلانات. تتوفر بعض البيانات لهذا المثال في الملف Record1.sav. يحوي ملف البيانات 200 صف، يمثل كل واحد منها اسطوانة موسيقية مختلفة. هناك عمودان أيضاً، يمثل أحدهما المبيعات لكل أسطوانة موسيقية خلال الأسبوع التالي لإطلاقها، ويمثل الآخر المبلغ المصروف في حملة الترويج للأسطوانة الموسيقية قبل إطلاقها (بالجنيهات). وهذا هو التنسيق المعتمد لإدخال بيانات التراجع، حيث يتم إدخال متحول النتيجة وكل من المتحولات التنبؤية في عمود مستقل، ويمثل كل صف القيم المستقلة لهذه المتحولات. يعرض الشكل 4.5 نمط هذه البيانات، ونلاحظ وجود علاقة طردية تبين أنه كلما ازداد المبلغ المصروف في الترويج للأسطوانة ازداد احتمال بيعها. وطبعاً هناك بعض الاسطوانات التي تحقق مبيعات جيدة بغض النظر عن مبالغ الحملة الترويجية (القسم العلوي الأيسر من المخطط المبعثر)، ولكن عندما تكون مستويات الترويج مرتفعة فلا توجد أسطوانات ذات مبيعات منخفضة. يعرض المخطط المبعثر أيضاً الخط الذي يمثل أفضل توافق لهذه البيانات، وإذا تذكرنا أن قيمة المتوسط ستكون ممثلة بخط أفقي قريب من القيمة 200,000 فإننا نجد أن خط التراجع مختلف بشكل ملحوظ عن خط المتوسط.

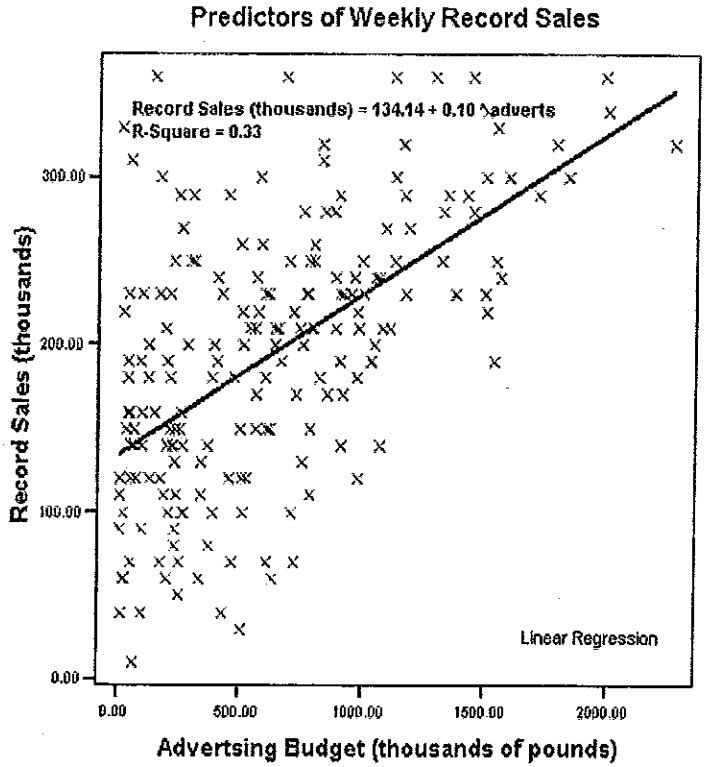

الشكل 4.5 يوضح المخطط المبعثر العلاقة بين مبيعات الأسطوانات الموسيقية والمبالغ المصروفة في الحملة الترويجية لها

لإيجاد البارامترات التي تصف خط التراجع ومعرفة فيما إذا كان هذا الخط هو نموذج مفيد، فإننا بحاجة لتنفيذ تحليل التراجع. يتم ذلك بفتح مربع الحوار الرئيسي للتراجع الخطي عبر أمر القائمة Analyze ⇒ Regression ⇒ Linear... يبين (الشكل 5.5) مربع الحوار الناتج. هناك حيز يحمل التسمية Dependent حيث يجب وضع متحول النتيجة (في هذا المثال sales). لذلك انقر المتحول sales من لائحة المتحولات في القسم الأيسر من مربع الحوار وانقله إلى ذلك الحيز بنقر زر السهم الموجود بين القسمين. هناك حيز آخر يحمل التسمية Independent(s) حيث يجب وضع المتحولات التنبؤية. في حالة التراجع البسيط لدينا متحول تنبؤي واحد (في هذا المثال adverts) ولذلك يجب عليك اختيار المتحول adverts من لائحة المتحولات في القسم الأيسر من مربع الحوار ونقله إلى هذا الحيز بنقر زر السهم الموجود بين القسمين. تتوفر مجموعة من الخيارات التي سيتم استكشافها ضمن إطار التراجع المتعدد (في الفقرة 5.5). نكتفي الآن بما قمنا به وننقر الزر OK لتنفيذ التحليل الأساسي.

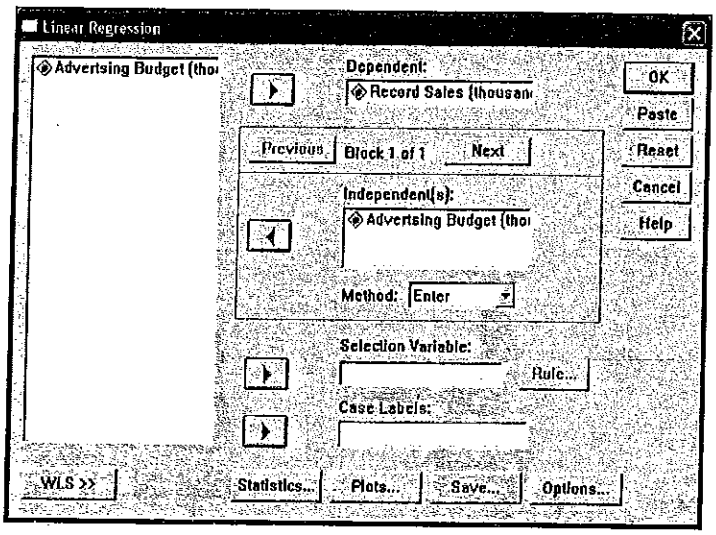

الشكل 5.5 مربع الحوار الرئيسي للتراجع الخطي

4.5 تفسير التراجع البسيط

1.4.5 التوافق الكلي للنموذج

يمثل الجدول الأول الذي يقدمه برنامج SPSS ملخصاً للنموذج. ويوفر هذا الجدول الملخص (المبين في الخرج 1.5) قيم R وR^2 للنموذج الذي تم اشتقاقه. ومن أجل هذا النموذج كانت قيمة R=0.578 لأن هناك متحولاً تنبؤياً واحداً فقط، وتمثل هذه القيمة الارتباط البسيط بين ميزانية الترويج ومبيعات الأسطوانات (يمكنك التأكد من هذه القيمة بتنفيذ الارتباط وفق ما تعلمته في الفصل 4). وكانت قيمة R^2=0.335 وهذا يعني أن الإنفاق الترويجي يساهم بمقدار 33.5% من

التغاير في مبيعات الأسطوانات. وبكلمات أخرى، إذا كنت تحاول تفسير سبب زيادة المبيعات لبعض الأسطوانات أكثر من غيرها، فعليك النظر إلى التغاير في المبيعات للأسطوانات المختلفة. ربما تكون هناك عوامل متعددة لتفسير هذا التغاير، ولكن النموذج الذي حصلنا عليه، والذي لا يتضمن سوى النفقات الإعلانية، يستطيع تفسير 33.5% من هذا التغاير. وهذا يعني أن 66.5% من التغاير في مبيعات الأسطوانات لا يمكن تفسيره بالنفقات الإعلانية وحدها. لذلك يجب أن تكون هناك متحولات أخرى التي تؤثر على المبيعات.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.578[a]	.335	.331	65.99144

a. Predictors: (Constant), Advertsing Budget (thousands of pounds)

الخرج 1.5

يعطي القسم الثاني من الخرج تحليل التباين ANOVA (انظر الفصل 8). ويبين هذا الجدول الملخص لمجاميع المربعات المختلفة التي تم وصفها في (الشكل 3.5) ودرجات الحرية المرتبطة بكل منها (الخرج 2.5). يمكن حساب متوسط المربعات بتقسيم مجموع المربعات على عدد درجات الحرية المرتبط به. إن أهم جزء في هذا الجدول هو النسبة F. وقد بلغت F=99.587 لهذه البيانات، وهي ذات دلالة عند مستوى p<0.001 (لأن القيمة الموجودة في عمود الدلالة المسمى Sig. في هذا الجدول هي أصغر من 0.001). وتخبرنا هذه النتيجة بأن هناك احتمال أقل من 0.1% بأن تكون قيمة النسبة F قد حدثت بالصدفة وحدها. لذلك يمكننا استنتاج أن نموذج التراجع يعطي توقعاً أفضل بكثير لمبيعات الأسطوانات مما يعطيه استخدام القيمة المتوسطة لمبيعات الأسطوانات. وباختصار فإن نموذج التراجع يتوقع إجمالاً المبيعات بشكل أفضل.

ANOVA[b]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	433687.8	1	433687.833	99.587	.000[a]
	Residual	862264.2	198	4354.870		
	Total	1295952	199			

a. Predictors: (Constant), Advertsing Budget (thousands of pounds)

b. Dependent Variable: Record Sales (thousands)

الخرج 2.5

2.4.5 بارامترات النموذج

يخبرنا تحليل التباين ANOVA فيما إذا كان النموذج يعطي درجة جيدة من التوقّع لمتحول النتيجة. ولكنه لا يخبرنا عن المساهمة المنفصلة للمتحولات في النموذج (مع أنه في هذه الحالة البسيطة هناك متحول واحد فقط للنموذج ولذلك يمكننا استنتاج أن هذا المتحول هو متنبئ جيد). يوفر الجدول في (الخرج 3.5) تفاصيلاً عن بارامترات النموذج ودلالة هذه القيم. رأينا في المعادلة (2.5) أن قيمة b_0 هي الاعتراض (التقاطع مع المحور الشاقولي Y) وهذه القيمة هي B في الخرج الذي يعطيه برنامج SPSS في السطر Constant. لذلك، ومن هذا الجدول يمكننا أن نقول أن قيمة b_0=134.14 ويمكن تفسير ذلك بأنه عند عدم إنفاق أي مبلغ في الحملة الإعلانية (أي عندما X=0) فإن النموذج يتوقع أن يتم بيع 134,140 أسطوانة فقط (تذكر أن وحدة القياس المستخدمة هي آلاف الأسطوانات أي 134.14*1000=134,140). يمكننا أن نقرأ أيضاً قيمة b_1 من الجدول، وهي تمثل ميل خط التراجع. وتبلغ قيمتها b_1=9.612E-2 (وهي شكل مختصر للقيمة 0.09612). ومع أن هذه القيمة تمثل ميل خط التراجع فمن الأفضل التفكير بأنها تمثيل للتغير في النتيجة المرتبط بتغير بمقدار الوحدة في المتحول التنبؤي. ولذلك إذا ازداد المتحول التنبؤي بمقدار وحدة فقط (أي إذا ازدادت ميزانية الترويج بمقدار 1) فإن النموذج يتوقع زيادة في مبيعات الأسطوانات قدرها 0.09612 أسطوانة. وبما أن وحدة القياس كانت آلاف الجنيهات وآلاف الأسطوانات المباعة، فإننا نستطيع القول أنه عند زيادة الحملة الترويجية بمقدار 1000 جنيه فإن النموذج يتوقع زيادة في المبيعات قدرها 0.09612*1000=96.12 أسطوانة. وكما ترى فإن هذا الاستثمار سيء للغاية بالنسبة لشركة الأسطوانات، إذ أنها تنفق 1000 جنيه لتحسين المبيعات بمقدار 96.12 أسطوانة. ولكن لحسن الحظ أننا نعلم (من الفقرة السابقة) أن ميزانية الإعلانات تساهم بمقدار 33.5% فقط من مبيعات الأسطوانات.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	134.140	7.537		17.799	.000
	Advertising Budget (thousands of pounds)	9.612E-02	.010	.578	9.979	.000

a. Dependent Variable: Record Sales (thousands)

الخرج 3.5

رأينا سابقاً أن قيم معاملات التراجع b، وبشكل عام، تمثل التغير في النتيجة الذي ينتج عن التغير بمقدار الوحدة في المتحول التنبؤي، وأنه إذا كان للمتحول التنبؤي أثر هام على مقدرتنا في توقّع النتيجة فإن قيم b يجب أن تكون مختلفة عن الصفر (وكبيرة مقارنة بالخطأ المعياري لها). ورأينا أيضاً أن اختبار t يخبرنا فيما إذا كانت قيم b مختلفة عن الصفر. يوفر برنامج SPSS الاحتمال الصحيح

لحدوث القيمة المشاهدة للاختبار t إذا كانت قيم b مساوية للصفر. وكقاعدة عامة، إذا كانت الدلالة المشاهدة أقل من 0.05 فإن علماء الاجتماع يقبلون أن النتيجة تعكس أثراً حقيقياً (انظر الفصل 1). ومن أجل هاتين القيمتين فإن الاحتمال هو 0.000 (صفر حتى المنزلة العشرية الثالثة) ولذلك يمكننا القول أن احتمال حصول القيم t إذا كانت قيم b مساوية للصفر هو أقل من 0.001 ولذلك نقول أن قيم b مختلفة عن الصفر ونستنتج أن ميزانية الترويج تساهم بشكل معقول ($p<0.001$) في التنبؤ بمبيعات الأسطوانات.

3.4.5 استخدام النموذج

والآن بعد أن اكتشفنا أن لدينا نموذجاً مفيداً يمكنه تحسين مقدرتنا على التنبؤ بالمبيعات بشكل جيد، فإننا ننتقل إلى المرحلة التالية والتي غالباً ما تكون استخدام ذلك النموذج للقيام ببعض التوقعات. في المرحلة الأولى يتم تعريف النموذج بتعويض قيم b في المعادلة (2.5) من الجدول في الخرج 3.5. بالإضافة لذلك يمكننا استبدال X و Y بأسماء المتحولات التي تمثلها، فيأخذ النموذج الشكل التالي:

$$\begin{aligned}\text{Record Sales}_i &= b_0 + b_1 \times \text{Advertising Budget}_i \\ &= 134.14 + (0.09612 \times \text{Advertising Budget}_i)\end{aligned} \quad (7.5)$$

من الممكن الآن القيام بتوقعات حول مبيعات الاسطوانات، وذلك باستبدال ميزانية الترويج Advertising Budget بالقيمة العددية التي نريدها. فعلى سبيل المثال تخيل أننا نريد أن ننفق 100,000 جنيه في الترويج لأسطوانة موسيقية جديدة. تذكر أن الوحدات المستخدمة هي آلاف الجنيهات، لذلك يمكننا استبدال ميزانية الترويج في المعادلة (7.5) بالقيمة 100. فنكتشف أن مبيعات الأسطوانة ستكون حوالي 144,000 أسطوانة خلال الأسبوع الأول من إطلاقها:

$$\begin{aligned}\text{Record Sales}_i &= 134.14 + (0.09612 \times \text{Advertising Budget}_i) \\ &= 134.14 + (0.09612 \times 100) = 143.75\end{aligned} \quad (8.5)$$

5.5 التراجع المتعدد: الأساسيات

لتلخيص ما تعلمناه سابقاً يمكننا القول أنه في التراجع الخطي البسيط يتم التنبؤ بمتحول النتيجة Y باستخدام معادلة الخط المستقيم (المعادلة (2.5)). وبعد أن نجمع قيماً عديدة لكل من Y و X يمكننا حساب البارامترات المجهولة في تلك المعادلة. يتم الحساب بملاءمة النموذج للبيانات (في هذه الحالة، النموذج هو الخط المستقيم) بحيث يكون مجموع المربعات للفروق بين الخط المستقيم ونقاط البيانات الفعلية أصغرياً. تدعى هذه الطريقة بطريقة المربعات الصغرى. يعتبر التراجع المتعدد توسيعاً منطقياً لهذه المبادئ ليشمل الحالات التي توجد فيها مجموعة من المتحولات التنبؤية. ونستخدم مرة أخرى المعادلة الأساسية التالية:

$$\text{Outcome}_i = (\text{Model}_i) + \text{error}_i$$

ولكن النموذج في هذه المرة سيكون أكثر تعقيداً. إنه بشكل أساسي مشابه للتراجع البسيط باستثناء أنه من أجل كل متحول تنبؤي إضافي نقوم بإضافة معامل جديد، وبذلك يكون لكل متحول تنبؤي معامله الخاص، ويتم التنبؤ بقيمة متحول النتيجة بتركيب من جميع المتحولات التنبؤية مضروبة بمعاملاتها الخاصة إضافة لقسم الباقي (انظر المعادلة (9.5)، الأقواس ليست ضرورية ولكننا استخدمناها للمحافظة على الربط مع المعادلة العامة):

$$Y_i = (b_0 + b_1 X_1 + b_2 X_2 + \cdots + b_n X_n) + \varepsilon_i \qquad (9.5)$$

يمثل Y متحول النتيجة، و b_1 المعامل للمتحول التنبؤي الأول (X_1)، و b_2 المعامل للمتحول التنبؤي الثاني (X_2)، و b_n المعامل للمتحول التنبؤي رقم n أي (X_n)، و ε_i هو الفرق بين القيمة المتوقعة والمشاهدة للنتيجة Y من أجل المشترك رقم i. في هذه الحالة يكون النموذج المتوافق أكثر تعقيداً، ولكن المبدأ الأساسي يبقى ذاته كما في حالة التراجع البسيط. وهكذا فإننا نبحث عن تركيب خطي للمتحولات التنبؤية يرتبط بشكل أعظمي مع متحول النتيجة. ولذلك عندما نشير لنموذج التراجع في التراجع المتعدد فإننا نتحدث عن النموذج الذي يأخذ شكل المعادلة (9.5).

1.5.5 مثال عن نموذج التراجع المتعدد

تخيل أن المدير التنفيذي لشركة الأسطوانات كان مهتماً بتوسيع نموذج المبيعات ليشمل متحولاً آخر. نعلم سابقاً أن الإعلانات تشكل 33.5% من التغاير في حجم المبيعات، ولكن النسبة الكبرى من التغاير والبالغة 66.5% تبقى غير معروفة الأسباب. يمكن للمدير التنفيذي أن يقيس متحولاً تنبؤياً جديداً للنموذج في محاولة لتفسير التغاير غير المبرر في حجم المبيعات. لقد قرر قياس عدد المرات التي تتم فيها بث التسجيل الجديد عبر الإذاعة الوطنية خلال الأسبوع الذي يسبق إطلاق الأسطوانة في السوق. يمكننا الآن توسيع النموذج الذي أوجدناه في برنامج SPSS (المعادلة (7.5)) ليشمل المتحول الجديد airplay:

$$\text{Record Sales}_i = b_0 + b_1 \times \text{Advertising Budget}_i + b_2 \times \text{Airplay}_i + \varepsilon_i \qquad (10.5)$$

يستند النموذج الجديد على المعادلة (9.5) ويتضمن قيم b لكل من المتحولين التنبؤيين (وطبعاً للحد الثابت). إذا حسبنا قيم b فيمكننا إجراء التوقعات عن مبيعات الأسطوانات بناءً على مبالغ الإعلانات المصروفة وعلى عدد مرات بث التسجيل عبر الإذاعة. ونظراً لوجود متحولين تنبؤيين فقط في هذا النموذج فإنه يمكننا عرض النموذج بيانياً على مخطط مبعثر ثلاثي الأبعاد (الشكل 6.5).

تصف المعادلة (9.5) شبه المنحرف المظلل في المخطط (والذي يعرف باسم مستوي التراجع (regression plane)) وتمثل النقاط الدائرية نقاط البيانات المشاهدة. وكما في حالة التراجع البسيط فإن المستوي الملائم للبيانات يهدف لإيجاد أفضل تنبؤ للبيانات المشاهدة. ولكن هناك دائماً بعض الفروق بين النموذج وبيانات العالم الحقيقي (وهذه الحقيقة واضحة لأن بعض النقاط لا تقع على المستوي المظلل تماماً في المخطط). تصف قيم b للإعلانات ميل القمة والقاعدة لمستوي التراجع،

بينما تمثل قيم b للبث الإذاعي ميل الجانبين الأيسر والأيمن لمستوي التراجع. وبمعرفة هذين الميلين يمكننا وضع مستوي التراجع في مكانه.

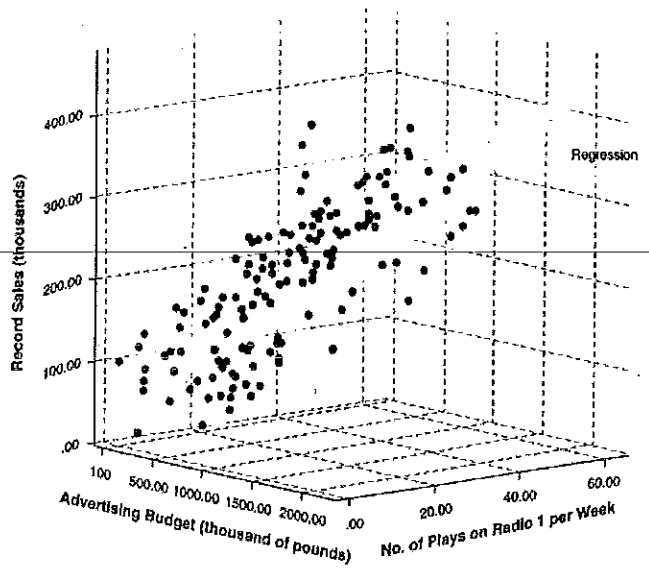

الشكل 6.5 مخطط مبعثر يظهر العلاقة بين مبيعات الأسطوانات وميزانية الإعلانات والبث عبر الإذاعة

من السهل معاينة نموذج التراجع بوجود متحولين تنبؤيين، لأنه من الممكن رسم مستوي التراجع باستخدام المخطط المبعثر ثلاثي الأبعاد. إلا أن التراجع المتعدد قد يستخدم ثلاثة متحولات أو أكثر. ومع أنه لا يمكنك في تلك الحالات معاينة النماذج المعقدة أو معرفة ماذا تمثل قيم b فيجب أن تكون قادراً على تطبيق مبادئ هذه النماذج الأساسية على النماذج الأكثر تعقيداً.

2.5.5 مجاميع المربعات و R و R^2

بوجود عدد من المتحولات التنبؤية فإن تجزئة مجاميع المربعات تتم بنفس الطريقة المتبعة في حالة متحول تنبؤي وحيد باستثناء أن النموذج الذي نقصده سيكون ممثلاً بالمعادلة (9.5) بدلاً من الخط المستقيم ثنائي الأبعاد. ولذلك فإنه يمكن حساب SS_T باعتباره يمثل الفرق بين القيم المشاهدة وقيمة المتوسط لمتحول النتيجة. ويمثل SS_R الفرق بين قيم Y المتوقعة من قِبَل النموذج والقيم المشاهدة. وأخيراً يمكن حساب SS_M الذي مازال يمثل الفرق بين قيم Y المتوقعة من قِبَل النموذج وقيمة المتوسط. ومع أن حساب هذه القيم أكثر تعقيداً من حالة التراجع البسيط فإن هذه القيم من ناحية المبدأ هي ذاتها.

عند وجود عدد من المتحولات التنبؤية، يصبح النظر إلى معامل الارتباط البسيط عديم الفائدة، ويقوم برنامج SPSS بإنتاج معامل ارتباط متعدد يدعى مضاعف R (Multiple R). ومضاعف R هو الارتباط بين القيم المشاهدة للنتيجة Y وقيم Y المتوقعة من قِبَل نموذج التراجع المتعدد. ولذلك فإن القيم الكبيرة لمضاعف R تمثل ارتباطاً كبيراً بين القيم المتوقعة والمشاهدة للنتيجة. تمثل القيمة 1 للمضاعف R الحالة التي يتوقع فيها النموذج القيم المشاهدة بشكل تام. وهكذا فالمضاعف R هو مؤشر لمدى تنبؤ النموذج بالقيم المشاهدة. وينتج عن ذلك أنه يمكن تفسير R^2 بنفس الطريقة كما في حالة التراجع البسيط، إنه مقدار التغاير في متحول النتيجة الذي يمكن تفسيره من قِبَل النموذج.

3.5.5 طرق التراجع

إذا كنا مهتمين ببناء نموذج معقد بعدة متحولات تنبؤية، فكيف يمكننا أن نحدد المتحولات التي نريد استخدامها؟ يجب الانتباه بشكل كبير لمسألة اختيار المتحولات التنبؤية في النموذج لأن قيم معاملات التراجع تعتمد على المتحولات في النموذج. ولذلك فقد يكون للمتحولات التنبؤية المضمّنة والطريقة التي تم إدخالها بها في النموذج أثر كبير. في عالم مثالي، يجب أن يتم اختيار المتحولات التنبؤية بناءً على أبحاث سابقة. إذا تمت إضافة متحولات تنبؤية جديدة إلى نموذج موجود فيتم اختيار هذه المتحولات الجديدة بناءً على الأهمية النظرية الجوهرية لهذه المتحولات. ولكن هناك شيء يجب عدم القيام به وهو اختيار المئات من المتحولات التنبؤية العشوائية ووضعها ضمن تحليل التراجع وتمني الحصول على أفضل نتيجة! إضافة لمشكلة اختيار المتحولات التنبؤية، فإن هناك عدة طرق يتم بها إدخال المتحولات إلى النموذج. عندما تكون جميع المتحولات التنبؤية غير مرتبطة بأي شكل فإن لترتيب المتحول أثر ضئيل جداً على البارامترات المحسوبة، وعلى كل حال فإنه في أبحاث علم الاجتماع نادراً ما تكون المتحولات التنبؤية غير مرتبطة ولذلك فإن طريقة اختيار المتحول التنبؤي تكون حاسمة.

1.3.5.5 الإدخال الهرمي

يتم في التراجع الهرمي اختيار المتحولات التنبؤية بناءً على الأعمال السابقة، ويقرر المختبِر ترتيب الإدخال للمتحولات التنبؤية في النموذج. وكقاعدة عامة، يجب إدخال المتحولات التنبؤية المعروفة (من الأبحاث الأخرى) في البداية إلى النموذج بحسب ترتيب أهميتها. وبعد إدخال المتحولات التنبؤية المعروفة، يمكن للمختبِر إدخال أيّ من المتحولات التنبؤية الجديدة في النموذج. يمكن إدخال جميع المتحولات التنبؤية الجديدة دفعة واحدة، بطريقة خطوية أو هرمية (بحيث يتم في البداية إدخال المتحول التنبؤي الذي نشك بأنه الأكثر أهمية).

2.3.5.5 الإدخال القسري

يتم في الإدخال القسري (أو طريقة Enter كما هي معروفة في برنامج SPSS) إجبار جميع المتحولات التنبؤية على الدخول في النموذج بآن واحد. وكالإدخال الهرمي فإن هذه الطريقة تعتمد بشكل كبير على الأسباب النظرية الجيدة لتضمين المتحولات التنبؤية المختارة في النموذج، ولكنها تختلف عنها بأنه ليس للمختبِر دور في ترتيب إدخال المتحولات.

3.3.5.5 الطرق الخطوية

يتم في التراجع الخطوي اتخاذ القرارات حول ترتيب إدخال المتحولات التنبؤية في النموذج بناءً على معيار رياضي صرف. ففي الطريقة التقدميّة (forward) يتم تعريف نموذج أولي يحوي الثابت b_0 فقط. يبحث البرنامج بعدئذ عن المتحول التنبؤي (من بين المتحولات المتوفرة) الذي يتوقع بشكل أفضل متحول النتيجة، ويقوم بذلك باختياره المتحول التنبؤي الذي يعطي الارتباط البسيط الأعلى مع النتيجة. إذا حسّن هذا المتحول التنبؤي مقدرة النموذج على التنبؤ بالنتيجة بشكل كبير فيتم الاحتفاظ بهذا المتحول في النموذج يبحث البرنامج عن متحول تنبؤي ثان. إن المعيار المستخدم لاختيار هذا المتحول الثاني هو أن يكون لهذا المتحول الارتباط شبه الجزئي الأكبر مع النتيجة. لنشرح ذلك بلغة واضحة. تخيل أن المتحول التنبؤي الأول قادر على تبرير 40% من التغاير لمتحول النتيجة، مازال هناك 60% من التغاير مجهول الأسباب. يبحث البرنامج عن المتحول التنبؤي الذي يستطيع تبرير الجزء الأكبر من النسبة 60% المتبقية (لذلك، فإنه غير مهتم بالنسبة 40% التي تم تبريرها سابقاً). وبمصطلحات إحصائية يمكننا التفكير بذلك على أنه ارتباط جزئي يقوم البرنامج فيه بإجراء الارتباط لكل من المتحولات التنبؤية مع متحول النتيجة وبالتحكم بأثر المتحول التنبؤي الأول. ويدعى هذا الارتباط بالارتباط شبه الجزئي (semi-partial correlation) لأن آثار المتحول التنبؤي الأول هي جزئية للمتحولات التنبؤية الباقية فقط، ولا يتم التحكم بها في النتيجة ذاتها. يعطي هذا الارتباط شبه الجزئي مقياساً لمدى تبرير التباين الجديد في النتيجة من قِبَل كل من المتحولات التنبؤية المتبقية (انظر الفقرة 6.4). تتم إضافة المتحول التنبؤي الذي يساهم بأكبر نسبة من التباين الجديد إلى النموذج، فإذا كانت مساهمته كبيرة في القدرة التنبؤية للنموذج فيتم الاحتفاظ به والانتقال لأخذ متحول تنبؤي جديد بعين الاعتبار.

إن الطريقة الخطوية (stepwise) مماثلة للطريقة التقدمية في برنامج SPSS، باستثناء أنه في كل مرة تتم فيها إضافة متحول تنبؤي إلى المعادلة يتم تنفيذ اختبار إزالة للتخلص من المتحول التنبؤي الأقل فائدة. وهكذا تتم إعادة تقييم معادلة التراجع باستمرار للتمكن من إزالة المتحولات التنبؤية الفائضة. أما الطريقة التراجعية (backward) فهي معاكسة للطريقة التقدمية، حيث يبدأ البرنامج بوضع جميع المتحولات التنبؤية في النموذج ثم يحسب مساهمة كل متحول وذلك بالنظر إلى قيمة الدلالة لاختبار t لكل من المتحولات التنبؤية. تتم مقارنة الدلالة مع معيار الإزالة (الذي يمكن أن

يكون قيمة مطلقة لإحصائية الاختبار أو قيمة الاحتمال لإحصائية الاختبار تلك). إذا حققت المتحولات التنبؤية معيار الإزالة (أي أنها لا تقدم مساهمة ذات دلالة إحصائية لمدى جودة توقّع النموذج لمتحول النتيجة) تتم إزالتها من النموذج وتتم إعادة تقدير النموذج للمتحولات التنبؤية المتبقية. وتتم إعادة تقييم مساهمة بقية المتحولات التنبؤية.

إذا قررت استخدام طريقة خطوية فإن الطريقة التراجعية هي المفضلة على الطريقة التقدمية. وذلك بسبب الآثار المخمّدة (suppressor effects) التي تحدث عندما يكون لأحد المتحولات التنبؤية أثر هام وذلك عندما يبقى متحول آخر ثابتاً. يفضل الاختيار التقدمي على الحذف التراجعي لإقصاء المتحولات التنبؤية المتضمنة في الآثار المخمدة. وهكذا، تعمل الطريقة التقدمية بمخاطر أعلى في القيام بأخطاء من النوع الثاني (Type II error) (كضياع متحول تنبؤي يتوقع النتيجة عملياً).

4.3.5.5 اختيار طريقة

يسمح برنامج SPSS باختيار واحدة من الطرق المذكورة، ومن المهم اختيار الطريقة المناسبة. وتندرج الطرق الثلاث التقدمية والخطوية والتراجعية تحت التسمية العامة الطرق الخطوية (stepwise methods) لأنها تعتمد جميعاً على اختيار البرنامج للمتحولات بناءً على المعايير الرياضية. ويحتج بعض الكتّاب على أن ذلك يسحب بعض القرارات المنهجية الهامة من بين أيدي الباحث. وأكثر من ذلك، أن النماذج المشتقة من قِبَل البرنامج تستفيد من تغاير أخذ العينات العشوائي، وبذلك تكون القرارات حول المتحولات التي يجب تضمينها مستنداً على فروق ضئيلة في معامل الارتباط شبه الجزئي لها. على كل حال، قد تتباين هذه الفروق الإحصائية الضئيلة بشكل كبير مع الأهمية النظرية لمتحول تنبؤي معين في النموذج. ولهذا السبب تم تجنب الطرق الخطوية إلا في حالة بناء نموذج استكشافي. عندما تتوفر أدبيات نظرية جادة، يجب عليك بناء النموذج اعتماداً على ما تخبرك به الأبحاث السابقة. وحاول تضمين المتحولات المفيدة في النموذج حسب ترتيب أهميتها. بعد التحليل الأولي، كرر التراجع مع استثناء المتحولات الفائضة إحصائياً في الجولة الأولى. هناك اعتبارات هامة في اتخاذ القرار بشأن المتحولات التنبؤية التي سيتم تضمينها. من المهم عدم تضمين عدد كبير من المتحولات التنبؤية. وكقاعدة عامة، كلما قلّ عدد المتحولات التنبؤية كان ذلك أفضل، ويجب تضمين المتحولات التنبؤية التي تملك أرضية نظرية جيدة (فمن غير المعقول قياس المئات من المتحولات ثم وضعها جميعاً في نموذج التراجع). كن انتقائياً وتذكّر أن لديك حجم عينة معقولاً (يقترح البعض 15 مشتركاً على الأقل لكل متحول تنبؤي، ولكن انظر الفقرة 3.2.6.5).

6.5 ما مدى دقة نموذج التراجع؟

عند استنتاج نموذج التراجع بناءً على عينة من البيانات، يُطرح السؤالان الهامّان التاليان: (1) هل يتوافق النموذج مع البيانات المشاهدة بشكل جيد، أم أنه تأثر بعدد صغير من الحالات، و(2) هل

يمكن تعميم أي نموذج على العينات الأخرى؟ من الضروري طرح هذه الأسئلة لأنها تؤثر على كيفية استخدامنا للنموذج الذي تم بناؤه. وهذه الأسئلة بمعنى آخر هي هرمية، لأننا لا نريد تعميم أي نموذج سيء. وعلى كل حال، من الخطأ التفكير أنه طالما توافق النموذج مع البيانات المشاهدة بشكل جيد فإنه يمكننا الوصول إلى استنتاجات تتعدى العينة. إن التعميم (Generalization) هو خطوة إضافية حرجة، وإذا وجدنا أن النموذج غير قابلٍ للتعميم فإن علينا حصر الاستنتاجات المستندة إلى النموذج بالعينة المستخدمة فقط. سنبحث أولاً في كيفية تحديد فيما إذا كان النموذج هو تمثيل دقيق للبيانات الفعلية، ثم ننتقل في الفقرة 2.6.5 للبحث في كيفية تقييم فيما إذا كان ممكناً استخدام النموذج للحصول على استنتاجات تتعدى عينة البيانات التي تم جمعها.

1.6.5 تقييم نموذج التراجع: التشخيص

للإجابة على السؤال فيما إذا كان النموذج يتوافق مع البيانات المشاهدة بشكل جيد، أو أنه قد تأثر بعدد صغير من الحالات، فإنه يمكننا النظر إلى النقاط المنعزلة والحالات المؤثرة (يوضح المربع 1.5 الفرق بينهما).

1.1.6.5 النقاط المنعزلة والبواقي

النقطة المنعزلة هي حالة تختلف بشكل كبير عن المنحى الرئيسي للبيانات (انظر المربع 1.3 في الفصل 3). يوضح (الشكل 7.5) مثالاً عن هذه الحالة في التراجع. يمكن أن تسبب النقاط المنعزلة انحرافاً للنموذج وذلك لأنها تؤثر على قيم معاملات التراجع التي يتم تقديرها. فعلى سبيل المثال، يستخدم (الشكل 7.5) نفس البيانات المستخدمة في الشكل 2.5 باستثناء أن علامات أحد المشتركين قد تم تعديلها لتعطي نقطة منعزلة (وهي هنا حالة الشخص الذي بقي هادئاً جداً بوجود عنكبوت ضخم جداً). لقد كان لتعديل نقطة واحدة أثر كبير على نموذج التراجع المختار لملاءمة البيانات. لقد تغير نموذج التراجع بوجود النقطة المنعزلة، إذ انخفض ميله (أصبح الخط أكثر تسطحاً) وازداد الاعتراض (يتقاطع المستقيم الجديد مع المحور الشاقولي في نقطة أعلى). يجب أن يكون واضحاً من هذا المخطط أنه من المهم البحث عن النقاط المنعزلة لمعرفة مدى تأثيرها على النموذج.

كيف يمكنك اكتشاف نقطة منعزلة؟ نعلم أن النقطة المنعزلة تكون بطبيعتها مختلفة جداً عن جميع النقاط الأخرى. وبأخذ هذه الحقيقة بعين الاعتبار، هل تعتقد أن النموذج سيكون قادراً على التنبؤ بعلامة ذلك الشخص بدقة كبيرة؟ من الواضح أن الجواب هو لا، وإذا نظرنا إلى الشكل 7.5 فمن الواضح أنه على الرغم من تأثير النقطة المنعزلة على النموذج، فمازال النموذج يتوقع هذه القيمة بشكل سيء للغاية (لأن خط التراجع بعيد جداً عن النقطة المنعزلة). لذلك إذا حسبنا الفروق بين قيم البيانات التي تم جمعها والقيم المتوقعة من النموذج، فإنه يمكننا اكتشاف النقطة المنعزلة بالنظر إلى الفروق الكبيرة. وهذه العملية شبيهة بالبحث عن الحالات التي يتوقعها النموذج بشكل غير دقيق.

تُعرف الفروق بين قيم النتيجة المتوقعة من النموذج وقيم النتيجة المشاهدة في العينة بالبواقي. تمثل هذه البواقي الخطأ الموجود في النموذج بشكل فعّال. إذا كان النموذج يتوافق مع بيانات العينة بشكل جيد فإن البواقي ستكون صغيرة (إذا كان النموذج يتوافق بشكل تام مع بيانات العينة فإن جميع نقاط البيانات ستقع على خط التراجع، وستكون جميع البواقي معدومة). أما إذا كان النموذج يتوافق مع بيانات العينة بشكل ضعيف فإن البواقي ستكون كبيرة. وإذا كانت بعض الحالات تملك باقياً كبيراً فمن المحتمل أن تكون نقاطاً معزولة.

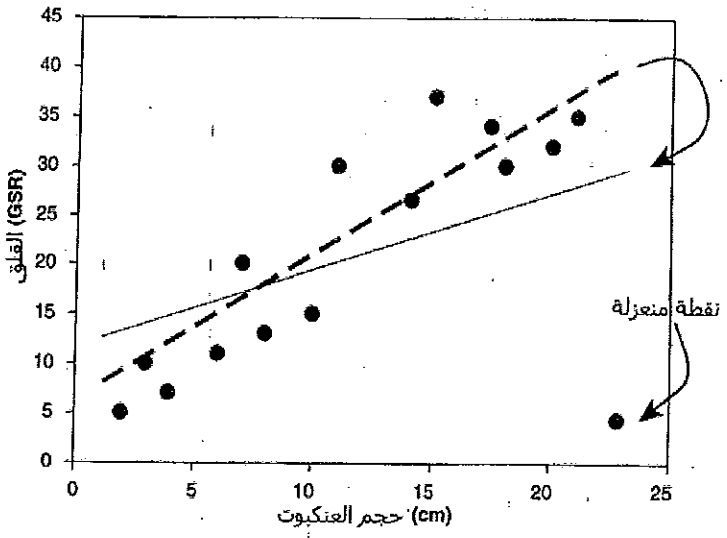

الشكل 7.5 يوضح المخطط البياني أثر نقطة منعزلة. يمثل الخط المتقطع خط التراجع الأصلي للبيانات (انظر الشكل 2.5) بينما يمثل الخط المستمر خط التراجع عند وجود نقطة منعزلة.

تقاس البواقي الطبيعية أو غير القياسية (normal or unstandardized residuals) الموصوفة أعلاه بنفس وحدات القياس لمتحول النتيجة، ولذلك يصعب تفسيرها عبر النماذج المختلفة. وما يمكننا فعله هو البحث عن البواقي الكبيرة بشكل خاص. وعلى كل حال، لا يمكننا تعريف نقطة قطع عامة لما يمكن أن يشكل باقياً كبيراً. للتغلب على هذه المشكلة، نستخدم البواقي المعيارية (standardized residuals) وهي ناتج قسمة البواقي على انحرافها المعياري المقدّر. وقد ناقشنا موضوع التوحيد القياسي في الفقرة 1.4.1 كوسيلة لتحويل المتحولات إلى وحدة قياسية للقياس (الانحراف المعياري)، كما ناقشنا العلامات المعيارية أو علامات z (انظر المربع 2.3) حيث يتم تحويل المتحولات إلى وحدات الانحراف المعياري (وذلك بتحويلها إلى علامات موزعة حول قيمة المتوسط 0 مع انحراف معياري 1). بتحويل البواقي إلى علامات z (البواقي المعيارية) يمكننا مقارنة البواقي من النماذج المختلفة واستخدام ما نعرفه عن خصائص العلامات z لابتكار تعليمات عامة لما يمكن أن يشكل قيمة مقبولة (أو غير مقبولة). فعلى سبيل المثال، نعلم من الفصل 3 أنه في عينة

موزعة طبيعياً يجب أن تقع 95% من علامات z بين 1.96- و1.96+، وأن تقع 99% من علامات z بين 2.58- و 2.58+، وأن تقع 99.9% من علامات z بين 3.29- و3.29+. يتم اشتقاق بعض القواعد العامة للبواقي المعيارية من الحقائق التالية: (1) البواقي المعيارية التي تكون قيمتها المطلقة أكبر من 3.29 (ونستخدم عملياً القيمة 3) هي موضع اهتمام لأنه في عينة متوسطة لا تحدث مثل هذه القيمة المرتفعة بالصدفة، (2) إذا كانت نسبة البواقي المعيارية التي تكون قيمتها المطلقة أكبر من 2.58 (ونستخدم عادة القيمة 2.5) تشكل أكثر من 1% من العينة فإن من الواضح أن مستوى الخطأ ضمن العينة غير مقبول (يتوافق النموذج بشكل ضعيف مع بيانات العينة)، و(3) إذا كانت نسبة البواقي المعيارية التي تكون قيمتها المطلقة أكبر من 1.96 (ونستخدم عادة القيمة 2) تشكل أكثر من 5% من العينة فإن من الواضح أن النموذج يمثل البيانات الفعلية بشكل ضعيف.

هناك شكل ثالث للبواقي هو Studentized residual وهو حاصل قسمة الباقي غير القياسي على قيمة تقديرية لانحرافه المعياري الذي يتغير من نقطة إلى أخرى. ولهذه البواقي نفس خصائص البواقي المعيارية ولكنها توفر تقديراً أكثر دقة لتباين الخطأ من أجل حالة معينة.

2.1.6.5 الحالات المؤثرة

يتم البحث عن النقاط المنعزلة بالنظر إلى الخطأ في النموذج، ومن الممكن البحث فيما إذا كانت هناك حالات تؤثر بشكل فعال على بارامترات النموذج. لذلك إذا أردنا حذف حالة معينة فهل سنحصل على معاملات تراجع مختلفة؟ يمكن أن يساعد هذا النوع من التحليل في تحديد فيما إذا كان نموذج التراجع مستقراً عبر العينة أم أنه يتأثر ببعض الحالات القليلة المؤثرة. ومرة أخرى تكشف هذه العملية النقاط المنعزلة.

هناك إحصائيات متعددة للباقي يمكن استخدامها لتقييم تأثير حالة معينة. إحدى الإحصائيات هي القيمة المتوقعة المعدّلة (adjusted predicted value) لحالة ما عندما تكون تلك الحالة مستثناة من التحليل. في الحقيقة، يقوم البرنامج بحساب نموذج جديد بدون حالة معينة ثم يستخدم هذا النموذج للتنبؤ بقيمة متحول النتيجة من أجل الحالة التي تم استثناؤها. إذا لم يكن لحالة ما تأثير كبير على النموذج فيمكننا أن نتوقع أن القيمة المتوقعة المعدّلة ستكون مشابهة للقيمة المتوقعة عندما تكون تلك الحالة مضمّنة. وببساطة إذا كان النموذج مستقراً فإن القيمة المتوقعة لحالة ما يجب أن تكون نفسها بغض النظر عما إذا كانت تلك الحالة مستخدمة في حساب النموذج أم لا. يُرمز للفرق بين القيمة المتوقعة المعدّلة والقيمة المتوقعة الأصلية بالرمز DFFit (انظر تعريفه لاحقاً). يمكننا أن ننظر أيضاً إلى الباقي المستند إلى القيمة المتوقعة المعدّلة، وهو الفرق بين القيمة المتوقعة المعدّلة والقيمة المشاهدة الأصلية، وهو ما يُعرف بالباقي المحذوف (deleted residual). يمكن تقسيم الباقي المحذوف على الخطأ المعياري للحصول على القيمة المعيارية المسماة Studentized deleted residual. يمكن مقارنة هذا الباقي عبر تحاليل التراجع المختلفة لأنه مقاسٌ بالوحدات القياسية.

إن البواقي المحذوفة مفيدة جداً لتقييم التأثير لحالة ما على مقدرة النموذج على توقّع تلك الحالة. ولكنها لا توفر أي معلومات عن مدى تأثير حالة ما على النموذج ككل (أي أثر تلك الحالة على مقدرة النموذج على توقّع جميع الحالات). هناك إحصائية تأخذ بعين الاعتبار أثر حالة معينة على النموذج ككل هي مسافة Cook (Cook's distance). وهي مقياس للتأثير الكلي لحالة ما على النموذج وقد اقترح Cook & Weisberg (1982) أن القيم الأكبر من 1 هي موضع الاهتمام.

هناك مقياس آخر للتأثير هو الفعالية (leverage) (ويدعى أحياناً قيم القبعة hat values) الذي يقيس تأثير القيم المشاهدة لمتحول النتيجة على القيم المتوقعة. يتم تعريف القيمة المتوسطة للفعالية بالشكل (k+1)/n حيث يمثل k عدد المتحولات التنبؤية في النموذج، وn عدد المشتركين[2]. يمكن أن تقع قيم الفعالية بين 0 (وتدل على عدم وجود أي تأثير للحالة) و 1 (وتدل على أن للحالة تأثير كامل على التوقع). إذا لم يكن لأي من الحالات تأثير كبير على النموذج فإننا نتوقع أن تكون جميع قيم الفعالية قريبة من القيمة المتوسطة (k+1)/n. وينصح Hoaglin & Welsch (1978) بالبحث والاستقصاء عن الحالات التي تكون قيمة الفعالية لها أكبر من ضعفي القيمة المتوسطة أي 2(k+1)/n)، وينصح Stevens (1992) باستخدام ثلاثة أمثال القيمة المتوسطة 3(k+1)/n) كنقطة قطع لتعريف الحالات التي تملك تأثيراً كبيراً. وسنرى كيفية استخدام نقاط القطع تلك في الفقرة 6.8.5. وعلى كل حال، فمن غير الضروري أن يكون للحالات ذات القيم الكبيرة للفعالية تأثير كبير على معاملات التراجع لأنها تقاس على متحولات النتيجة بدلاً من المتحولات التنبؤية.

وهناك مسافات Mahalanobis (Mahalanobis distances) (انظر الشكل 8.5) المرتبطة بقيم الفعالية، والتي تقيس المسافة بين الحالات والمتوسط (أو المتوسطات) للمتحول (أو المتحولات) التنبؤية. يجب البحث عن الحالات ذات القيم الأعلى. ليس من السهل إقامة نقطة قطع تعرّف حد القلق، على الرغم من أن Barnett & Lewis (1978) قد أعدّا جدولاً للقيم الحرجة اعتماداً على عدد المتحولات التنبؤية وحجم العينة. ويتضح من عملهما أنه مع العينات الكبيرة (N=500) ومن أجل 5 متحولات تنبؤية فإن القيم الأكبر من 25 هي موضع اهتمام. وفي العينات الصغيرة (N=100) وعدد أقل من المتحولات التنبؤية (3) فإن القيم الأكبر من 15 هي صاحبة الإشكالية، بينما في العينات الصغيرة جداً (N=30) ومتحولين تنبؤيين فقط فإنه يجب دراسة القيم التي تكون أكبر من 11.

من الممكن تنفيذ تحليل التراجع بوجود حالة معينة، ثم إعادة تنفيذ بعد إقصاء تلك الحالة. إذا قمنا بذلك، فسيكون هناك دون أدنى شك بعض الفرق بين معاملات b في معادلتي التراجع. ويخبرنا هذا الفرق عن مقدار تأثير حالة معينة على البارامترات لنموذج التراجع. لنأخذ مثالاً فرضياً، تحليل علاقة عكسية مثالية بين متحولين باستثناء حالة وحيدة (الحالة 30). إذا تم تنفيذ تحليل التراجع على

2 يمكن أن تصادف القيمة المتوسطة للفعالية مكتوبة بالشكل p/n حيث يمثل p عدد البارامترات التي يتم تقديرها. في التراجع المتعدد، يتم تقدير البارامترات لكل من المتحولات التنبؤية وكذلك للحد الثابت، وبذلك تكون p مساوية لعدد المتحولات التنبؤية مضافاً له العدد 1 أي (k+1).

الحالات 29 المرتبطة خطياً بشكل مثالي فإننا سنحصل على نموذج يتوقّع فيه المتحول التنبؤي X متحول النتيجة Y، ولا توجد أية أخطاء. إذا قمنا بعد ذلك بتنفيذ التحليل ولكن مع تضمين الحالة التي كانت مستثناة (الحالة 30) فستكون للنموذج الناتج بارامترات مختلفة. تم تخزين بعض البيانات في الملف dfbeta.sav وهي توضح هذا الوضع. حاول تنفيذ التراجع البسيط أولاً مع تضمين جميع الحالات، ثم احذف الحالة 30 وأعد تنفيذ التحليل. يلخص (الجدول 1.5) تلك النتائج، حيث يعرض (1) البارامترات لنموذج التراجع عندما تكون الحالة القصوى مضمنة أو مستثناة، (2) معادلات التراجع الناتج، (3) قيمة Y المتوقعة من تعويض علامة المشترك 30 في المتحول X.

الشكل 8.5 Prasanta Chandra Mahalanobis يحدّق بمسافاته (Mahalanobis distances)

البارامتر (b)	تضمين الحالة 30	استثناء الحالة 30	الفرق
الحد الثابت (الاعتراض)	29.00	31.00	-2.00
المتحول التنبؤي (الميل)	-0.90	-1.00	0.10
النموذج (خط التراجع)	Y = (-0.9) X + 29	Y = (-1) X + 31	
قيمة Y المتوقعة	28.10	30.00	-1.09

الجدول 1.5 الفرق بين بارامترات نموذج التراجع عند استثناء حالة واحدة

عندما كانت الحالة 30 مستثناة، كانت العلاقة بين البيانات عكسية تماماً لأن قيمة المعامل b_1=-1 (تذكر أن هذا المعامل في التراجع الخطي يكون مساوياً لمعامل Pearson للارتباط)، وأن قيمة (الاعتراض) b_0=31. ولكن عند تضمين الحالة 30 انخفضت قيمة هذين المعاملين[3]. يُرمز للفرق بين قيمة البارامتر المقدّر باستخدام جميع الحالات وقيمة البارامتر المقدّر عند استثناء حالة واحدة

3 انخفضت قيمة b_1 لأن العلاقة بين البيانات لم تعد خطية تماماً، وظهر تباين لا يمكن للنموذج تفسيره.

بالرمز DFBeta في برنامج SPSS. ويتم حسابه لكل حالة ومن أجل جميع البارامترات في النموذج. لذلك وفي مثالنا الفرضي فإن قيمة DFBeta للحد الثابت هي 2-، بينما قيمته للاعتراض هي 0.1. وبالنظر إلى قيم DFBeta فمن الممكن تحديد الحالات التي تملك تأثيراً كبيراً على بارامترات نموذج التراجع. ومرة أخرى يكون لوحدات القياس المستخدمة أثرها على هذه القيم، ولذلك يعطي برنامج SPSS القيم المعيارية standardized DFBeta. وهذه القيم المعيارية أسهل استخداماً لأنه يمكن تطبيق نقاط القطع العامة. في هذه الحالة تشير القيم المطلقة التي تكون أكبر من 1 للحالات ذات الأثر الحقيقي على بارامترات النموذج (ويقترح Stevens أن يُنظر للحالات التي تكون فيها القيمة المطلقة أكبر من 2).

وهناك الإحصائية DFFit المتعلقة بالموضوع، وهي الفرق بين القيمة المتوقعة لحالة ما عندما يتم حساب النموذج بتضمين تلك الحالة وعندما يتم حسابه باستثناء تلك الحالة، وفي هذا المثال تبلغ قيمة هذا الفرق 1.09- (انظر الجدول 1.5). إذا لم تكن الحالة مؤثرة فإن قيمة DFFit لها تكون معدومة، ولذلك نتوقع أن تملك الحالات غير المؤثرة قيم DFFit صغيرة. ولدينا هنا أيضاً مشكلة اعتماد هذه الإحصائية على وحدات القياس للنتيجة، فالقيمة DFFit = 0.5 تكون صغيرة جداً إذا تراوحت قيم النتيجة بين 1 و100، ولكنها تكون كبيرة جداً إذا تغيرت النتيجة في المجال من 0 من 1، ولذلك يعطي برنامج SPSS نسخة معيارية من هذه الإحصائية تدعى standardized DFFit. ولدينا أخيراً نسبة التباين المشترك CVR (covariance ratio) وهي مقياس لمدى تأثير حالة ما على التباين لبارامترات التراجع. ولن ندخل في التفاصيل الحسابية لهذه الإحصائية، وإنما سنكتفي بالقول أنه عندما تكون هذه النسبة قريبة من 1 فإن للحالة تأثير ضئيل جداً على التباين لبارامترات النموذج. وينصح Belsey, Kuh & Welsch (1980) بما يلي:

- إذا كانت $CVR_i > 1+[3(k+1)/n]$ فإن حذف الحالة i سيضرّ بدقة بعض بارامترات النموذج.
- إذا كانت $CVR_i < 1-[3(k+1)/n]$ فإن حذف الحالة i سيحسّن دقة بعض بارامترات النموذج.

ويمثل k عدد المتحولات التنبؤية، و CVR_i نسبة التباين المشترك للمشترك i، و n حجم العينة.

المربع 1.5 الفرق بين البواقي وإحصائيات التأثير

قدمنا في هذه الفقرة وصفاً لطريقتين في البحث عن الحالات التي قد تؤثر على النموذج: البواقي (residuals) و إحصائيات التأثير (influence statistics). ولتوضيح الاختلاف بين هذين المقياسين، تخيل أن عمدة لندن في نهاية القرن الماضي اهتم في أثر شرب الكحول على معدلات الوفاة. تنقسم لندن إلى مناطق مختلفة تدعى boroughs (دوائر مستقلة)، ولذلك قام العمدة بقياس عدد الحانات وعدد الوفيات خلال فترة زمنية في ثماني دوائر مستقلة. يحوي الملف pubs.sav هذه البيانات.

يوضح المخطط المبعثر لهذه البيانات أنه بدون الحالة الأخيرة هناك علاقة خطية مثالية (الخط المتقطع). إن وجود الحالة الأخيرة (رقم 8) يغيّر الخط بشكل كبير (مع أن هذا الخط يمثل توافقاً جيداً مع البيانات، نفّذ تحليل التراجع واكتشف ذلك بنفسك).

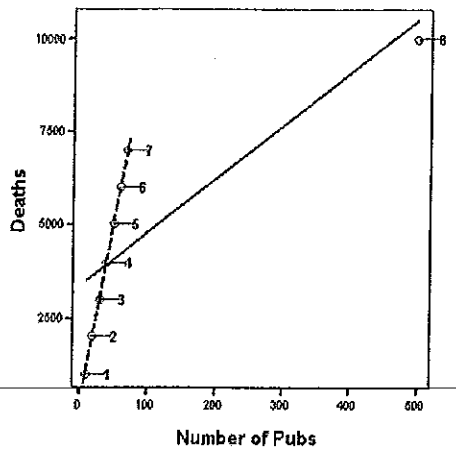

والممتع في هذه البيانات هو البحث عن البواقي وإحصائيات التأثير. إن الباقي المعياري للحالة 8 هو ثاني البواقي من حيث الصغر، أي أن النقطة المنعزلة أعطت باقياً صغيراً جداً مقارنة ببقية النقاط (غير المنعزلة) التي أعطيت باقياً أكبر، وذلك لأنها قريبة جداً من الخط المتوافق مع البيانات. كيف يمكن أن يحدث ذلك؟ لننظر إلى إحصائيات التأثير ومدى فعاليتها. للحالة 8 تأثير هائل على النموذج.

وعندما ترى غرابة أو شذوذاً إحصائياً فإنه ينبغي عليك التساؤل عما حدث في العالم الحقيقي. تمثل نقطة البيانات الأخيرة City of London وهي منطقة صغيرة لا تتجاوز مساحتها ميلاً مربعاً واحداً تقع في مركز مدينة لندن، يعيش فيها عدد قليل من السكان، ولكن يقصدها آلاف العمال للعمل يومياً ويتناولون طعامهم في حاناتها. وبما أن الحانات لا تعتمد في عملها على سكان المنطقة فإن هناك عدداً كبيراً من الحانات.

يوضح ذلك أن حالة مؤثرة بشكل كبير قد تعطي باقياً صغيراً جداً، لذلك يجب النظر إلى الاثنين: الباقي والتأثير.

Case Summaries[a]

		Standardized Residual	Centred Leverage Value	Standardized DFFIT	Standardized DFBETA Intercept	Standardized DFBETA PUBS
1		-1.33839	.04074	-.74402	-.74317	.36886
2		-.87895	.03196	-.40964	-.40766	.18484
3		-.41950	.02424	-.17697	-.17494	.07132
4		.03995	.01759	.01606	.01572	-.00564
5		.49940	.01200	.20042	.19337	-.05933
6		.95885	.00748	.40473	.38333	-.09618
7		1.41830	.00402	.68084	.62996	-.12023
8		-.27966	.86196	-460379232.7	92676016.019	-430238878.2
Total	N	8	8	8	8	8

a Limited to first 100 cases

3.1.6.5 تعليق أخير حول إحصائيات التشخيص

يجب اختبار مجموعة من إحصائيات التشخيص بعد تحليل التراجع، ويصعب تلخيص هذه الإحصائيات الكثيرة في خلاصة موجزة. وعلى كل حال فإننا سنشدّد على نقطة أشار إليها Belsey et al. (1908) حيث حذّر من المخاطر الناتجة عن هذه الإجرائيات. وهذه النقطة هي أن إحصائيات التشخيص هي أدوات تسمح لك بمعرفة مدى جودة أو رداءة النموذج من حيث توافقه مع بيانات العينة. إنها طريقة لتقييم النموذج، وليست على أي حال طريقة لتبرير حذف نقاط البيانات للتأثير على التغير المرغوب في بارامترات التراجع (كحذف حالة تقوم بتغيير قيم b من قيم عديمة الدلالة إلى قيم ذات دلالة). ويقدم Stevens (1992) نصيحة رائعة:

إذا كانت نقطة ما نقطة منعزلة هامة على ٧، ولكن مسافة كوك لها أصغر من القيمة 1، فليست هناك حاجة فعلية لحذف هذه النقطة لأنها لا تملك أثراً كبيراً على تحليل التراجع. ولكن يجب الاهتمام بدراسة مثل هذه النقاط لفهم أسباب عدم توافقها مع النموذج.

2.6.5 تقييم نموذج التراجع: التعميم

عند الانتهاء من تحليل التراجع، يمكن الحصول على معادلة صحيحة بالنسبة لعينة القيم المشاهدة. أما في علم الاجتماع فإننا نهتم عادة بتعميم النتائج خارج إطار العينة. ولذلك ومع أنه من المفيد الحصول على استنتاجات حول عينة محددة من الأشخاص، فإن إمكانية اعتبار الاستنتاجات صحيحة على مجتمع أكبر سيكون أكثر أهمية. ومن أجل تعميم نموذج التراجع يجب أن نكون متأكدين من تحقيق الفرضيات الأساسية، واختبار فيما إذا كان ممكناً تعميم النموذج، وتنفيذ التحقق المتصالب.

1.2.6.5 التحقق من الفرضيات

لسحب الاستنتاجات التي نحصل عليها من تحليل التراجع المنفذ على عينة وتطبيقها على مجتمع، يجب أن تكون الفرضيات التالية صحيحة (انظر Berry 1993):

- **أنواع المتحولات (Variable types):** يجب أن تكون جميع المتحولات التنبؤية كمّية أو فئوية (مع فئتين)، كما يجب أن يكون متحول النتيجة كمياً مستمراً وغير محدود. ونقصد بالكمّي (quantitative) أن يكون المتحول قابلاً للقياس على مستوى المجال، ونقصد بغير المحدود (unbounded) أن لا تكون هناك قيود على تغايرية النتيجة. إذا كان مجال قياس النتيجة ممتداً بين 1 و10 وكانت البيانات المجمّعة تتغير بين 3 و7 فإن هذه البيانات مقيدة.
- **التباين غير المعدوم (Non-zero variance):** يجب أن يكون للمتحولات التنبؤية تغايراً في القيمة (لا يكون تباينها مساوياً 0).

- **عدم وجود ارتباط خطي متعدد مثالي (No perfect multicollinearity):** يجب أن لا تكون هناك علاقة خطية مثالية بين اثنين أو أكثر من المتحولات التنبؤية. لذلك يجب أن لا تكون المتحولات التنبؤية مرتبطة بشكل كبير (انظر الفقرة 4.2.6.5).

- **المتحولات التنبؤية غير مرتبطة بالمتحولات الخارجية:** يقصد بالمتحولات الخارجية (External variables) المتحولات غير المضمنة في نموذج التراجع ولكنها تؤثر على متحول النتيجة[4]. يمكن النظر إلى هذه المتحولات بطريقة مشابهة للمتحول الثالث الذي ناقشناه في الارتباط. وهذه الفرضية تعني عدم وجود أي متحولات خارجية مرتبطة بأي من المتحولات المضمنة في نموذج التراجع. وبشكل بديهي، إذا ارتبطت المتحولات الخارجية مع المتحولات التنبؤية فإن الاستنتاجات المسحوبة من النموذج تصبح غير موثوقة (وذلك بسبب وجود متحولات أخرى ويمكنها التنبؤ بالنتيجة بشكل جيد أيضاً).

- **تجانس التباين (Homoscedasticity):** عند كل مستوى للمتحول (أو المتحولات) التنبؤية، فإن التباين لحد البواقي يجب أن يكون ثابتاً. وهذا يعني أن تملك البواقي عند كل مستوى من المتحول (أو المتحولات) التنبؤية نفس التباين، وعندما تكون التباينات متفاوتة بشكل كبير فإننا نقول أن هناك اختلافاً في التباين (heteroscedasticity) (انظر الفقرة 6.3).

- **الأخطاء المستقلة (Independent errors):** بالنسبة لأي نقطتين مراقبتين يجب أن تكون البواقي غير مرتبطة (أي مستقلة). يدعى هذه الاحتمال أحياناً بنقص الارتباط الذاتي (lack of autocorrelation). يمكن اختبار هذه الفرضية باستخدام اختبار Durbin-Watson الذي يختبر الارتباطات التسلسلية بين الأخطاء. ويختبر بشكل خاص إذا كانت البواقي المتجاورة مرتبطة. يمكن أن تتغير إحصائية الاختبار بين 0 و4 حيث تدل القيمة 2 على أن البواقي غير مرتبطة. إذا كانت القيمة أكبر من 2 فهذا يشير لارتباط عكسي بين البواقي المتجاورة بينما تشير القيمة الأقل من 2 إلى ارتباط طردي. ويعتمد حجم إحصائية Durbin-Watson على عدد المتحولات التنبؤية في النموذج، وعدد النقاط المشاهدة. ومن أجل الدقة، يجب البحث عن القيم الدقيقة المقبولة في بحث Durbin & Watson (1951) الأصلي. وكقاعدة موثوقة ومعتمدة يجب أن تكون القيم الأصغر من 1 أو الأكبر من 3 موضع اهتمام خاص، أما القيم القريبة من 2 فتبقى إشكالية تعتمد على العينة والنموذج.

- **الأخطاء موزعة طبيعياً (Normally distributed errors):** من المفترض أن تكون البواقي في النموذج هي متحولات عشوائية موزعة طبيعياً بقيمة متوسط تساوي 0. وتعني هذه الفرضية ببساطة أن الفروق بين النموذج والبيانات المشاهدة هي معدومة أو قريبة جداً من الصفر، وأن الفروق الأكبر من الصفر بكثير تحدث أحياناً فقط. ويخلط بعض الناس بين هذه الفرضية

4 يفضل بعض المؤلفين اعتبار المتحولات الخارجية كجزء من الخطأ الذي يتضمن أي عامل عشوائي في طريقة تغيّر النتيجة. ولتجنب الخلط مع البواقي في معادلات التراجع فقد اخترنا التسمية "متحولات خارجية". ويغطي هذا المصطلح بشكل ضمني أية عوامل عشوائية.

وفكرة أن تكون المتحولات التنبؤية موزعة طبيعياً. في الواقع، لا يجب أن تكون المتحولات التنبؤية موزعة طبيعياً (انظر الفقرة 10.5).

- **الاستقلال (Independence):** يُفترض أن تكون جميع القيم لمتحول النتيجة مستقلة (وبكلمات أخرى، أن تأتي كل قيمة لمتحول النتيجة من كيان منفصل).
- **الخطية (Linearity):** يُفترض أن تقع قيم المتوسط لمتحول النتيجة من أجل كل زيادة في المتحول (أو المتحولات) التنبؤية على خط مستقيم. ويعني ذلك بلغة واضحة افتراض أن العلاقة التي نقوم بنمذجتها هي علاقة خطية. إذا كنا نقوم بنمذجة علاقة غير خطية باستخدام نموذج خطي فإن ذلك يعني بوضوح الحد من إمكانية تعميم النتائج.

قد تبدو هذه اللائحة من الفرضيات مخيفة، ويميل معظم الطلاب (وحتى بعض الأكاديميين) للنظر إلى هذه الفرضيات على أنها أشياء مملة لا ينبغي لأحد القلق بشأنها. عندما عرضنا هذه الفرضيات الإحصائية على بعض علماء النفس، ألمحوا إلى أننا متزمتون نوعاً ما. على كل حال، وبغض النظر عن التزمّت، فإن هناك أسباب جيدة لأخذ هذه الفرضيات بشكل جدّي. تخيل أنني ذهبت لمنزل أحد الأصدقاء، وكانت الأضواء مُنارةً، ومن الواضح وجود شخص ما في المنزل. قرعت جرس الباب ولكني لم أسمع جواباً. لقد استنتجت من هذه التجربة أن صديقي يكرهني، وأنني شخص غير محبوب وغير مرحب به. ما مدى مصداقية هذا الاستنتاج؟ حسناً، هناك الواقعة الحقيقية، وهي أنني حاولت التلصص على صديقي (سواء كان صديقي يحبني أم يكرهني) وجمعت البيانات حول تلك الحقيقة (ذهبت إلى المنزل، ورأيت أنه هناك، وقرعت جرس الباب، ولم أسمع جواباً). تخيل أن صديقي يحبني، في هذه الحالة يكون استنتاجي خاطئاً. لماذا قادتني البيانات التي جمعتها إلى استنتاج خاطئ؟ الجواب بسيط، لقد افترضت أن جرس الباب في منزل صديقي يعمل جيداً، وتحت هذه الفرضية فإن الاستنتاج الذي توصلت إليه اعتماداً على البيانات كان دقيقاً (أي أن صديقي سمع الجرس واختار عدم الرد لأنه يكرهني). على كل حال، لم تكن هذه الفرضية صحيحة إذ لم يكن الجرس يعمل، ولهذا لم يرد صديقي، وكنتيجة لذلك فإن الاستنتاج الذي طبقته على الواقع كان خاطئاً تماماً.

إن النقطة التي يجب أن نتذكرها هي أنه عندما تنهار الفرضيات لا نبقى قادرين على القيام باستنتاجات دقيقة عن الواقع. وبمصطلحات التراجع، عندما تتحقق الفرضيات فإن النموذج الذي حصلنا عليه من أجل العينة يصبح قابلاً للتطبيق بدقة على المجتمع موضوع الدراسة (نقول عن معاملات وبارامترات معادلة التراجع أنها غير منحازة (unbiased)). يعتقد بعض الناس أن ذلك يعني أنه عندما تتحقق الفرضيات فإن نموذج التراجع المستمد من العينة مماثل دائماً للنموذج الذي سنحصل عليه ونكون قادرين على اختباره من أجل المجتمع بكامله. لسوء الحظ فإن ذلك الاعتقاد غير صحيح. ويخبرنا النموذج غير المنحاز أن نموذج التراجع المستمد من العينة هو بشكل وسطي نفس النموذج للمجتمع. على كل حال، يجب أن يكون واضحاً أنه حتى عند تحقق الفرضيات فمن

المحتمل أن لا يكون النموذج الذي حصلنا عليه من العينة مماثلاً لنموذج المجتمع، ولكن أرجحية أو احتمال أن يكونا متماثلين تزداد.

2.2.6.5 التحقق المتصالب من النموذج

حتى إذا لم نكن واثقين من أن النموذج المستمد من العينة يمثل المجتمع كاملاً بشكل دقيق، فما تزال هناك طرق يمكن من خلالها تقييم دقة توقّع النموذج للنتيجة في عينة مختلفة. ويُعرف تقييم دقة النموذج عبر العينات المختلفة باسم التحقق المتصالب (cross-validation). إذا كان تعميم النموذج ممكناً فيجب أن يكون قادراً على التوقّع بدقة لنفس متحول النتيجة من نفس مجموعة المتحولات التنبؤية في مجموعة مختلفة من البشر. إذا كان النموذج مطبقاً على عينة مختلفة وهناك هبوط حاد في قوته التنبؤية، فمن الواضح أنه لا يمكن تعميم النموذج. وكقاعدة عملية عامة، يجب أن يكون هدفنا جمع بيانات كافية للحصول على نموذج تراجع موثوق (انظر الفقرة التالية). بعد الحصول على نموذج التراجع هناك طريقتان أساسيتان لتنفيذ التحقق المتصالب.

- **R^2 المعدّلة:** لا يتم في برنامج SPSS حساب R وR^2 فقط، وإنما R^2 المعدّلة أيضاً. وتشير هذه القيمة المعدّلة لفقدان القوة التنبؤية أو التقلص (shrinkage). وبينما تخبرنا R^2 عن مقدار التباين في المتحول Y الذي يفسره نموذج التراجع المستمد من العينة، فإن قيمة R^2 المعدّلة تخبرنا بمقدار التباين في المتحول Y الذي سيفسره النموذج لو تم اشتقاقه من المجتمع الذي أُخذت منه العينة. يقوم برنامج SPSS بحساب R^2 المعدّلة مستخدماً معادلة Wherry. على كل حال، تم انتقاد هذه المعادلة لأنها لا تخبرنا شيئاً عن دقة توقّع نموذج التراجع لمجموعة من البيانات مختلفة تماماً (دقة توقّع النموذج لعلامات عينة مختلفة من البيانات مأخوذة من نفس المجتمع). هناك نسخة أخرى من R^2 يمكنها أن تخبرنا بدقة التحقق المتصالب للنموذج، وتستخدم صيغة Stein، وهي موضحة في المعادلة (11.5)، حيث يمثل R^2 القيمة غير المعدّلة، و n عدد الحالات، و k عدد المتحولات التنبؤية في النموذج:

$$\text{Adjusted } R^2 = 1 - \left[\left(\frac{n-1}{n-k-1}\right)\left(\frac{n-2}{n-k-2}\right)\left(\frac{n+1}{n}\right)\right](1-R^2) \qquad (11.5)$$

- **تقسيم البيانات:** تتضمن هذه الطريقة تقسيم مجموعة البيانات إلى نصفين بشكل عشوائي، وحساب معادلة التراجع لكل من النصفين ثم مقارنة النموذجين الناتجين. ونادراً ما تتوفر للباحثين مجموعات ضخمة من البيانات لكي يقوموا بهذا النوع من التحليل.

3.2.6.5 حجم العينة في التراجع

لقد قلنا في الفقرة السابقة أنه من المهم جمع بيانات كافية للحصول على نموذج تراجع موثوق. حسناً، وما هو العدد الكافي؟ هناك مجموعة من القواعد حول هذا الموضوع، ومن أكثرها شيوعاً القاعدة التي تطلب وجود 10 حالات من البيانات لكل متحول تنبؤي في النموذج، والقاعدة التي

تطلب وجود 15 حالة من البيانات لكل متحول تنبؤي في النموذج. لذلك إذا كان لدينا 5 متحولات تنبؤية فقد نحتاج إلى 50 أو 75 حالة من البيانات (حسب القاعدة التي نستخدمها). إن هذه القواعد عامة، ولكنها تبسّط المسألة بشكل كبير. في الواقع، سيعتمد حجم العينة المطلوب على حجم الأثر الذي نريد اكتشافه (ما مدى قوة العلاقة التي نريد قياسها؟) وعلى المقدرة التي نريد بها اكتشاف تلك الآثار (انظر الفصل 1). إن القاعدة العملية الأبسط هي كلما زاد حجم العينة كان ذلك أفضل. والسبب هو أن تقدير R الذي نحصل عليه من التراجع يعتمد على عدد المتحولات التنبؤية k، وحجم العينة n. وفي الواقع إن قيمة R المتوقعة للبيانات العشوائية هي k/(n-1) ولذلك فمن أجل عينات البيانات العشوائية صغيرة الحجم قد يظهر أثر قوي. فعلى سبيل المثال، عند وجود 6 متحولات تنبؤية مع 21 حالة من البيانات تكون قيمة R=6/(21-1)=0.3 (أثر متوسط حسب معيار Cohen المبين في الفقرة 2.2.4). من البديهي أن نتوقع أن تكون قيمة R قريبة من 0 في حالة البيانات العشوائية (عدم وجود أثر)، ولكي يكون ذلك صحيحاً فإننا نحتاج إلى عينات كبيرة الحجم (إذا أخذنا المثال السابق، وكانت لدينا 100 حالة وليس 21، فإن قيمة R المتوقعة ستكون R=0.06 وهي أكثر قبولاً).

صحيح أنه كلما كانت العينة أكبر كان ذلك أفضل، ولكن الباحثين يريدون تعليمات أكثر دقة (قد نريد جمع 1000 حالة من البيانات، ولكن ذلك غير عملي دائماً). قدم Green (1991) قاعدتين عمليتين لحجم العينة المقبول الأصغري، تعتمد الأولى على فيما إذا كنت تريد اختبار التوافق الكلي لنموذج التراجع (أي اختبار R^2)، وتعتمد الثانية على فيما إذا كنت تريد اختبار المتحولات التنبؤية المنفصلة ضمن النموذج (أي اختبار قيم b للنموذج). إذا أردت الاختبار الكلي للنموذج فإنه ينصح بحجم العينة الأصغري 50+8k، حيث k عدد المتحولات التنبؤية. فمن أجل 5 متحولات تنبؤية سيكون حجم العينة المطلوب 90=5*8+50. إذا أردت اختبار المتحولات التنبؤية المنفصلة فإن Green يقترح أن يكون حجم العينة الأصغري 104+k، ولذلك يكون حجم العينة الأصغري من أجل المثال السابق هو 109=5+104. ونهتم في معظم الحالات بالتوافق الكلي للنموذج وبمساهمة المتحولات التنبؤية المنفصلة، وفي هذه الحالة يقترح Green أن نحسب حجمَي العينة الأصغريين، ثم نأخذ القيمة الأكبر بينهما (وفي المثال السابق نأخذ 109 لأنه أكبر من 90).

والآن أصبحت لدينا جميع التعليمات كدليل خشن وجاهز، ولكنها مازالت تبسط المسألة بشكل كبير. وكما أشرنا سابقاً، فإن حجم العينة المطلوب عملياً يعتمد على حجم الأثر (ما مدى دقة تنبؤ النتيجة من قِبَل المتحولات التنبؤية) وما هي القدرة الإحصائية التي نريدها لاكتشاف هذه الآثار. وقد وضع Miles & Shevlin (2001) بعض المخططات البيانية المفيدة جداً التي توضح حجم العينة المطلوب لتحقيق مستويات مختلفة من القدرة، ومن أجل حجوم أثر مختلفة وذلك عند تغيّر عدد المتحولات التنبؤية. ومن أجل تقدير دقيق لحجم العينة الواجب استخدامها، فإننا ننصح باستخدام هذه المخططات البيانية. لقد تم تلخيص بعض النتائج العامة من عمل Miles & Shevlin في (الشكل 9.5). يبين هذا المخطط البياني حجم العينة المطلوب لتحقيق مستوى مرتفع من القدرة

بناءً على عدد المتحولات التنبؤية وحجم الأثر المتوقع (اعتمدنا قيمة مؤشر Cohen 1988 البالغة 0.8). من هذا المخطط يمكن سرد النتائج العامة التالية: (1) إذا كنت تتوقع أن تعثر على أثر كبير فإن حجم العينة 80 سيكون كافياً دوماً (مع حد أعظمي لعدد المتحولات التنبؤية يصل إلى 20)، وإذا كان عدد المتحولات التنبؤية أقل فإنه يمكن اختيار عينة أصغر، (2) إذا كنت تتوقع أثراً متوسطاً فإن حجم العينة 200 سيكون كافياً (مع حد أعظمي لعدد المتحولات التنبؤية يصل إلى 20) ولكن يجب أن لا يقل حجم العينة عن 60، ومن أجل 6 متحولات تنبؤية أو أقل فإن حجم العينة 100 يكون كافياً، (3) إذا كنت تتوقع أثراً صغير الحجم فلا تتعب نفسك ما لم يكن لديك الوقت والموارد لجمع 600 حالة من البيانات على الأقل (وأكثر من ذلك بكثير إذا كان لديك 6 متحولات تنبؤية أو أكثر).

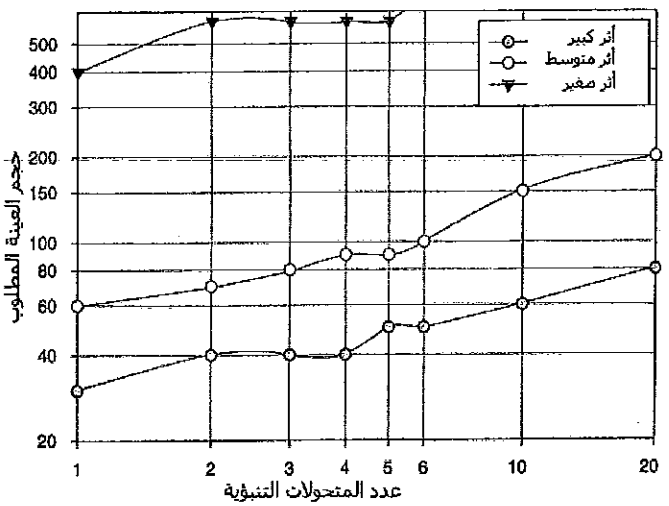

الشكل 9.5 يوضح المخطط البياني حجم العينة المطلوب في التراجع بناءً على عدد المتحولات التنبؤية وحجم الأثر المتوقع

4.2.6.5 الارتباط الخطي المتعدد

يوجد الارتباط الخطي المتعدد (multicollinearity) عندما يكون هناك ارتباط قوي بين متحولين تنبؤيين أو أكثر في نموذج التراجع. ويطرح الارتباط الخطي المتعدد مشكلة في حالة التراجع المتعدد فقط، وذلك لأن التراجع البسيط يتطلب متحولاً تنبؤياً وحيداً. ويوجد الارتباط الخطي المثالي (Perfect collinearity) عندما يكون أحد المتحولات التنبؤية هو تركيب خطي مثالي للمتحولات الأخرى (والمثال الأبسط هو حالة الارتباط المثالي بين متحولين تنبؤيين، حيث تبلغ قيمة معامل الارتباط 1). عند وجود ارتباط خطي مثالي بين المتحولات التنبؤية يصبح من المستحيل الحصول على تقديرات وحيدة لمعاملات الارتباط لأن هناك عدداً لانهائياً من تراكيب المعاملات التي يمكن أن تنجز هذا العمل بنفس الجودة. وببساطة إذا ارتبط متحولان تنبؤيان بشكل مثالي فإن قيم b لهما

تكون قابلة للتبادل. لحسن الحظ أن الارتباط الخطي المثالي نادر جداً في بيانات العالم الحقيقي. ولكن على ما يبدو أنه لا يمكن تجنب الارتباط الخطي الأقل من المثالي. إن المستويات الدنيا للارتباط الخطي تهدد بشكل ضئيل النماذج التي يولّدها برنامج SPSS، ولكن مع ازدياد الارتباط الخطي تزداد الأخطاء المعيارية للمعاملات b، مما يؤثر على الدلالة الإحصائية لهذه المعاملات. وباختصار، تزيد المستويات المرتفعة للارتباط الخطي احتمال أن يفقد أحد المتحولات التنبؤية الجيدة بالنتيجة دلالته ويتم الاستغناء عنه في النموذج (خطأ من النوع الثاني). وهناك ثلاثة أسباب أخرى لتفسير التهديد الذي يطرحه وجود الارتباط الخطي المتعدد على تحليل التراجع المتعدد:

- **أنه يحدّ من قيمة R:** تذكّر أن R هو مقياس للارتباط المتعدد بين المتحولات التنبؤية والنتيجة، وأن R^2 يدل على التباين في النتيجة الذي تساهم به المتحولات التنبؤية. تخيل أن متحولاً تنبؤياً وحيداً يتوقّع متحول النتيجة بنجاح مقبول (R=0.80) وقد تمت إضافة متحول تنبؤي آخر إلى هذا النموذج. قد يساهم المتحول الثاني بنسبة من التباين في النتيجة (ولذلك تم تضمينه في النموذج)، ولكن التباين الذي يساهم به هو نفس التباين المعتبر للمتحول الأول. بعبارة أخرى، عند حذف التباين المحسوب للمتحول الأول، فإن مساهمة المتحول الثاني في التباين المتبقي ستكون ضئيلة جداً (لأن المتحول الثاني يساهم بشكل ضئيل في التباين الوحيد). وهكذا فإن التباين الكلي في النتيجة والمحسوب للمتحولين التنبؤيين أعلى بقليل مما يعطيه استخدام متحول تنبؤي واحد (فقد تتغير قيمة R من 0.80 إلى 0.82). وتتصل هذه الفكرة بمفهوم الارتباط الجزئي الذي تم توضيحه في الفصل 3. ولكن إذا كان المتحولان التنبؤيان غير مرتبطين مطلقاً فمن المحتمل أن يساهم المتحول التنبؤي الثاني بقيمة من التباين للنتيجة مختلفة عما يساهم به المتحول التنبؤي الأول. لذلك، ومع أن المتحول التنبؤي الثاني قد يساهم بذاته بجزء صغير من التباين في النتيجة، فإن التباين المحسوب هو مختلف عما يساهم به المتحول التنبؤي الآخر (ولذلك تم تضمين المتحولان، وتصبح قيم R أكبر، ولنقل مثلاً 0.95). ولذلك فإن وجود المتحولات التنبؤية غير المرتبطة أمر مفيد جداً.
- **أهمية المتحولات التنبؤية:** يجعل الارتباط الخطي المتعدد بين المتحولات التنبؤية تقييم الأهمية المنفصلة لمتحول تنبؤي أمراً صعباً. إذا كانت المتحولات التنبؤية مرتبطة بشكل وثيق فإن كلاً من المتحولين يساهم بتباين مشابه في النتيجة، فكيف يمكننا إذاً التمييز بين المتحولات التنبؤية الهامة؟ ببساطة لا يمكننا معرفة المتحول التنبؤي الهام، لأن النموذج يمكن أن يتضمن أيّاً منهما بشكل تبادلي.
- **معادلات المتحول التنبؤي غير المستقرة:** لقد قلنا أن الارتباط الخطي المتعدد يزيد التباينات لمعاملات التراجع، مما يعطي معادلات غير مستقرة للمتحولات التنبؤية. وهذا يعني أن القيم المتوقعة لمعاملات التراجع (القيم b) ستكون غير مستقرة من عينة إلى أخرى.

هناك طريقة لتحديد الارتباط الخطي المتعدد وهي القيام بعملية مسح لمصفوفة الارتباط لجميع المتحولات التنبؤية ثم البحث عن قيم الارتباطات المرتفعة جداً (التي تكون قيمتها أعلى من 0.80 أو

حتى 0.90). وهذه الطريقة جيدة ولكنها تُغفل الأشكال غير الملحوظة من الارتباط الخطي المتعدد. لحسن الحظ فإن برنامج SPSS يقوم ببعض مهمات التشخيص للارتباط الخطي، ومنها عامل تضخم التباين VIF (Variance Inflation Factor). يدل VIF على وجود علاقة خطية قوية بين متحول تنبؤي ما والمتحولات التنبؤية الأخرى. وعلى الرغم من عدم وجود قواعد أو قيود صارمة على قيم VIF التي يجب الانتباه إليها، فإن Myers (1990) يقترح القيمة 10 كقيمة جيدة لحدود القلق، بينما يقترح Bowerman & O'Connell (1990) أنه إذا كانت القيمة الوسطية للعامل VIF أكبر من 1 فإن الارتباط الخطي المتعدد قد يؤثر على نموذج التراجع. وهناك إحصائية التسامح (tolerance) التي هي مقلوب VIF أي (1/VIF). وبذلك فإن القيم الأدنى من 0.1 تدل على مشاكل جدية، مع أن Menard (1995) كان قد اقترح أن تكون القيم الأدنى من 0.2 هي التي تستحق الاهتمام.

من القياسات الأخرى المفيدة في اكتشاف فيما إذا كانت المتحولات التنبؤية مستقلة يمكن أن نذكر القيم الخاصة لمصفوفة الجداء المتصالب، أدلة الحالة، ونسب التباين. وهذه الإحصائيات معقدة جداً، وستتم تغطيتها كجزء من تفسير الخرج لبرنامج SPSS (انظر الفقرة 5.8.5). إذا لم تقدم لك هذه الإحصائيات شيئاً مفيداً فيمكنك العودة إلى الصفحات 78-85 من كتاب Hutcheson & Sofroniou (1999) الذي يعطي شرحاً واضحاً للارتباط الخطي المتعدد.

7.5 كيف ننفذ التراجع المتعدد في برنامج SPSS

1.7.5 الخيارات الأساسية

تخيل أن المدير التنفيذي لشركة الأسطوانات كان مهتماً بتوسيع نموذج المبيعات ليشمل متحولات جديدة. لقد قرر أن يقيس متحولين جديدين: (1) عدد مرات بث الأسطوانة في الإذاعة الوطنية خلال الأسبوع الذي يسبق إطلاق الأسطوانة (المتحول airplay)، و(2) جاذبية الفرقة صاحبة الأسطوانة (المتحول attract). وقبل إطلاق الأسطوانة، دوّن المدير التنفيذي المبالغ المنفقة في الحملة الإعلانية، وعدد مرات بث الأسطوانة في الإذاعة الوطنية خلال الأسبوع الذي سبق إطلاق الأسطوانة، وكذلك جاذبية الفرقة. لقد سجل هذه المعلومات من أجل 200 أسطوانة مختلفة (وكل منها لفرقة مختلفة). تم قياس جاذبية الفرقة بسؤال عينة عشوائية من الجمهور المستهدف عن تقييمهم لكل فرقة على مقياس يتراوح بين 0 (بشع) و 10 (فائق الجمال). استُخدمَ منوال (mode) الجاذبية الذي أعطته العينة في التراجع (وذلك لأن المدير التنفيذي يرغب بمعرفة ما تفكر به الأغلبية وليس متوسط آراء الناس).

يحوي الملف Record2.sav هذه البيانات، ويجب أن تلاحظ أن لكل متحول عموده الخاص (كما في حالة الارتباط)، ويمثل كل سطر أسطوانة مختلفة. وهكذا فقد تم صرف مبلغ 10,260 جنيهاً في الترويج للأسطوانة الأولى، وتم بيع 330,000 نسخة منها، بعد أن تمت إذاعتها 43 مرة في الإذاعة

الوطنية خلال الأسبوع الذي سبق إطلاقها، وهي لفرقة يقيّمها الناس بأعلى مستويات الجاذبية 10 (انظر الشكل 10.5).

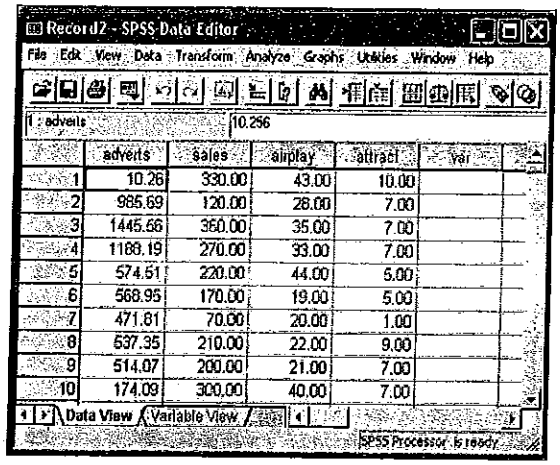

الشكل 10.5 صفحة البيانات للتراجع المتعدد

للمدير التنفيذي أبحاث سابقة تدل على أن ميزانية الإعلانات هي متحول تنبؤي ذو دلالة في مبيعات الأسطوانات، ولذلك يجب أن يكون هذا المتحول هو الأول في النموذج. وبهذا يتم إدخال المتحولين الجديدين (airplay وattract) في النموذج بعد ميزانية الإعلانات. وهذه الطريقة هرمية (حيث يقرر الباحث التسلسل الذي يتم به إدخال المتحولات في النموذج بناءً على الأبحاث السابقة). ولتنفيذ تراجع هرمي في برنامج SPSS يجب علينا إدخال المتحولات ضمن كتل (blocks) (تمثل كل كتلة خطوة واحدة في التسلسل الهرمي). لفتح مربع الحوار الرئيسي للتراجع نستخدم أمر القائمة Analyze ⇒ Regression ⇒ Linear. يوضح (الشكل 11.5) مربع الحوار الرئيسي للتراجع وهو نفس مربع الحوار الذي صادفناه في حالة التراجع البسيط.

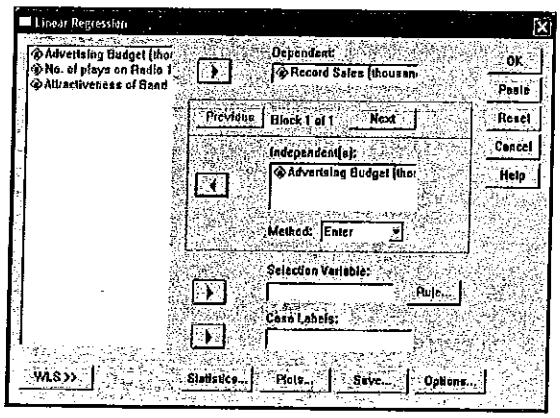

الشكل 11.5 مربع الحوار الرئيسي للكتلة 1 في التراجع المتعدد

إن مربع الحوار الرئيسي واضح، حيث يوجد حيز لمتحول النتيجة (Dependent)، وحيز آخر لوضع المتحولات التنبؤية ((Independent(s)). وكالعادة، يتم سرد المتحولات الموجودة في محرر البيانات لبرنامج SPSS في القسم الأيسر من مربع الحوار. اختر المتحول sales من لائحة المتحولات وانقله إلى الحيز المسمى Dependent بنقر زر السهم الموجود بين القسمين. علينا أيضاً تحديد المتحول التنبؤي للكتلة الأولى. لقد قررنا أن يتم إدخال ميزانية الإعلانات أولاً في النموذج (لأن الأبحاث السابقة تدل على أنه متحول تنبؤي هام)، لذلك علينا اختيار المتحول adverts ونقله إلى الحيز المسمى Independent(s) بنقر الزر الموجود بين القسمين. تحت حيز المتحولات التنبؤية هناك قائمة منسدلة بجانب التسمية Method يتم فيها تحديد طريقة التراجع (انظر الفقرة 3.5.5). يمكنك اختيار طريقة التراجع التي تريد تطبيقها باستخدام هذه القائمة. والطريقة الافتراضية هي الإدخال القسري، وهي الطريقة المناسبة لمثالنا. ولكن يمكنك فتح القائمة المنسدلة واستعراض الطرق المتوفرة الأخرى (forward وbackward وstepwise وremove).

بعد تحديد الكتلة الأولى في التسلسل الهرمي، علينا الانتقال للكتلة الثانية. ويتم ذلك بنقر الزر Next. تقوم هذه العملية بتنظيف الحيز Independent(s) بحيث يمكنك إدخال المتحولات التنبؤية للكتلة الثانية (لاحظ أن العبارة فوق هذا الحيز تصبح Block 2 of 2 لتدل على أننا الآن في الكتلة 2 من العدد الكلي للكتل التي قمنا بتحديدها). لقد قررنا أن تحوي الكتلة الثانية المتحولين التنبؤيين الجديدين، لذلك ننقر المتحولين airplay وattract في لائحة المتحولات وننقلهما إلى الحيز Independent(s) بنقر زر السهم الموجود بين القسمين. يجب أن يبدو مربع الحوار كما في الشكل 12.5. للتنقل بين الكتلتين استخدم المفاتيح Previous وNext (فعلى سبيل المثال، إذا أردت الانتقال إلى الكتلة 1 انقر الزر Previous).

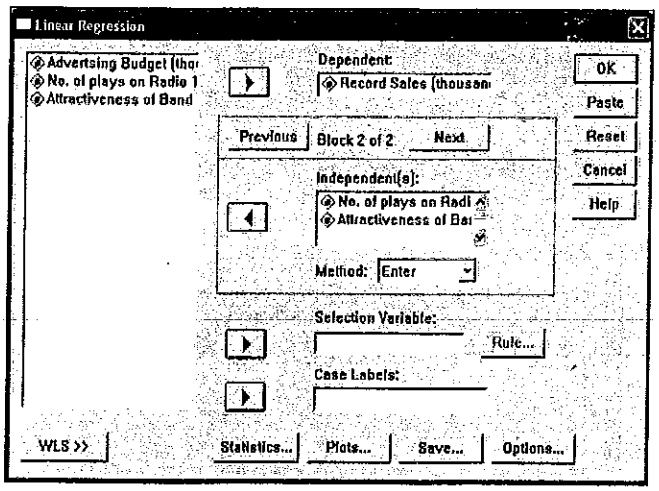

الشكل 12.5 مربع الحوار الرئيسي للكتلة 2 في التراجع المتعدد

من الممكن استخدام طرق مختلفة لإدخال المتحولات في الكتل المختلفة للتسلسل الهرمي. لذلك، ومع أننا اخترنا الإدخال القسري في الكتلة 1 فإنه يمكننا اختيار طريقة مختلفة للكتلة 2 كالطريقة الخطوية مثلاً. نظراً لعدم وجود أبحاث سابقة تتعلق بأثر الجاذبية وعدد مرات البث على أرقام المبيعات فيمكننا أن نبرر استخدام الطريقة الخطوية لهذه الكتلة. ولكن بسبب المشاكل المرتبطة بالطرق الخطوية، فقد فضّلنا المحافظة على طريقة الإدخال القسري للكتلتين في هذا المثال.

2.7.5 الإحصائيات

انقر الزر ...Statistics في مربع الحوار الرئيسي للتراجع لفتح مربع الحوار الخاص بتحديد الخيارات الهامة المختلفة المتعلقة بالنموذج (انظر الشكل 13.5). تتعلق معظم هذه الخيارات ببارامترات النموذج، فمنها ما يتعلق بالتحقق من فرضيات عدم الارتباط الخطي (collinearity diagnostics) والاستقلال التسلسلي للأخطاء Durbin-Watson. وعند الانتهاء من تحديد الخيارات المطلوبة (وكقاعدة عامة ننصح بتحديد جميع الخيارات عدا مصفوفة التباين المشترك (covariance matrix)) انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

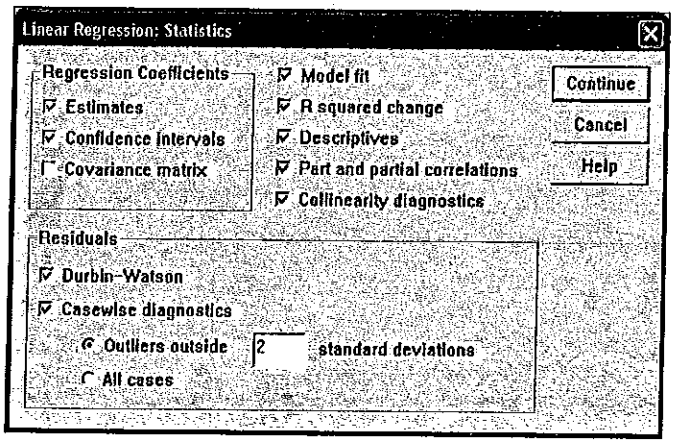

الشكل 13.5 مربع حوار الإحصائيات Statistics لتحليل التراجع

- **التقديرات (Estimates):** يتم تحديد هذا الخيار بشكل افتراضي لأنه يعطينا المعاملات المقدّرة لنموذج التراجع (أي قيم b المقدّرة). يتم حساب إحصائيات الاختبار ودلالتها لكل من معاملات التراجع: يتم استخدام الاختبار t لمعرفة فيما إذا كانت كل قيمة للمعامل b تختلف بشكل كبير عن الصفر (انظر الفقرة 4.2.5).
- **مجالات الثقة (Confidence intervals):** إذا تم تحديد هذا الخيار فإنه يعطي مجالات الثقة لكل من معاملات التراجع غير المعيارية. يمكن أن تكون مجالات الثقة أداة مفيدة في تقييم القيمة المحتملة لمعاملات التراجع في المجتمع، وسنصف تفسيرها الدقيق لاحقاً.

- **مصفوفة التباين المشترك (Covariance matrix):** إذا تم تحديد هذا الخيار فإنه يُظهر مصفوفة التباين المشترك ومعاملات الارتباط والتباينات بين معاملات التراجع لكل متحول في النموذج. كما يعطي مصفوفة التباين–التباين المشترك بحيث تظهر التباينات في القطر الرئيسي، والتباينات المشتركة في بقية عناصر المصفوفة. أما الارتباطات فيتم عرضها في مصفوفة منفصلة.
- **توافق النموذج (Model fit):** هذا الخيار حيوي، ولذلك يتم تحديده بشكل افتراضي. فهو يعطي الاختبار الإحصائي لمقدرة النموذج على التنبؤ بمتحول النتيجة (الاختبار F، انظر الفقرة 3.2.5)، إضافة إلى قيمة R (أو مضاعف R)، قيمة R^2 الموافقة، وقيمة R^2 المعدّلة.
- **تغير R مربع (R squared change):** يُظهر هذا الخيار التغير في قيمة R^2 الناتج عن تضمين متحول تنبؤي جديد (أو كتلة من المتحولات التنبؤية). وهذا المقياس مفيد لتقييم مساهمة المتحول التنبؤي الجديد (أو الكتل) في تفسير التباين في النتيجة.
- **الإحصائيات الوصفية (Descriptives):** إذا تم تحديد هذا الخيار فإنه يعطي جدولاً بقيم المتوسط والانحراف المعياري وعدد المشاهدات لجميع المتحولات المتضمنة في التحليل. كما يتم عرض مصفوفة الارتباط التي تبين الارتباط بين جميع المتحولات والاحتمال وحيد الطرف لكل من معاملات الارتباط. وهذا الخيار مفيد جداً لأنه يمكن استخدام مصفوفة الارتباط لتقييم فيما إذا كانت المتحولات التنبؤية مرتبطة فيما بينها (الأمر الذي يمكن استخدامه للتحقق من وجود الارتباط الخطي المتعدد).
- **الارتباط شبه الجزئي والارتباط الجزئي (Part and partial correlations):** يعطي هذا الخيار الارتباط من المرتبة 0 (ارتباط Pearson) بين كل متحول تنبؤي ومتحول النتيجة. كما يعطي الارتباط الجزئي بين كل متحول تنبؤي ومتحول النتيجة مع التحكم بجميع المتحولات التنبؤية الأخرى في النموذج. وأخيراً فإنه يعطي الارتباط شبه الجزئي بين كل متحول تنبؤي والنتيجة. يمثل هذا الارتباط العلاقة بين كل متحول تنبؤي والجزء من النتيجة الذي لم يتم تبريره بالمتحولات التنبؤية الأخرى في النموذج. وهكذا فإنه يقيس العلاقة الوحيدة بين متحول تنبؤي معين والنتيجة (انظر الفقرة 6.4).
- **تشخيص الارتباط الخطي (Collinearity diagnostics):** يسمح هذا الخيار بالحصول على إحصائيات الارتباط الخطي مثل VIF و التسامح والقيم الخاصة لمصفوفة الجداء المتصالب، أدلة الحالة، ونسب التباين (انظر الفقرة 4.2.6.5).
- **اختبار Durbin-Watson:** يعطي هذا الخيار إحصائية اختبار Durbin-Watson التي تختبر فرضية الأخطاء المستقلة. ولكن SPSS لا يقدم قيمة الدلالة لهذا الاختبار، لذلك ينبغي عليك أن تقرر بنفسك فيما إذا كانت القيمة مختلفة لحد كاف عن 2 لكي تصبح هذه الفرضية موضع اهتمام (انظر الفقرة 1.2.6.5).

- **تشخيص الحالة (Casewise diagnostics):** إذا تم تحديد هذا الخيار فإنه يعطي لائحة بالقيم المشاهدة للنتيجة والقيمة المتوقعة للنتيجة والفرق بين هاتين القيمتين (الباقي) والقيمة المعيارية لهذا الفرق. ويمكن أن يعطي هذه القيم لجميع الحالات أو للحالات التي يكون فيها الباقي المعياري أكبر من 3 (عندما تهمل إشارة الفرق). يمكن تغيير المعيار 3، وننصح باستخدام القيمة 2 للأسباب التي ستصبح واضحة لاحقاً. كما يعطي جدولاً يلخص إحصائيات الباقي حيث يشير للقيمة الدنيا والعظمى والمتوسط والانحراف المعياري لكل من القيمة المتوقعة من قبل النموذج وللباقي (انظر الفقرة 6.8.5).

3.7.5 المخططات البيانية للتراجع

عند العودة لمربع الحوار الرئيسي، انقر الزر ...Plots لتفعيل مربع الحوار الخاص برسم المخططات البيانية للتراجع والمبين في (الشكل 14.5). يوفر مربع الحوار Plots وسيلة لتحديد عدة مخططات بيانية يمكنها أن تساعدك في التحقق من بعض فرضيات التراجع. وتتضمن معظم هذه المخططات البيانية قيم الباقي المختلفة، والتي سيتم وصفها بالتفصيل في الفقرة 4.7.5.

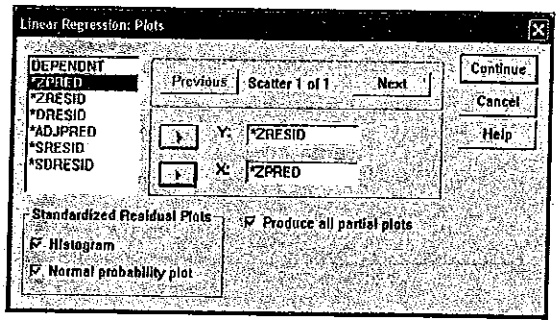

الشكل 14.5 مربع الحوار الخاص برسم المخططات البيانية للتراجع الخطي

يحوي القسم الأيسر من مربع الحوار لائحة ببعض المتحولات:

- **DEPENDNT:** (متحول النتيجة).
- **ZPRED*:** (القيم المتوقعة المعيارية لمتحول النتيجة بناءً على النموذج). وهذه القيم هي الأشكال المعيارية للقيم المتوقعة من قِبَل النموذج.
- **ZRESID*:** (البواقي المعيارية أو الأخطاء). وهذه القيم هي الفروق المعيارية بين البيانات المشاهدة والقيم المتوقعة من قِبَل النموذج.
- **DRESID*:** (البواقي المحذوفة). انظر الفقرة 1.1.6.5 لمعرفة التفاصيل.
- **ADJPRED*:** (القيم المتوقعة المعدّلة). انظر الفقرة 2.1.6.5 لمعرفة التفاصيل.

- **SRESID*:** (باقي Studentized).
- **SDRESID*:** (الباقي المحذوف Studentized). وهذه القيمة هي حاصل قسمة الباقي المحذوف على خطئه المعياري.

تأتي جميع هذه المتحولات في مربع الحوار الحالي تحت التسمية العامة البواقي residuals، وقد تمت مناقشتها بالتفصيل في الفقرة 1.1.6.5. من أجل التحليل الرئيسي، ينبغي رسم المخطط البياني للمتحول ZRESID* على المحور الشاقولي كتابع للمتحول ZPRED* على المحور الأفقي، لأن هذا المخطط مفيد في تحديد فيما إذا كانت فرضيات الأخطاء العشوائية وتجانس التباين محققة أم لا. أما المخطط البياني للمتحول SRESID* على المحور الشاقولي كتابع للمتحول ZPRED* على المحور الأفقي فيظهر فرضية عدم تجانس التباين. ومع أن هذين المخططين متماثلان ظاهرياً، فإن الأخير أكثر حساسية للتعامل على أساس الحالة. لإنشاء هذه المخططات، نختار متحولاً من اللائحة وننقله إلى الحيز المسمى Y (للمحور الشاقولي) أو X (للمحور الأفقي) وذلك بنقر زر السهم المناسب. عند اختيار المتحولين للمخطط البياني الأول (كما هو مبين في الشكل 14.5) يمكنك نقر الزر Next لتحديد مخطط بياني جديد. تقوم هذه العملية بمسح المتحولات المعرفة للمخطط الحالي. إذا نقرت الزر Next ثم أردت العودة للمخطط الذي حددته سابقاً فيمكنك نقر الزر Previous. يمكن تعريف 9 مخططات بيانية كحد أقصى.

يمكنك أيضاً تحديد الخيار Produce all partial plots لإنتاج المخططات المبعثرة لبواقي متحول النتيجة مع كل من المتحولات التنبؤية عندما يتم إجراء التراجع لهذين المحولين بشكل منفصل عن بقية المتحولات التنبؤية. وبغض النظر عما تعنيه الجملة السابقة، فإن لهذه المخططات عدة مميزات هامة تستحق الدراسة. أولاً، ميل خط التراجع بين متحولي الباقي مكافئ لمعامل المتحول التنبؤي في معادلة التراجع. وهكذا فإن أي نقطة منعزلة في مخطط بياني جزئي تمثل الحالات التي قد تكون ذات تأثير قوي على معامل التراجع للمتحول التنبؤي. ثانياً، بفضل هذه المخططات يمكن اكتشاف العلاقات غير الخطية بين متحول تنبؤي معين ومتحول النتيجة بسهولة أكبر. وأخيراً، تعتبر هذه المخططات وسيلة مفيدة لاكتشاف الارتباط الخطي. ولهذه الأسباب مجتمعة، ننصح بتحديد هذا الخيار للحصول على جميع المخططات الجزئية.

هناك عدة خيارات لمخططات البواقي المعيارية. يمكنك أولاً اختيار المخطط التكراري للبواقي المعيارية (وهو مفيد جداً للتحقق من فرضية طبيعية الأخطاء). يمكنك أيضاً تحديد الخيار لرسم مخطط الاحتمال الطبيعي، والذي يوفر معلومات حول إذا ما كانت البواقي في النموذج موزعة بشكل طبيعي. بعد الانتهاء من تحديد الخيارات المرغوبة، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي للتراجع.

4.7.5 حفظ إحصائيات تشخيص التراجع

قابلنا في الفقرة 6.5 نوعين من إحصائيات تشخيص التراجع، يساعدنا النوع الأول في تقييم مدى توافق النموذج مع العينة، ويساعدنا النوع الآخر في اكتشاف الحالات التي لها تأثير كبير على النموذج الناتج. يسمح برنامج SPSS بحفظ متحولات التشخيص في محرر البيانات (لذلك يقوم البرنامج بحساب تلك المتحولات وإنشاء أعمدة جديدة في محرر البيانات لوضع المتحولات الجديدة).

لحفظ إحصائيات تشخيص التراجع ننقر الزر ...Save في مربع الحوار الرئيسي للتراجع، حيث يتم تفعيل مربع الحوار Save لحفظ البيانات الجديدة (انظر الشكل 15.5). يمكنك تحديد الخيارات للإحصائيات التي ترغب بحفظها. لقد تم إعطاء وصف لمعظم الخيارات المتوفرة في الفقرة 6.5، ويبين (الشكل 15.5) ما يمكن أن نعتبره مجموعة أساسية من إحصائيات التشخيص. وبشكل عام فإن من الأسهل تفسير النسخ المعيارية (والنسخ Studentized) من هذه الإحصائيات، ولذلك نقترح تحديدها كخيار مفضل على النسخ غير المعيارية. بعد تنفيذ التراجع، يقوم برنامج SPSS بإنشاء عمود في محرر البيانات لكل إحصائية محددة، ويعطيها اسماً من مجموعة الأسماء القياسية المعرَّفة فيه. وبعد الاسم هناك رقم يدل على التحليل الذي تم تنفيذه. لذلك فإنه عند تنفيذ التراجع لأول مرة على مجموعة البيانات ستكون أسماء المتحولات متبوعة بالرقم 1، إذا نفذت تحليل التراجع مرة ثانية ستكون أسماء المتحولات متبوعة بالرقم 2 وهلم جرا. بعد الانتهاء من تحديد الإحصائيات المطلوبة، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي للتراجع.

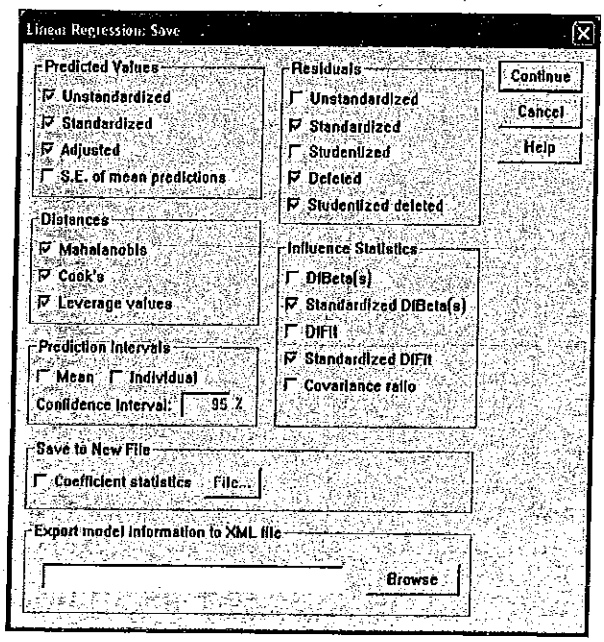

الشكل 15.5 مربع الحوار لحفظ إحصائيات تشخيص التراجع

تبين اللائحة التالية أسماء المتحولات لإحصائيات التشخيص في التراجع:

* **pre_1:** القيمة المتوقعة غير المعيارية.
* **zpr_1:** القيمة المتوقعة المعيارية.
* **adj_1:** القيمة المتوقعة المعدّلة.
* **sep_1:** الخطأ المعياري للقيمة المتوقعة.
* **res_1:** الباقي غير المعياري.
* **zre_1:** الباقي المعياري.
* **sre_1:** باقي Studentized.
* **dre_1:** الباقي المحذوف.
* **sdr_1:** الباقي المحذوف Studentized.
* **mah_1:** مسافة Mahalanobis.
* **coo_1:** مسافة Cook.
* **lev_1:** قيمة الفعالية المتمركزة.
* **sdb0_1:** قيمة DFBETA المعيارية (الاعتراض).
* **sdb1_1:** قيمة DFBETA المعيارية (المتحول التنبؤي الأول).
* **sdb2_1:** قيمة DFBETA المعيارية (المتحول التنبؤي الثاني).
* **sdf_1:** قيمة DFFIT المعيارية.
* **cov_1:** نسبة التباين المشترك.

5.7.5 المزيد من الخيارات

الخطوة الأخيرة في عملية التحليل ستكون بضبط بعض الخيارات الأخرى وذلك بنقر الزر Options... في مربع الحوار الرئيسي لفتح مربع الحوار Options المبين في (الشكل 16.5). تسمح المجموعة الأولى من الخيارات بتغيير المعيار المستخدم لإدخال البيانات في التراجع الخطوي. إذا أردت استخدام تراجع خطوي فمن الأفضل الإبقاء على القيمة الافتراضية للمعيار وهي احتمال 0.05 للإدخال وحده. يمكنك إدخال قيمة أكثر صرامة لهذا المعيار (0.01). هناك أيضاً خيار لبناء نموذج لا يتضمن حداً ثابتاً (لا يتقاطع مع المحور الشاقولي). يجب ترك القيمة الافتراضية لهذا الخيار. أخيراً يمكنك اختيار طريقة للتعامل مع نقاط البيانات المفقودة. بشكل افتراضي يقوم برنامج SPSS باستثناء الحالات بشكل لائحة، وهذا يعني أنه إذا كانت هناك قيمة مفقودة لمتحول ما لإحدى

الحالات فسيتم استثناء الحالة من عملية التحليل بكاملها. فعلى سبيل المثال، إذا لم تتوفر للمدير التنفيذي لشركة الأسطوانات علامة الجاذبية لإحدى الفرق فلن يتم استخدام بياناتها في عملية التراجع. الخيار الآخر هو استثناء الحالات على أساس التشابه، وهذا يعني أنه إذا كان لمشترك ما قيمة مفقودة لمتحول معين، فيتم استثناء بياناته فقط من الحسابات التي تتضمن ذلك المتحول. ولذلك فمن أجل المثال السابق، تستخدم بيانات الفرقة التي لا تتوفر علامة الجاذبية لها في حساب العلاقات بين ميزانية الإعلانات وعدد مرات البث وأرقام المبيعات. ولكن إذا حددت هذا الخيار فإن عدداً من المتحولات سيصبح دون معنى، وقد تنتهي بحالة من اللامنطقية كأن تكون قيمة R^2 سالبة أو أكبر من القيمة 1.0 لذلك فهو ليس خياراً جيداً. أما الخيار الأخير فيسمح باستبدال القيمة المفقودة بقيمة المتوسط للمتحول ثم تضمين الحالة في عملية التحليل (لذلك ومن أجل المثال السابق، ستعطى للفرقة التي لا تتوفر لها علامة الجاذبية قيمة مساوية لمتوسط الجاذبية لجميع الفرق). المشكلة في هذا الخيار أنه يحاول إلغاء القيمة الحقيقة للانحراف المعياري (وأهم من ذلك الخطأ المعياري). سيتم إلغاء الانحراف المعياري لأنه من أجل أية حالة مستبدلة لن يكون هناك فرق بين قيمة المتوسط والعلامة التي تم وضعها بدلاً من القيمة المفقودة، بينما لو كانت القيمة موجودة فسيكون هناك حتماً بعض الفرق بين هذه القيمة وقيمة المتوسط. ومن البديهي أنه لو كان حجم العينة كبيراً وعدد القيم المفقودة صغيراً فلن تكون هناك مشكلة جدية. على كل حال، إذا كان هناك العديد من القيم المفقودة فإن هذا الخيار يصبح خطيراً لأن الأخطاء المعيارية الأصغر ربما ستقود إلى نتائج ذات دلالة وهي ناتجة عن استبدال البيانات المفقودة وليس عن أثر حقيقي. يوفر برنامج SPSS خياراً للخبراء من أجل التعامل مع القيم المفقودة، وهو استخدام إجرائية تحليل القيمة المفقودة Missing Value Analysis. تستفيد هذه الإجرائية من حقيقة أنه إذا كان متحولان (أو أكثر) موجودين ومرتبطين لمعظم الحالات في الملف، وصادف وجود قيمة مفقودة فإنه يمكنك استبدال القيم المفقودة بقيم تقديرية أفضل من قيمة المتوسط.

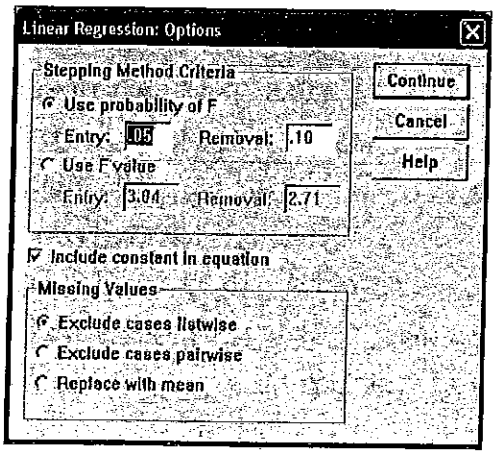

الشكل 16.5 مربع حوار الخيارات للتراجع الخطي

8.5 تفسير التراجع المتعدد

هناك استراتيجية جيدة يمكن اعتمادها في التراجع وهي قياس المتحولات التنبؤية التي نعتقد أن هناك أسباب قوية تجعلها تتوقع النتيجة. يتم تنفيذ تحليل التراجع بحث تكون جميع المتحولات التنبؤية ضمن النموذج ودراسة الخرج لمعرفة المتحولات التنبؤية التي تساهم بشكل كبير في قدرة النموذج على توقع النتيجة. بعد تحديد المتحولات الهامة، نقوم بإعادة تنفيذ التحليل بحيث يتم تعريف نموذج التراجع باستخدام المتحولات التنبؤية الهامة تقديرات البارامترات الناتجة. إذا كشف التحليل الأولي وجود متحولين تنبؤيين هامين أو أكثر فإنه يمكننا تنفيذ التحليل باستخدام التحليل الخطوي التقدمي (بدلاً من الإدخال القسري) وذلك لإيجاد المساهمة الفردية لكل من المتحولات التنبؤية.

لقد شرحنا بشكل واف المبادئ النظرية للتراجع وبعض أدوات التشخيص للحكم على دقة نموذج التراجع. ومن المهم أن نتذكر أن برنامج SPSS قد يبدو ذكياً جداً، ولكنه في الحقيقة ليس كذلك. يمكن أن نقبل بأن البرنامج قادر على تنفيذ الحسابات المعقدة بسرعة هائلة، ولكن ما لا يمكنه عمله هو التحكم بجودة النموذج الذي يتم إنشاؤه لأن ذلك يتطلب دماغاً بشرياً (ومن الأفضل أن يكون دماغاً مدرباً). يقوم برنامج SPSS بتوليد الخرج بناءً على البيانات التي تقدمها له في محرر البيانات، ولكنه لا يحكم على النتائج أو يعطي إشارة عن إمكانية تعميم النموذج أو حتى عن صحته. على كل حال، يوفر برنامج SPSS الإحصائيات الضرورية للحكم على تلك الأمور، وعند هذه النقطة يجب على دماغنا أن يتولى زمام الأمور، وهو أمر مقلق نوعاً ما.

بعد تحديد جميع الخيارات الهامة والعودة إلى مربع الحوار الرئيسي، يجب أن ننقر الزر OK لتنفيذ عملية التحليل. يقوم برنامج SPSS بعد ذلك بإنتاج كميات كبيرة من النتائج في نافذة العارض، وعلينا الآن أن نبحث في كيفية فهم هذه المعلومات.

1.8.5 الإحصائيات الوصفية

إن الخرج الذي سيتم شرحه في هذه الفقرة هو ناتج عن الخيارات في مربع الحوار Linear Regression: Statistics (انظر الشكل 13.5). إذا حددت الخيار Descriptives فإنك ستحصل على الجدول المبين في الخرج 4.5. يخبرنا هذا الجدول بقيمة المتوسط والانحراف المعياري لكل متحول في مجموعة البيانات، لذلك فإننا نعلم الآن أن متوسط عدد الأسطوانات المباعة هو 193,200 أسطوانة. وهذا الجدول غير ضروري لتفسير نموذج التراجع، ولكنه مفيد كملخص للبيانات. بالإضافة للإحصائيات الوصفية فإن هذا الخيار يعطينا مصفوفة الارتباط. يعرض الجدول ثلاثة أشياء: (1) يبين قيمة معامل Pearson للارتباط بين كل زوج من المتحولات (يمكننا أن نرى على سبيل المثال الارتباط الطردي الكبير بين ميزانية الإعلانات وأرقام المبيعات R=0.578). (2) يعرض الدلالة وحيدة الطرف لكل ارتباط (الارتباط ذو دلالة عند p<0.001). (3) عدد الحالات المساهمة بكل ارتباط (نلاحظ N=200).

Descriptive Statistics

	Mean	Std. Deviation	N
Record Sales (thousands)	193.2000	80.69896	200
Advertsing Budget (thousands of pounds)	614.4123	485.65521	200
No. of plays on Radio1 per week	27.5000	12.26958	200
Attractiveness of Band	6.7700	1.39529	200

Correlations

		Record Sales (thousands)	Advertsing Budget (thousands of pounds)	No. of plays on Radio 1 per week	Attractiveness of Band
Pearson Correlation	Record Sales (thousands)	1.000	.578	.599	.326
	Advertsing Budget (thousands of pounds)	.578	1.000	.102	.081
	No. of plays on Radio 1 per week	.599	.102	1.000	.182
	Attractiveness of Band	.326	.081	.182	1.000
Sig. (1-tailed)	Record Sales (thousands)	.	.000	.000	.000
	Advertsing Budget (thousands of pounds)	.000	.	.076	.128
	No. of plays on Radio 1 per week	.000	.076	.	.005
	Attractiveness of Band	.000	.128	.005	.
N	Record Sales (thousands)	200	200	200	200
	Advertsing Budget (thousands of pounds)	200	200	200	200
	No. of plays on Radio 1 per week	200	200	200	200
	Attractiveness of Band	200	200	200	200

الخرج 4.5 الإحصائيات الوصفية لتحليل التراجع

ربما لاحظت أن جميع قيم معامل الارتباط على القطر الرئيسي لمصفوفة الارتباط تساوي 1.00 (ارتباط طردي تام). والسبب وراء ذلك أن هذه القيم تمثل ارتباط كل متحول مع نفسه. إن مصفوفة الارتباط مفيدة جداً في تكوين فكرة عامة عن العلاقات بين المتحولات التنبؤية والنتيجة، وفكرة أولية عن الارتباط الخطي المتعدد. إذا لم يكن هناك ارتباط خطي متعدد في البيانات فلن يكون هناك ارتباطات كبيرة بين المتحولات التنبؤية (R>0.9).

إذا نظرنا إلى المتحولات التنبؤية فقط (أهملنا أرقام المبيعات) فإن القيمة العظمى للارتباط هي بين جاذبية الفرقة وعدد مرات البث في الإذاعة الوطنية، وقيمته ذات دلالة عند مستوى 0.01 (p=0.005، R=.182). وعلى الرغم من دلالة هذا الارتباط فإن معامل الارتباط صغير ولذلك

يبدو أن المتحولات التنبؤية تقيس أشياء مختلفة (ليس هناك ارتباط خطي). يمكننا أن نرى أيضاً أن من بين جميع المتحولات التنبؤية فإن عدد مرات البث في الإذاعة الوطنية يرتبط بالنتيجة بأفضل شكل ($p<0.001$، $R=0.599$) ولذلك يبدو أن هذا المتحول هو أفضل من يتوقع المبيعات.

فكرة: استخدم الإحصائيات الوصفية للتحقق من الارتباط الخطي المتعدد عبر مصفوفة الارتباط، أي المتحولات التنبؤية التي ترتبط مع بعضها بقيم مرتفعة $R>0.9$.

2.8.5 ملخص النموذج

يصف القسم التالي في الخرج النموذج بشكله الإجمالي (لذلك يخبرنا عما إذا كان النموذج ناجحاً في توقع أرقام المبيعات). تذكّر أننا اخترنا الطريقة الهرمية ولذلك فإن كل مجموعة من الإحصائيات الملخصة ستكون مكررة لكل مرحلة في التسلسل الهرمي. يجب أن تلاحظ وجود نموذجين في الخرج 5.5. يمثل النموذج الأول Model 1 المرحلة الأولى في التسلسل الهرمي عندما استخدمنا ميزانية الإعلانات فقط كمتحول تنبؤي. بينما يمثل النموذج الثاني Model 2 المرحلة التي تم فيها استخدام المتحولات التنبؤية الثلاثة. يدعى الخرج 5.5 بملخص النموذج Model Summary وقد نتج هذا الجدول عن استخدام الخيار Model fit. يتم تحديد هذا الخيار بشكل افتراضي في برنامج SPSS لأنه يزودنا ببعض المعلومات الهامة عن النموذج مثل قيم R وR^2 وR^2 المعدّلة. إذا تم تحديد الخيارين R squared change وDurbin-Watson فإن هذه القيم ستكون موجودة أيضاً (وإذا لم تكن هذه الخيارات محددة فإن الجدول سيكون أصغر).

يعرض الخرج 5.5 جدول ملخص النموذج، ويجب أن تنتبه لوجود الملاحظات تحت الجدول التي تعرّفنا بمتحول النتيجة والمتحولات التنبؤية المستخدمة في كل من النموذجين. يحوي العمود R قيم مضاعف معامل الارتباط بين المتحولات التنبؤية والنتيجة. عندما نستخدم ميزانية الإعلانات فقط كمتحول تنبؤي فإننا نحصل على الارتباط البسيط بين ميزانية الإعلانات وأرقام المبيعات (.578). إن جميع الإحصائيات للنموذج الأول هي نفس الإحصائيات التي حصلنا عليها في حالة نموذج التراجع البسيط الذي درسناه في الفقرة 4.5. يعطي العمود التالي قيمة R^2 والتي نعرف مسبقاً أنها مقياس لمقدار التغايرية في النتيجة التي تساهم بها المتحولات التنبؤية. وقد بلغت قيمة R^2 للنموذج الأول 0.335 وهذا يعني أن ميزانية الإعلانات تساهم في تفسير 33.5% من التغاير في أرقام المبيعات. وعندما تم تضمين المتحولين الآخرين في النموذج الثاني فإن هذه القيمة ارتفعت إلى 0.665 أو 66.5% من التباين لأرقام المبيعات. ولذلك إذا كانت ميزانية الإعلانات تساهم بمقدار 33.5% فإنه يمكننا أن نقول أن جاذبية الفرقة وعدد مرات البث في الإذاعة تساهم بمقدار 33% إضافية (وهي قيمة تغير R^2 الموجودة في العمود R Square Change وتحسب بالشكل 33.0%=33.5%-66.5%). لذلك فإن تضمين المتحولين التنبؤيين الجديدين قد فسرا مقداراً كبيراً من التغاير في أرقام المبيعات.

Model Summary[c]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	.578[a]	.335	.331	65.99144	.335	99.587	1	198	.000	
2	.815[b]	.665	.660	47.08734	.330	96.447	2	198	.000	1.950

a. Predictors: (Constant), Advertising Budget (thousands of pounds)

b. Predictors: (Constant), Advertising Budget (thousands of pounds), Attractiveness of Band, No. of plays on Radio 1 per week

c. Dependent Variable: Record Sales (thousands)

الخرج 5.5 ملخص نموذج التراجع

تعطي قيمة R^2 المعدّلة فكرة عن قابلية النموذج للتعميم، ونرغب بأن تكون قيمتها مساوية أو قريبة جداً من قيمة R^2. في هذا المثال فإن الفرق للنموذج النهائي صغير (الفرق بين القيمتين 0.005=0.660-0.665 أي 0.5%). ويعني التقلص أنه إذا كان النموذج مشتقاً من المجتمع بدلاً من العينة فإن مساهمته بتفسير التباين في النتيجة ستكون أقل بمقدار 0.5%. قد يرغب بعض المهتمين بتطبيق صيغة Stein على R^2 للحصول على فكرة عن القيمة المحتملة لها في العينات المختلفة. تم إعطاء صيغة Stein في المعادلة (11.5) ويمكن تطبيقها باستبدال n بحجم العينة البالغ 200 و k بعدد المتحولات التنبؤية 3:

$$R^2 \text{ المعدّلة} = 1 - \left[\left(\frac{200-1}{200-3-1}\right)\left(\frac{200-2}{200-3-2}\right)\left(\frac{200+1}{200}\right)\right](1-0.665) = 0.653$$

وهذه القيمة مشابهة جداً لقيمة R^2 المشاهدة البالغة (0.665) وهذا يدل على أن التحقق المتصالب للنموذج جيد جداً.

تتوفر إحصائية التغير إذا تم طلبها، وهي تخبرنا فيما إذا كان التغير في R^2 ذي دلالة. يمكن اختبار دلالة R^2 فعلياً باستخدام النسبة F، ويتم حساب F من المعادلة التالية (حيث يمثل N عدد الحالات المشاركة، و k عدد المتحولات التنبؤية في النموذج):

$$F = \frac{(N-k-1)R^2}{k(1-R^2)}$$

يعرض الخرج 5.5 التغير في قيمة F لكل من الكتلتين في التسلسل الهرمي. أدى النموذج الأول، لتغيير قيمة R^2 من 0 إلى 0.335 وهذا التغير في مقدار التباين المبرر يرفع قيمة النسبة F إلى 99.587، وهي قيمة ذات دلالة عند احتمال $p<0.001$. لا تنس أنه من أجل النموذج الأول، كان لدينا متحول تنبؤي واحد فقط (أي أن k=1) وعدد الحالات 200 (أي N=200)، ولهذا تكون قيمة النسبة F هي:

$$F_{\text{Model 1}} = \frac{(200-1-1)\times 0.334648}{1\times(1-0.334648)} = 99.587$$

إن إضافة المتحولين التنبؤيين الجديدين (النموذج الثاني) رفع قيمة R^2 بمقدار 0.330، وهكذا يمكننا حساب النسبة F لهذا التغير باستخدام نفس المعادلة، ولكن بما أننا نبحث عن التغير في النماذج فإننا نستخدم التغير في R^2_{Change}، و R^2 في النموذج الجديد (النموذج الثاني في هذه الحالة ولذلك سميناها R^2_2) وقد استخدمنا أيضاً التغير في عدد المتحولات التنبؤية k_{Change} (يحوي النموذج الأول متحولاً تنبؤياً واحداً فقط، ويحوي النموذج الثاني 3 متحولات تنبؤية، ولذلك فإن $k_{Change}=3-1=2$)، بينما عدد المتحولات التنبؤية في النموذج الجديد هو k_2. ومرة أخرى إذا استخدمنا عدداً أكبر للمنازل العشرية مما هو ظاهر في جدول SPSS فإننا نحصل على نفس القيم التي يعطيها برنامج SPSS تقريباً:

$$F_{Change} = \frac{(N - k_2 - 1)R^2_{Change}}{k_{Change}(1 - R^2_2)} = \frac{(200 - 3 - 1) \times 0.330}{2 \times (1 - 0.664668)} = 96.44$$

وهكذا فإن التغير في مقدار التباين المبرر يرفع قيمة النسبة F إلى 96.44، وهي قيمة ذات دلالة عند احتمال $p<0.001$. ولذلك فإن إحصائيات التغير تخبرنا عن الفرق الناتج بسبب إضافة المتحولات التنبؤية الجديدة إلى النموذج.

أخيراً، إذا حددت خيار الإحصائية Durbin-Watson فإنك ستجدها في العمود الأخير من الجدول المبين في الخرج 5.5. تخبرنا هذه الإحصائية عما إذا كانت فرضية الأخطاء المستقلة محققة (انظر الفقرة 1.2.6.5). وكقاعدة فإننا نقول أن هناك حالة خطر عندما تكون قيمة هذه الإحصائية أصغر من 1 أو أكبر من 3 (مع ضرورة ملاحظة القيمة الدقيقة تبعاً للحالة موضع الدراسة). كلما كانت هذه القيمة أقرب إلى 2 كان ذلك أفضل، ومن أجل المثال الذي ندرسه فإن القيمة هي 1.950 وهي قريبة من 2 وهذا يعني أن الفرضية محققة بالتأكيد.

يعرض الخرج 6.5 القسم التالي من الخرج لبرنامج SPSS والذي يحوي تحليل التباين (ANOVA) الذي يختبر فيما إذا كان النموذج يتوقع النتيجة بشكل أفضل من استخدام قيمة المتوسط كأفضل تخمين. تمثل النسبة F بشكل خاص نسبة التحسن في التوقّع والتي تنتج عن ملاءمة النموذج، مقارنة بالخطأ (أو عدم الدقة) الذي مازال موجوداً في النموذج (انظر الفقرة 3.2.5). ينقسم هذا الجدول إلى قسمين أيضاً، قسمٌ لكل نموذج. نعرف قيمة مجموع المربعات للنموذج (وهذه القيمة هي SS_M في الفقرة 3.2.5 وتمثل التحسن في التوقّع الناتج من ملاءمة خط التراجع للبيانات بدلاً من استخدام المتوسط كتقدير للنتيجة). كما نعرف مجموع المربعات للباقي (وهذه القيمة هي SS_R في الفقرة 3.2.5 وتمثل الفرق الكلي بين النموذج والبيانات المشاهدة). ونعرف أيضاً درجات الحرية (df) لكل حد. في حالة التحسن العائد للنموذج فإن هذه القيمة تساوي عدد المتحولات التنبؤية (1 للنموذج الأول، و 3 للنموذج الثاني)، ومن أجل SS_R فهو عدد المراقبات (200) مطروحاً منه عدد المعاملات في نموذج التراجع. يملك النموذج الأول معاملين فقط (الحد الثابت، والمعامل للمتحول التنبؤي الوحيد) بينما يملك النموذج الثاني 4 معاملات (الحد الثابت، ومعامل لكل من المتحولات

التنبؤية الثلاثة). ولذلك فإن عدد درجات الحرية للنموذج الأول يساوي df=200-2=198، بينما للنموذج الثاني df=200-4=196. يتم حساب متوسط مجموع المربعات (MS) لكل حد بتقسيم المجموع الكلي للمربعات (SS) على عدد درجات الحرية (df). يتم حساب النسبة F بتقسيم متوسط التحسن في التوقع للنموذج (MS_M) على متوسط الفرق بين النموذج والقيم المشاهدة (MS_R). إذا كان التحسن العائد لملاءمة نموذج التراجع أكبر بكثير من عدم الدقة ضمن النموذج فإن قيمة F ستكون أكبر من 1 وسيقوم برنامج SPSS بحساب الاحتمال الدقيق للحصول على قيمة F بالصدفة. من أجل النموذج الأول كانت قيمة النسبة F تساوي 99.587 وهي قيمة غير محتملة الحدوث بالصدفة ($p<0.001$). أما من أجل النموذج الثاني فكانت قيمة F أعلى بكثير وتساوي 129.498 وهي ذات دلالة كبيرة ($p<0.001$). يمكننا تفسير هذه النتائج بأن النموذج الأول قد حسّن مقدرتنا على التنبؤ بمتحول النتيجة بشكل كبير، إلا أن النموذج الثاني (مع المتحولات التنبؤية الجديدة) كان أفضل (لأن قيمة النسبة F كانت ذات دلالة أكبر).

ANOVA[c]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	433687.8	1	433687.833	99.587	.000[a]
	Residual	862264.2	198	4354.870		
	Total	1295952	199			
2	Regression	861377.4	3	287125.806	129.498	.000[b]
	Residual	434574.6	196	2217.217		
	Total	1295952	199			

a. Predictors: (Constant), Advertsing Budget (thousands of pounds)

b. Predictors: (Constant), Advertsing Budget (thousands of pounds), Attractiveness of Band, No. of plays on Radio 1 per week

c. Dependent Variable: Record Sales (thousands)

الخرج 6.5 تحليل التباين

فكرة: يمكن تقييم ملاءمة نموذج التراجع باستخدام جدول ملخص النموذج Model Summary وجدول تحليل التباين ANOVA الناتجة عن برنامج SPSS. نبحث عن R^2 لمعرفة نسبة التباين التي يفسرها النموذج. إذا قمت بتراجع هرمي فإنه يمكنك تقييم التحسّن في النموذج في كل مرحلة من التحليل وذلك بالنظر إلى التغير في قيمة R^2 وفيما إذا كان هذا التغير ذا دلالة (ابحث في العمود المسمى Sig. F Change عن القيم التي تكون أقل من 0.05). يخبرنا جدول ANOVA عما إذا كان النموذج ملائماً بشكل إجمالي للبيانات (ابحث في العمود المسمى .Sig عن القيم الأدنى من 0.05). أخيراً هناك فرضية أن الأخطاء في التراجع مستقلة، ويبدو هذه الفرضية محققة إذا كانت إحصائية Durbin-Watson قريبة من القيمة 2 (محصورة بين القيم 1 و 3).

3.8.5 بارامترات النموذج

يهتم القسم التالي من الخرج الذي يعطيه برنامج SPSS ببارامترات النموذج. ويعرض (الخرج 7.5) بارامترات النموذج لكلتا المرحلتين في التسلسل الهرمي. تم في الخطوة الأولى من التسلسل الهرمي تضمين ميزانية الإعلانات (وهذا ما قمنا به في بداية الفصل عند استخدام التراجع البسيط)، وبالتالي فإن بارامترات النموذج الأول هي مماثلة للبارامترات التي حصلنا عليها في الخرج 3.5. ولذلك سنهتم في هذه الفقرة بالبارامترات الخاصة بالنموذج الثاني (الذي يتضمن جميع المتحولات التنبؤية). يعتمد تنسيق جدول المعاملات على الخيارات المحددة سابقاً. فإذا قمت بتحديد مجال الثقة لقيم b، وإحصائيات الارتباط الخطي، والارتباط الجزئي والارتباط شبه الجزئي في مربع الحوار 13.5 فإن هذه القيم ستكون موجودة في الجدول.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	95% Confidence Interval for B	
		B	Std. Error	Beta			Lower Bound	Upper Bound
1	(Constant)	134.140	7.537		17.799	.000	119.278	149.002
	Advertsing Budget (thousands of pounds)	9.612E-02	.010	.578	9.979	.000	.077	.115
2	(Constant)	-26.613	17.350		-1.534	.127	-60.830	7.604
	Advertsing Budget (thousands of pounds)	8.488E-02	.007	.511	12.261	.000	.071	.099
	No. of plays on Radio 1 per week	3.367	.278	.512	12.123	.000	2.820	3.915
	Attractiveness of Band	11.086	2.438	.192	4.548	.000	6.279	15.894

a. Dependent Variable: Record Sales (thousands)

Coefficients[a]

Model		Correlations			Collinearity Statistics	
		Zero-order	Partial	Part	Tolerance	VIF
1	(Constant)					
	Advertsing Budget (thousands of pounds)	.578	.578	.578	1.000	1.000
2	(Constant)					
	Advertsing Budget (thousands of pounds)	.578	.659	.507	.986	1.015
	No. of plays on Radio 1 per week	.599	.655	.501	.959	1.043
	Attractiveness of Band	.326	.309	.188	.983	1.038

a. Dependent Variable: Record Sales (thousands)

الخرج 7.5 معاملات نموذج التراجع

في التراجع المتعدد يأخذ النموذج شكله من المعادلة (9.5) التي تحوي عدة مقادير مجهولة (قيم b). يعطي القسم الأول من الجدول القيم التقديرية للقيم b، وتدل هذه القيم على المساهمة المنفصلة لكل متحول تنبؤي في النموذج. إذا عوضنا قيم b في المعادلة (9.5) فإننا نستطيع تعريف النموذج كما في المعادلة (12.5):

$$Sales_i = b_0+b_1Advertising_i+b_2Airplay_i+b_3Attractiveness_i$$

$$= -26.61+(0.08\ Advertising_i)+(3.37\ Airplay_i)+(11.09\ Attractiveness_i) \quad (5.12)$$

تخبرنا قيم b عن العلاقة بين أرقام المبيعات وكل من المتحولات التنبؤية. إذا كانت القيمة موجبة فإن العلاقة بين المتحول التنبؤي والنتيجة هي علاقة طردية، أما إذا كانت القيمة سالبة فإن العلاقة تكون عكسية. وبالنسبة للمثال الذي ندرسه هنا، فإن جميع قيم b للمتحولات التنبؤية هي موجبة مما يدل على علاقة طردية. ولذلك إذا ازدادت ميزانية الإعلانات فإن أرقام المبيعات ستزداد، وإذا ارتفع عدد مرات البث في الإذاعة الوطنية فإن أرقام المبيعات ستزداد، وأخيراً ترتفع أرقام المبيعات مع ازدياد جاذبية الفرقة صاحبة الأسطوانة. وتخبرنا قيم b بأكثر من ذلك أيضاً، فهي تدلنا على درجة تأثير كل متحول تنبؤي على المبيعات إذا تمت المحافظة على آثار بقية المتحولات التنبؤية ثابتة.

- **ميزانية الإعلانات (Advertising budget, b=0.085):** تدل هذه القيمة على أنه إذا ازدادت ميزانية الإعلانات بمقدار وحدة واحدة فإن أرقام المبيعات ستزداد بمقدار 0.085 وحدة. لقد تم تقدير كلا المتحولين بالآلاف، ولذلك فإن إنفاق 1000 جنيه إضافي في ميزانية الإعلانات سيزيد أرقام المبيعات بمقدار 0.085×1000=85 أسطوانة. وهذا التفسير صحيح فقط إذا تمت المحافظة على آثار عدد مرات البث الإذاعي وجاذبية الفرقة ثابتة.
- **البث الإذاعي (Airplay, b=3.367):** تدل هذه القيمة على أنه إذا ازداد عدد مرات البث الإذاعي في الأسبوع الذي يسبق إطلاق الأسطوانة بمقدار وحدة واحدة فإن أرقام المبيعات ستزداد بمقدار 3.367 وحدة. ولذلك فإن البث الإذاعي لمرة إضافية واحدة في الأسبوع الذي يسبق إطلاق الأسطوانة سيرفع أرقام المبيعات بمقدار 3.367×1000=3367 أسطوانة. وهذا التفسير صحيح فقط إذا تمت المحافظة على آثار ميزانية الإعلانات وجاذبية الفرقة ثابتة.
- **جاذبية الفرقة (Attractiveness, b=11.086):** تدل هذه القيمة على أن ارتفاع تقييم الفرقة بمقدار وحدة واحدة سيزيد أرقام المبيعات بمقدار 11.086 وحدة إضافية. ولذلك فإن كل وحدة إضافية في تقييم الفرقة سيزيد المبيعات بمقدار 11.086×1000=11,086 أسطوانة. وهذا التفسير صحيح فقط إذا تمت المحافظة على آثار ميزانية الإعلانات وعدد مرات البث الإذاعي ثابتة.

ويرتبط بكل قيمة من قيم b خطأ معياري يدل على مدى تغير هذه القيم عبر العينات المختلفة، وتُستخدم هذه الأخطاء المعيارية لتحديد فيما إذا كانت قيم b مختلفة بشكل كبير عن القيمة 0. وكما رأينا في الفقرة 4.2.5 فإنه يمكن اشتقاق الإحصائية t لاختبار فيما إذا كانت قيم b مختلفة بشكل كبير عن القيمة 0. في التراجع البسيط، تدل قيمة t ذات الدلالة على أن ميل خط التراجع مختلف بشكل كبير عن الوضعية الأفقية، أما في التراجع المتعدد فمن الصعب تخيل معنى هذه القيم. ولذلك فإن من الأسهل تخيل مبدأ الاختبار t على أنه مقياس لمقدار مساهمة المتحول التنبؤي في النموذج. ولذلك إذا كانت قيمة الاختبار t المرتبطة بقيمة b ذات دلالة (أي إذا كانت القيمة في العمود المسمى .Sig أقل من 0.05) فإن للمتحول التنبؤي مساهمة كبيرة في النموذج. وكلما كانت القيمة في العمود .Sig

أصغر (وكانت قيمة t أكبر) فإن مساهمة ذلك المتحول التنبؤي هي أكبر. ومن أجل النموذج المدروس، فإن ميزانية الإعلانات (t(196)=12.26 ،p<0.001)، وعدد مرات البث الإذاعي الذي يسبق إطلاق الأسطوانة (t(196)=12.12 ،p<0.001)، وجاذبية الفرقة (t(196)=4.55 ،p<0.001) هي متحولات ذات دلالة لأرقام المبيعات[5]. من مقارنة القيم السابقة للإحصائية t نجد أن آثار ميزانية الإعلانات وعدد مرات البث الإذاعي متشابهة بينما لجاذبية الفرقة أثر أقل.

تعتبر قيم b ومستوى دلالتها إحصائيات هامة تنبغي دراستها، ولكن تفسير النسخ المعيارية من قيم b يكون أسهل (لأنها مستقلة عن وحدات القياس للمتحولات). يوفر برنامج SPSS قيم بيتا المعيارية (تسمى β_i) وتخبرنا عن عدد مرات الانحراف المعياري التي ستتغير بها النتيجة نتيجة تغير المتحول التنبؤي بمقدار انحراف معياري واحد. تقاس جميع قيم بيتا المعيارية بوحدة الانحراف المعياري ولذلك يمكن مقارنتها فيما بينها، ولهذا فهي توفر نظرة أوضح عن أهمية متحول تنبؤي معين في النموذج. إن قيم بيتا المعيارية لعدد مرات البث الإذاعي (0.512) وميزانية الإعلانات (0.511) متماثلة تقريباً مما يدل على أن لهذين المتحولين نفس درجة الأهمية في النموذج تقريباً. ولتفسير هذه القيم، ينبغي علينا معرفة الانحرافات المعيارية لجميع المتحولات، ويمكن أن نجد هذه القيم في الخرج 4.5.

- **ميزانية الإعلانات (Advertising budget, β=0.511):** تدل هذه القيمة على أنه إذا ازدادت ميزانية الإعلانات بمقدار انحراف معياري واحد (485,655 جنيه) فإن أرقام المبيعات ستزداد بمقدار 0.511 انحرافاً معيارياً. يبلغ الانحراف المعياري لأرقام المبيعات 80,699 وهذا يعطي تغيراً في أرقام المبيعات قدره 0.511×80,699=41,240 أسطوانة. ولذلك فإن إنفاق 485,655 جنيه إضافي في ميزانية الإعلانات سيزيد أرقام المبيعات بمقدار 41,240 أسطوانة. وهذا التفسير صحيح فقط إذا تمت المحافظة على آثار عدد مرات البث الإذاعي وجاذبية الفرقة ثابتة.
- **البث الإذاعي (Airplay, β=0.512):** تدل هذه القيمة على أنه إذا ازداد عدد مرات البث الإذاعي في الأسبوع الذي يسبق إطلاق الأسطوانة بمقدار انحراف معياري واحد (12.27) فإن أرقام المبيعات ستزداد بمقدار 0.512 انحرافاً معيارياً. يبلغ الانحراف المعياري لأرقام المبيعات 80,699 وهذا يعطي تغيراً في أرقام المبيعات قدره 0.512×80,699=41,320 أسطوانة. ولذلك فإن ازدياد البث الإذاعي بمقدار 12.27 مرة في الأسبوع الذي يسبق إطلاق الأسطوانة سيرفع أرقام المبيعات بمقدار 41,320 أسطوانة. وهذا التفسير صحيح فقط إذا تمت المحافظة على آثار ميزانية الإعلانات وجاذبية الفرقة ثابتة.

---

5 لقد كتبنا t(196) حيث يشير الرقم بين القوسين على عدد درجات الحرية. ورأينا في الفقرة 5-2-4 أن عدد درجات الحرية في التراجع هو N-p-1، حيث N حجم العينة الكلي (وفي هذه الحالة 200)، و p عدد المتحولات التنبؤية (وفي هذه الحالة 3). وهكذا نحصل على عدد درجات الحرية 196=1-3-200.

- **جاذبية الفرقة (Attractiveness, β=0.192):** تدل هذه القيمة على أن ارتفاع تقييم الفرقة بمقدار انحراف معياري واحد (1.40 وحدة) سيزيد أرقام المبيعات بمقدار 0.192 انحرافاً معيارياً. وهذا يشكل تغيراً بمقدار 0.192×80,699=15,490 أسطوانة في المبيعات. أي أن تقييم فرقة ما بمقدار 1.40 أعلى من فرقة أخرى سيزيد أرقام مبيعاتها بمقدار 15,490 أسطوانة. وهذا التفسير صحيح فقط إذا تمت المحافظة على آثار ميزانية الإعلانات وعدد مرات البث الإذاعي ثابتة.

تخيل أننا جمعنا 100 عينة من البيانات بقياس نفس المتحولات الموجودة في النموذج الحالي. يمكننا من أجل كل عينة إنشاء نموذج تراجع ليمثل البيانات. إذا كان النموذج موثوقاً فإننا نأمل أن نجد بارامترات متشابهة في كلا النموذجين. ولذلك فإن كل عينة يجب أن تعطي نفس قيم b تقريباً. يُعتبر مجال الثقة لقيم بيتا غير المعيارية هو الحدود التي يتم وضعها بحيث تحوي هذه الحدود في 95% من العينات قيمة b الحقيقية (انظر الفقرة 2.6.1). فإذا جمعنا 100 عينة وحسبنا مجال الثقة لـــ b فإننا نقول أن 95% من مجالات الثقة ستحوي قيمة b الحقيقية. لذلك يمكن أن نكون على ثقة بأن مجال الثقة الذي حددناه لهذه العينة سيحوي قيمة b الحقيقية في المجتمع. وهكذا فإن للنموذج الجيد مجالات ثقة صغيرة تدل على أن قيمة b في هذه العينة قريبة من قيمة b الحقيقية في المجتمع. وتدل إشارة القيم b على اتجاه العلاقة بين المتحول التنبؤي والنتيجة. ولذلك فإننا نتوقع أن يحوي مجال الثقة للنموذج السيئ على القيمة 0 مما يدل على أنه في بعض العينات تكون علاقة المتحول التنبؤي بالنتيجة طردية بينما تصبح علاقة عكسية في العينات الأخرى. في النموذج المدروس، يملك أفضل متحولين تنبؤيين (ميزانية الإعلانات وعدد مرات البث الإذاعي) مجال ثقة ضيقاً جداً مما يدل على احتمال أن تكون القيم التقديرية للنموذج الحالي ممثلة لقيم المجتمع الحقيقي. إن مجال الثقة للجاذبية أعرض (ولكنه لا يحوي القيمة 0) مما يدل على أن البارامتر لهذا المتحول أقل تمثيلاً ولكنه مازال يتمتع بالأهمية.

إذا سألت عن الارتباط الجزئي (Partial) والارتباط شبه الجزئي (Part) فإنك تراهما في عمودين مستقلين في جدول الخرج. يمثل الارتباط من المرتبة 0 معاملات Pearson للارتباط البسيط (ولذلك تتطابق قيمها مع الخرج 4.5). يمثل الارتباط الجزئي (Partial) العلاقات بين كل متحول تنبؤي ومتحول النتيجة مع التحكم بأثر المتحولين التنبؤيين الآخرين. بينما يمثل الارتباط شبه الجزئي (Part) العلاقة بين كل متحول تنبؤي ومتحول النتيجة مع التحكم بالأثر الذي يملكه كل من المتحولين التنبؤيين الآخرين على النتيجة. وفي الحقيقة، تمثل الارتباطات شبه الجزئية العلاقة الوحيدة التي يملكها كل متحول تنبؤي مع النتيجة. إذا اخترت أن تقوم بتراجع خطوي فإنك تجد أن إدخال المتحولات يعتمد بشكل أولي على المتحول الذي يملك أكبر قيمة لمعامل الارتباط من المرتبة 0 ثم على الارتباطات شبه الجزئية لبقية المتحولات التنبؤية. لذلك يجب إدخال متحول عدد مرات البث الإذاعي أولاً (لأنه يملك القيمة الأكبر لمعامل الارتباط من المرتبة 0)، ثم ميزانية الإعلانات (لأن الارتباط شبه الجزئي لها أكبر من الارتباط شبه الجزئي لجاذبية الفرقة)، وأخيراً يتم إدخال جاذبية

الفرقة. حاول تنفيذ التراجع الخطوي التقدمي على هذه البيانات للتحقق من صحة ما ذكرناه. وأخيراً يعطي البرنامج بعض التفاصيل عن إحصائيات الارتباط الخطي، وستتم مناقشة هذه الإحصائيات في الفقرة 5.8.5.

فكرة: يمكن إيجاد المساهمة المنفصلة للمتحولات في نموذج التراجع في الجدول Coefficients الذي يعطيه برنامج SPSS. إذا قمت بتراجع هرمي فانظر إلى القيم في النموذج النهائي. يمكنك أن ترى المساهمة التي قام بها كل متحول تنبؤي في التوقّع بالنتيجة وذلك بالنظر إلى العمود المسمى .Sig (القيم الأصغر من 0.05 هي ذات الدلالة). يجب أن تنظر أيضاً إلى قيم بيتا المعيارية لأنها تخبرك بأهمية كل متحول تنبؤي (كلما كانت القيمة المطلقة أكبر كان المتحول أكثر أهمية). كما تساعد قيم التسامح و VIF التي تأتي لاحقاً في هذه العملية.

4.8.5 المتحولات المستثناة

يوفر برنامج SPSS عند كل مرحلة من تحليل التراجع ملخصاً للمتحولات التي لم يتم إدخالها بعد في النموذج. في النموذج الهرمي، يقدم هذا الملخص تفاصيل عن المتحولات التي تم تحديدها ليتم إدخالها في الخطوات التالية، وفي التراجع الخطوي فإن هذا الجدول (الخرج 8.5) يحوي ملخصاً للمتحولات المعتبرة ضمن النموذج. ومن أجل هذا المثال، هناك ملخص للمتحولات المستثناة في المرحلة الأولى من التسلسل الهرمي (ليس هناك ملخص للمرحلة الثانية، لأن جميع المتحولات التنبؤية هي ضمن النموذج). يعطي الملخص تقديراً لقيمة بيتا لكل متحول تنبؤي كما لو تم إدخاله في المعادلة عند هذه النقطة، ويقوم بحساب الاختبار t لهذه القيمة. في التراجع الخطوي، يجب أن يتم إدخال المتحول التنبؤي الذي يملك أعلى قيمة للاختبار t ومتابعة إدخال المتحولات التنبؤية حتى لا يبقى أي متحول تنبؤي ذي دلالة أقل من 0.05 لاختبار t. يوفر الارتباط الجزئي بعض المعلومات مثل المساهمة (إن وجدت) التي يمكن أن يقدمها أي من المتحولات التنبؤية المستثناة فيما لو تم إدخاله في النموذج.

Excluded Variables[b]

Model		Beta In	t	Sig.	Partial Correlation	Collinearity Statistics		
						Tolerance	VIF	Minimum Tolerance
1	No. of plays on Radio 1 per week	.546[a]	12.513	.000	.665	.990	1.010	.990
	Attractiveness of Band	.281[a]	5.136	.000	.344	.993	1.007	.993

a. Predictors in the Model: (Constant), Advertising Budget (thousands of pounds)

b. Dependent Variable: Record Sales (thousands)

الخرج 8.5 المتحولات المستثناة

5.8.5 تقييم فرضية عدم الارتباط الخطي المتعدد

يوفر الخرج 7.5 بعض القياسات حول وجود الارتباط الخطي في البيانات. ويقدم بشكل خاص إحصائية التسامح و VIF (التسامح هو مقلوب VIF). هناك بعض التوجيهات من الفقرة 3.2.6.5 التي يمكن تطبيقها هنا:

- إذا كانت أكبر قيمة للإحصائية VIF أكبر من 10 فإن هناك مايدعو للقلق.
- إذا كان متوسط VIF أكبر بكثير من 1 فإن التراجع قد يتأثر.
- تدل القيمة الأدنى من 0.1 للتسامح على مشكلة خطيرة.
- تدل القيمة الأدنى من 0.2 للتسامح على مشاكل محتملة.

من أجل النموذج الحالي فإن جميع قيم VIF أصغر من 10 وجميع إحصائيات التسامح أعلى من 0.2 ولذلك يمكننا أن نستنتج بأمان عدم وجود ارتباط خطي ضمن البيانات. لحساب متوسط VIF نجمع قيم VIF لجميع المتحولات التنبؤية ونقسم ناتج الجمع على عدد المتحولات التنبؤية (k):

$$\overline{VIF} = \frac{\sum_{i=1}^{k} VIF_i}{k} = \frac{1.015 + 1.043 + 1.038}{3} = 1.032$$

إن قيمة متوسط VIF قريبة جداً من 1 وهذا يؤكد أن الارتباط الخطي لا يعتبر مشكلة لهذا النموذج. يعطي برنامج SPSS أيضاً جدولاً للقيم الخاصة لمصفوفة الجداء المتصالب، وأدلة الحالة، ونسب التباين. ستكون هناك مناقشة طويلة ومثال عن الارتباط الخطي في الفقرة 8.6 وكيفية اكتشافها باستخدام نسب التباين، ولذلك نكتفي الآن بالقول أننا نبحث عن النسب الكبيرة للتباين على نفس القيم الخاصة الصغيرة. ولذلك فإننا ننظر في الخرج 9.5 إلى الأسطر السفلية من الجدول (وهي القيم الخاصة الصغيرة) ونبحث عن المتحولات التي تملك نسباً عالية للتباين من أجل تلك القيمة الخاصة. تتغير نسب التباين بين القيمتين 0 و1، ومن أجل كل متحول تنبؤي فإنها يجب أن تكون موزعة عبر الأبعاد المختلفة (أو القيم الخاصة). فمن أجل هذا النموذج، يمكننا أن نرى أن كل متحول تنبؤي يملك معظم تحميله من التباين على بُعد مختلف (لميزانية الإعلانات 96% من التباين على البعد 2، ولعدد مرات البث 93% من التباين على البعد 3، ولجاذبية الفرقة 92% من التباين على البعد 4). تمثل هذه البيانات مثالاً تقليدياً عن عدم الارتباط الخطي المتعدد. وكمثال عن وجود الارتباط الخطي في البيانات وبعض الاقتراحات عما يمكن إنجازه، ننصحك بالعودة للفصل 5 والفصل 11 والفقرة 8.6.

Collinearity Diagnostics[a]

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions			
				(Constant)	Advertising Budget (thousands of pounds)	No. of plays on Radio 1 per week	Attractiveness of Band
1	1	1.785	1.000	.11	.11		
	2	.215	2.883	.89	.89		
2	1	3.562	1.000	.00	.02	.01	.00
	2	.308	3.401	.01	.96	.05	.01
	3	.109	5.704	.05	.02	.93	.07
	4	2.038E-02	13.219	.94	.00	.00	.92

a. Dependent Variable: Record Sales (thousands)

الخرج 9.5 أدوات التشخيص للارتباط الخطي

فكرة: للتحقق من فرضية عدم الارتباط الخطي المتعدد، استخدم قيم VIF من الجدول المسمى Coefficients في الخرج الذي يعطيه برنامج SPSS. إذا كانت هذه القيم أصغر من 10 فإن ذلك يدل على عدم وجود أسباب للقلق. إذا أخذنا متوسط القيم VIF ولم تكن قيمة المتوسط أكبر من 1 بكثير فإن ذلك يدل على عدم وجود أسباب للقلق أيضاً.

المربع 5-2 ما هي الأشعة الخاصة والقيم الخاصة؟

تعتبر التعاريف والرياضيات المتعلقة بالأشعة الخاصة eigenvectors والقيم الخاصة eigenvalues معقدة جداً، ولكن لا داعي لأن نقلق بشأنها (مع أننا سنصادفها مرة أخرى في الفصول 14 و 15). ومع أن المفاهيم الرياضية صعبة فمن السهل تصورها. تخيل أن لدينا متحولين: الراتب السنوي الذي تتقاضاه عارضة أزياء، ومدى جاذبيتها. تخيل أن هذين المتحولين موزعين طبيعياً ولذلك يمكن اعتبارهما معاً كتوزيع طبيعي ثنائي التغير. إذا كان هذان المتحولان مرتبطين فإن المخطط المبعثر لهما يشكل قطعاً ناقصاً (ellipse). ويظهر ذلك في المخططات المبعثرة اللاحقة، إذا رسمنا خطاً متقطعاً حول القيم الخارجية في المخطط المبعثر فإننا نحصل على شكل بيضوي. يمكننا أن نرسم الآن خطين لقياس طول وارتفاع هذا القطع الناقص. يمثل هذان الخطان الأشعة الخاصة (eigenvectors) لمصفوفة الارتباط الأصلية لهذين المتحولين (الشعاع هو مجموعة من الأرقام التي تدل على موقع خط ما في فراغ هندسي). لاحظ أن الخطين اللذين قمنا برسمهما متعامدان وهذا يعني أنهما مستقلان عن بعضهما البعض. ولذلك فإنه في حالة متحولين فقط تكون الأشعة الخاصة هي الخطوط التي تقيس طول وارتفاع القطع الناقص الذي يحيط بالمخطط المبعثر للبيانات من أجل هذين المتحولين. إذا أضفنا متحولاً ثالثاً (كخبرة عارضة الأزياء) فإن ما يحصل هو أن يأخذ المخطط المبعثر بعداً ثالثاً، ويتحول القطع الناقص إلى شكل فراغي يشبه كرة الركبي (أو كرة القدم الأميركية). ونظراً لوجود ثلاثة أبعاد (الارتفاع والعرض والعمق) فإن هناك شعاعاً خاصاً لقياس هذا البعد الإضافي. وإذا أضفنا بعداً رابعاً فيتم تطبيق منهجية مشابهة (مع صعوبة تخيل ذلك)، حيث تتم إضافة بعد رابع، وبالتالي شعاع خاص لقياس هذا البعد الإضافي. لكل شعاع خاص قيمة

خاصة (eigenvalue) تدلنا على طوله (أي المسافة من أحد طرفي الشعاع إلى الطرف الآخر). لذلك وبالنظر إلى جميع القيم الخاصة لمجموعة من البيانات فإننا نعرف أبعاد القطع الناقص أو كرة الركبي، وبشكل عام فإننا نعرف أبعاد البيانات. لذلك فإن القيم الخاصة تبين كيفية توزع تباينات المصفوفة.

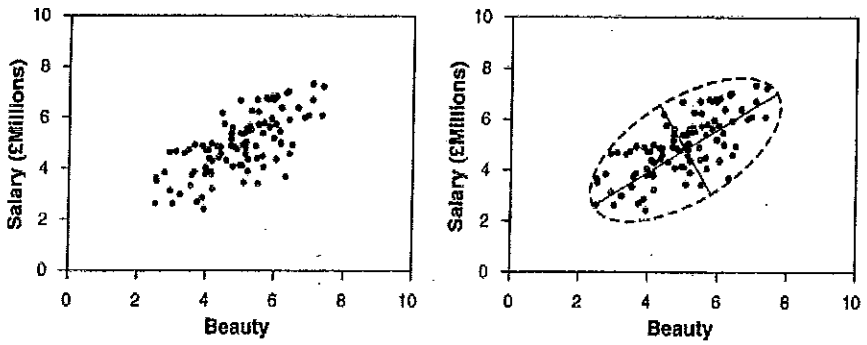

في حالة وجود متحولين، ترتبط الحالة (condition) للبيانات بنسبة القيمة الخاصة الكبرى إلى القيمة الخاصة الصغرى. لنأخذ الحالتين الحديتين: عدم وجود علاقة بين المتحولات على الإطلاق، ووجود علاقة تامة بين المتحولات. عند عدم وجود علاقة سيكون المخطط المبعثر موجوداً ضمن دائرة (أو كرة إذا كان هناك ثلاثة متحولات). إذا رسمنا الخطوط التي تقيس العرض والارتفاع لهذه الدائرة فإننا نجد أن الخطين متساويان في الطول. وبما أن القيم الخاصة تقيس طول الخط فإن القيم الخاصة تكون متساوية. لذلك عندما نقسم القيمة الخاصة الكبرى على القيمة الخاصة الصغرى فإننا نحصل على القيمة 1 (لأن القيم الخاصة متساوية). أما عندما تكون المتحولات مرتبطة بشكل مثالي (هناك ارتباط خطي تام) فإن المخطط المبعثر يشكّل خطاً مستقيماً، وسينطبق القطع الناقص المحيط به ويتحول إلى خط مستقيم. ولذلك فإن ارتفاعه سيكون صغيراً جداً (قريباً جداً من القيمة 0). وبالتالي فإن حاصل قسمة القيمة الخاصة الكبرى على الصغرى سيعطي قيمة تسعى للانهاية (لأن القيمة الخاصة الصغرى قريبة جداً من 0). ولذلك فإن دليل الحالة اللانهائي هو دليل على مشكلة كبيرة.

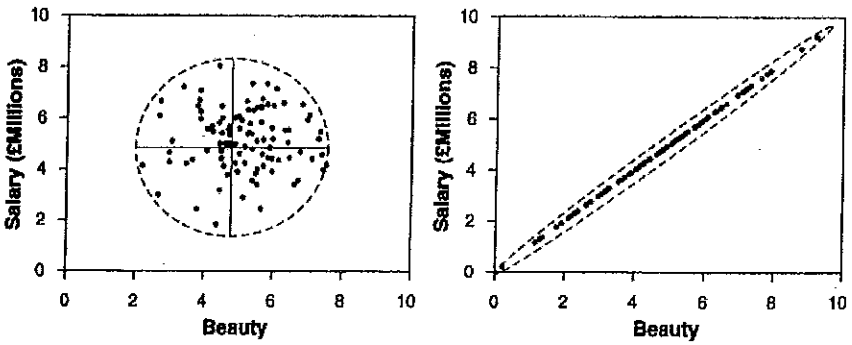

6.8.5 أدوات تشخيص الحالة

يعطي برنامج SPSS جدولاً بإحصائيات الباقي التي يجب تدقيقها بحثاً عن الحالات القصوى. يعرض (الخرج 10.5) الحالات التي تملك باقياً معيارياً أصغر من 2- أو أكبر من 2+ (تذكّر أننا غيرنا القيمة الافتراضية للمعيار من 3 إلى 2 في مربع الحوار المبين في الشكل 13.5). لقد ذكرنا في الفقرة 1.1.6.5 أنه في مثال عادي علينا أن نتوقع أن تملك 95% من الحالات باقياً معيارياً ضمن الحدود 2±. لدينا عينة مؤلفة من 200 حالة، ومن المعقول أن نتوقع وجود 10 حالات (تشكل 5% من حجم العينة) يكون الباقي المعياري فيها خارج تلك الحدود. من الخرج 10.5 يمكننا أن نحصي 12 حالة (أي 6%) خارج الحدود، ولذلك فإن العينة ضمن 1% مما توقعناه. إضافة لذلك يجب أن تقع 99% من الحالات ضمن الحدود 2.5± وبالتالي فإن 1% فقط من الحالات تقع خارج تلك الحدود. ومن أجل الحالات المبينة فمن الواضح وجود حالتين فقط (أي 1%) خارج الحدود (هما الحالتان 164 و 169). وهكذا فإن العينة تبدو مطابقة لما يمكن أن نعتبره نموذجاً دقيقاً. لم تعطنا أدوات تشخيص الحالة سبباً حقيقياً للقلق ما عدا أن للحالة 169 باقياً معيارياً تتعدى قيمته 3 وهي قيمة كبيرة نسبياً تدفعنا لدراسة هذه الحالة بشكل معمق.

Casewise Diagnostics[a]

Case Number	Std. Residual	Record Sales (thousands)	Predicted Value	Residual
1	2.125	330.00	229.9203	100.0797
2	-2.314	120.00	228.9490	-108.9490
10	2.114	300.00	200.4662	99.5338
47	-2.442	40.00	154.9698	-114.9698
52	2.069	190.00	92.5973	97.4027
55	-2.424	190.00	304.1231	-114.1231
61	2.098	300.00	201.1897	98.8103
68	-2.345	70.00	180.4156	-110.4156
100	2.066	250.00	152.7133	97.2867
164	-2.577	120.00	241.3240	-121.3240
169	3.061	360.00	215.8675	144.1325
200	-2.064	110.00	207.2061	-97.2061

a. Dependent Variable: Record Sales (thousands)

الخرج 10.5 أدوات تشخيص الحالة

ربما تتذكر أننا طلبنا في الفقرة 4.7.5 من برنامج SPSS حفظ إحصائيات التشخيص المختلفة. وتجد الآن أن محرر البيانات يحوي أعمدة لتلك المتحولات. يمكنك طبعاً التدقيق بهذه القيم في محرر

البيانات، ولكن يمكنك أن تطلب من برنامج SPSS أن يعرض القيم في نافذة العارض أيضاً. ويتم ذلك باختيار أمر القائمة Analyze ⇒ Reports ⇒ Case Summaries... يبين (الشكل 17.5) مربع الحوار لهذه الوظيفة. اختر المتحولات التي تريد عرضها وانقلها من القسم الأيسر من مربع الحوار إلى الحيز المسمى Variables بنقر زر السهم الموجود بين القسمين. يحدّ برنامج SPSS الخرج بمقدار 100 حالة الأولى، ولكن إذا أردت عرض جميع الحالات فانقر لإلغاء تحديد هذا الخيار (Limit cases to first). من المهم جداً تحديد الخيار Show case numbers وإلا فإنك لن تستطيع تمييز الحالة صاحبة المشكلة.

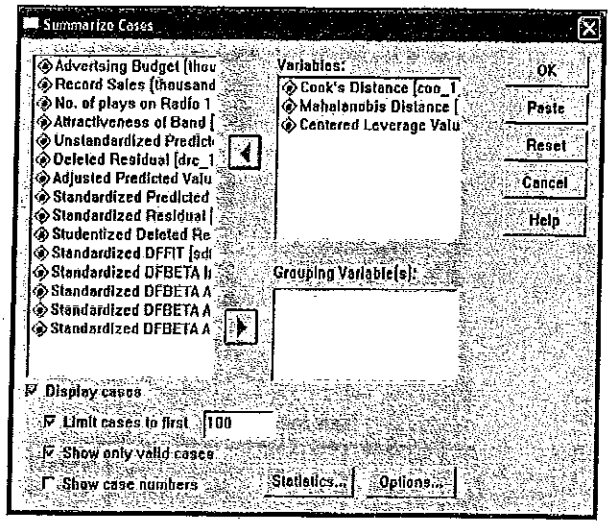

الشكل 17.5

هناك إستراتيجية مفيدة وهي استخدام أدوات تشخيص الحالة لتحديد الحالات التي تريد التدقيق فيها بشكل معمق. ولذلك فقد قمنا بإنشاء متحول ترميز (مع القيم 1=تضمين، 0=استثناء) بحيث يمكننا تحديد 12 حالة المبينة في الخرج 11.5 في مجموعة واحدة، وبقية الحالات في المجموعة الأخرى. باستخدام متحول الترميز وتحديده كمتحول تجميع في مربع الحوار تلخيص الحالات Summarize Cases المبين في الشكل 17.5 يمكننا النظر إلى هذه الحالات معاً وإهمال بقية الحالات.

يعرض الخرج 11.5 إحصائيات التأثير للحالات المحددة. لا تتجاوز مسافة كوك Cook لأي من هذه الحالات القيمة 1 (حتى للحالة 169 فإن مسافة كوك أدنى من هذا المعيار)، وليس لأي من هذه الحالات تأثير مهم على النموذج. يمكن حساب الفعالية الوسطى من العلاقة (k+1)/n=0.02 ونبحث عن ضعفي هذه القيمة (أي 0.04) أو ثلاثة أضعافها (أي 0.06) بناءً على المعايير التي نثق بها (انظر الفقرة 2.1.6.5). تقع جميع الحالات ضمن حدود ثلاثة أضعاف متوسطة الفعالية، باستثناء الحالة 1 القريبة من ضعفي متوسط الفعالية. أخيراً، ومن خلال التوجيهات لمسافة Mahalanobis

فإننا نرى أنه من أجل عينة مؤلفة من 100 حالة وثلاثة متحولات تنبؤية فإن القيم التي تكون أكبر من 15 تكون حالات إشكالية. ولكننا نملك عينة أكبر (200 حالة) مع ثلاثة متحولات تنبؤية لذلك فإن تلك القيمة تكون نقطة القطع، ومع ذلك لا توجد أية حالة قريبة من ذلك المعيار. ونستنتج بالتالي عدم وجود حالات مؤثرة في البيانات (يجب التدقيق في جميع الحالات لتأكيد هذه الحقيقة).

Case Summaries

	Case Number	Standardized DFBETA Intercept	Standardized DFBETA ADVERTS	Standardized DFBETA AIRPLAY	Standardized DFBETA ATTRACT	Standardized DFFIT	COVRATIO
1	1	-.31554	-.24235	.15774	.35329	.48929	.97127
2	2	.01259	-.12637	.00942	-.01868	-.21110	.92018
3	10	-.01256	-.15612	.16772	.00672	.26896	.94392
4	47	.06645	.19602	.04829	-.17857	-.31469	.91458
5	52	.35291	-.02881	-.13667	-.26965	.36742	.95995
6	55	.17427	-.32649	-.02307	-.12435	-.40736	.92486
7	61	.00082	-.01539	.02793	.02054	.15562	.93654
8	68	-.00281	.21146	-.14766	-.01760	-.30216	.92370
9	100	.06113	.14523	-.29984	.06766	.35732	.95888
10	164	.17983	.28988	-.40088	-.11706	-.54029	.92037
11	169	-.16819	-.25765	.25739	.16968	.46132	.85325
12	200	.16633	-.04639	.14213	-.25907	-.31985	.95435
Total N		12	12	12	12	12	12

Case Summaries

	Case Number	Cook's Distance	Mahalanobis Distance	Centered Leverage Value
1	1	.05870	8.39591	.04219
2	2	.01089	.59830	.00301
3	10	.01776	2.07154	.01041
4	47	.02412	2.12475	.01068
5	52	.03316	4.81841	.02421
6	55	.04042	4.19960	.02110
7	61	.00595	.06880	.00035
8	68	.02229	2.13106	.01071
9	100	.03136	4.53310	.02278
10	164	.07077	6.83538	.03435
11	169	.05087	3.14841	.01582
12	200	.02513	3.49043	.01754
Total N		12	12	12

الخرج 11.5 ملخصات الحالة

يمكننا أن ننظر إلى إحصائيات DFBeta لنرى فيما إذا كان لأي من الحالات تأثير كبير على بارامترات التراجع. إذا كانت القيمة المطلقة أكبر من 1 فإن الحالة تكون إشكالية، ونجد أن جميع الحالات تقع ضمن الحدود 1± وهذا يعني أنه ليس لهذه الحالات تأثير مهم على بارامترات التراجع. هناك عمود أيضاً لنسبة التباين المشترك (COVRATIO). وقد رأينا في الفقرة 2.1.6.5 أننا بحاجة إلى المعايير التالية:

- $CVR_i > 1+[3(k+1)/n]=1+[3(3+1)/200]=1.06$
- $CVR_i < 1-[3(k+1)/n]=1-[3(3+1)/200]=0.94$

لذلك نبحث عن الحالة التي تنحرف بشكل كبير عن هذه الحدود. تقع قيم CVR لمعظم الحالات (من بين الحالات المحددة والمحتملة لأن تكون نقاطاً منعزلة) ضمن هذه الحدود أو على أطرافها الخارجية مباشرة. والحالة الوحيدة التي تستدعي الاهتمام هي الحالة 169 (مرة أخرى!) حيث تنخفض قيمة CVR فيها عن الحد الأدنى. وبمعرفتنا مسافة كوك لهذه الحالة فمن المحتمل وجود سبب للتنبيه.

لقد حددنا إحصائيات تشخيص أخرى، ومما تعلمناه من المناقشة الأخيرة لتلك الإحصائيات فإننا ننصحك بإلقاء نظرة على هذه الإحصائيات لمعرفة الحالات غير العادية في البيانات. على كل حال، ومن خلال هذه المجموعة من أدوات التشخيص يبدو أن النموذج موثوق إلى حد ما ولا يوجد تأثير مهم لأي من الحالات.

فكرة: يجب أن تنظر إلى الحالات التي قد يكون لها تأثير على نموذج التراجع.

- انظر إلى البواقي المعيارية وتحقق من عدم امتلاك أكثر من 5% من الحالات لقيمة مطلقة أعلى من 2، ومن عدم امتلاك أكثر من 1% من الحالات لقيمة مطلقة أعلى من 2.5. وعند وجود حالة تكون قيمتها المطلقة أكبر من 3 فيمكنك اعتبارها كنقطة منعزلة.
- انظر في محرر البيانات إلى قيم مسافة كوك، إن القيم التي تكون أكبر من 1 تدل على حالة قد تؤثر على النموذج.
- احسب متوسط الفعالية (حاصل قسمة مجموع عدد المتحولات التنبؤية مع العدد 1 على حجم العينة)، ثم ابحث عن القيم التي تكون أكبر من ضعفي أو ثلاثة أضعاف متوسط الفعالية.
- ابحث في مسافة Mahalanobis عن القيم التي تكون أكبر من 25 في العينات الكبيرة (250 حالة) أو التي تكون أكبر من 15 في العينات الأصغر (100 حالة). ومن أجل تحليل مفصل يمكن العودة إلى كتاب Barnett & Lewis (1978).
- ابحث عن القيم المطلقة التي تكون أكبر من 1 للإحصائية DFBeta.
- احسب الحد الأعلى والأدنى للقيم المقبولة لنسبة التباين المشترك CVR. يحسب الحد الأعلى بإضافة العدد 1 إلى ثلاثة أضعاف متوسط الفعالية، بينما يحسب الحد الأدنى بطرح ثلاثة أضعاف متوسط الفعالية من العدد 1. إن الحالات التي تكون قيمة CVR لها خارج تلك الحدود قد تكون إشكالية.

7.8.5 التحقق من الفرضيات

كمرحلة أخيرة في التحليل، يجب التحقق من فرضيات النموذج، لقد نظرنا سابقاً للارتباط الخطي ضمن البيانات واستخدمنا Durbin-Watson للتحقق فيما إذا كانت البواقي في النموذج مستقلة.

وقد طلبنا في الفقرة 3.7.5 مخططاً بيانياً للمتحول ZRESID* مقابل ZPRED* ومخططاً تكرارياً ومخطط الاحتمال الطبيعي للبواقي. يجب أن يبدو مخطط ZRESID* مع ZPRED* كصف عشوائي من النقاط المبعثرة بانتظام حول القيمة 0. إذا كان المخطط يأخذ شكل قمع فإن هناك عدم تجانس في التباين للبيانات. إذا وجد شكل منحني من أي نوع في المخطط فإن ذلك يدل على أن البيانات لم تحقق فرضية الخطية. يبين (الشكل 18.5) عدة أمثلة لمخطط البواقي المعيارية مقابل القيم المتوقعة المعيارية. يبين المخطط (a) بيانات أرقام المبيعات لمثالنا الحالي. لاحظ التوزع العشوائي والتبعثر المنتظم في المخطط. يدل هذا النمط على حالة تحققت فيها فرضيات الخطية وتجانس التباين. يعرض المخطط (b) مجموعة بيانات لم تتحقق فيها فرضية تجانس التباين. لاحظ أن المخطط يأخذ شكل قمع حيث تكون النقاط مبعثرة بشكل أكبر على المخطط. يدل شكل القمع على عدم تجانس التباين وعلى زيادة التباين في البواقي. يعرض المخطط (c) بعض البيانات التي توجد فيها علاقة غير خطية بين المتحول التنبؤي والنتيجة. وينتج هذا النمط عن البواقي. يوضح الخط العلاقة المنحنية في البيانات. وأخيراً يمثل المخطط (d) الوضعية التي تكون فيها العلاقة غير خطية وهناك عدم تجانس في التباين للبيانات. لاحظ أولاً المنحى المنحني للبيانات، ثم لاحظ أن النقاط في نهايتي مخطط البيانات تصبح متقاربة جداً بينما هي في النهاية الأخرى منتشرة بشكل واسع. عندما لا تتحقق هذه الفرضيات فإنك لن ترى هذه الأنماط بدقة، ولكنها تساعدك على فهم هذه الأنواع من عدم الانتظام التي تبحث عنها.

لاختبار طبيعة البواقي، يجب أن ننظر إلى المخطط التكراري ومخطط الاحتمال الطبيعي اللذين اخترناهما في مربع الحوار المبين في الشكل 14.5. يعرض (الشكل 19.5) المخطط التكراري ومخطط الاحتمال الطبيعي للبيانات في المثال الحالي (القسم الأيسر من الشكل). يجب أن يكون شكل المخطط التكراري كتوزيع طبيعي (منحني الجرس). يرسم برنامج SPSS خطاً منحنياً فوق المخطط التكراري ليبين شكل التوزيع. ويبدو التوزيع لبيانات المبيعات لشركة الأسطوانات طبيعياً نوعاً ما (رغم وجود تشوه للبواقي عند القيمة 0 تماماً). بمقارنة هذا المخطط التكراري مع المخطط التكراري غير الطبيعي الموجود بجانبه نرى أن المخطط التكراري غير الطبيعي غير متناظر. لذلك يجب أن نبحث عن منحني له نفس الشكل الموجود لبيانات المبيعات لشركة الأسطوانات. إن أي انحراف عن هذا المنحني هو دليل على عدم الطبيعية، وكلما ازداد الانحراف كان التوزيع غير الطبيعي للبواقي أكبر. يبين مخطط الاحتمال الطبيعي الانحرافات عن المنحني الطبيعي (انظر الفصل 2). يمثل الخط المستقيم في هذا المخطط التوزيع الطبيعي، وتمثل النقاط البواقي المشاهدة. لذلك فإنه في مجموعة البيانات الموزعة طبيعياً بشكل مثالي، ستقع جميع النقاط على هذا الخط. وما رأيناه لبيانات المبيعات رائع جداً. بجانب هذا المخطط هناك مثال عن حالة الانحراف العظمى عن التوزيع الطبيعي. في هذا المخطط تبتعد النقاط بشكل كبير عن الخط مما يدل على انحراف كبير عن التوزيع الطبيعي. وفي المخططين اللذين يمثلان بيانات غير طبيعية، استخدمنا حالات قصوى، ولكن عليك الحذر والانتباه إلى أن الانحراف عن الطبيعية من المحتمل أن يكون بهذا الشكل. يمكنك طبعاً

الاستفادة مما تعلمته في الفصل 2 للقيام باختبار K-S على البواقي المعيارية لمعرفة مدى انحرافها عن التوزيع الطبيعي.

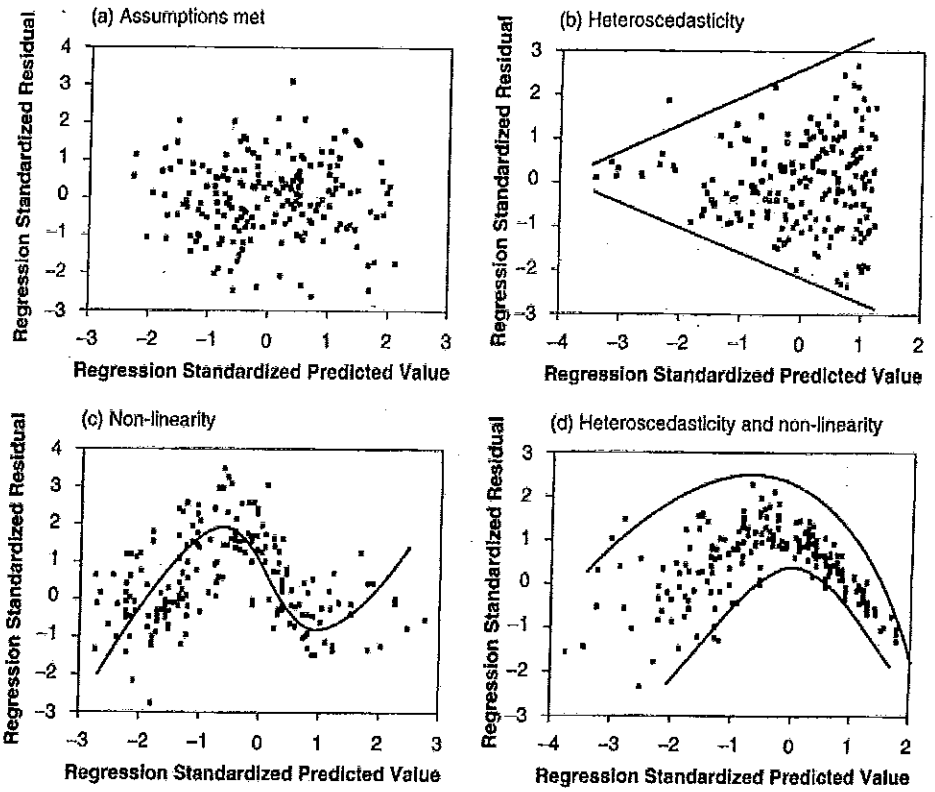

الشكل 18.5

أما المجموعة الأخيرة من المخططات التي حددناها في مربع الحوار المبين في الشكل 14.5 فهي المخططات الجزئية. وهذه المخططات هي عبارة عن مخططات مبعثرة لبواقي متحول النتيجة مع كل من المتحولات التنبؤية عند القيام بالتراجع لكل من المتحولين بشكل منفصل عن بقية المتحولات التنبؤية. لقد أشرنا سابقاً أن النقاط المنعزلة البديهية في مخطط جزئي تمثل الحالات التي قد تملك تأثيراً مهماً على معامل التراجع للمتحول التنبؤي، وأنه يمكن اكتشاف العلاقات غير الخطية وعدم تجانس التباين باستخدام هذه المخططات أيضاً.

فمن أجل ميزانية الإعلانات، يمثل المخطط الجزئي العلاقة الطردية القوية مع أرقام المبيعات. إن ميل الخط هو b لميزانية الإعلانات في النموذج (لا يظهر هذا الخط بشكل افتراضي). لا تبدو هناك نقاط منعزلة بديهية في هذا المخطط، وتبدو غيمة النقاط متباعدة بشكل منتظم حول الخط مما يدل على تجانس التباين.

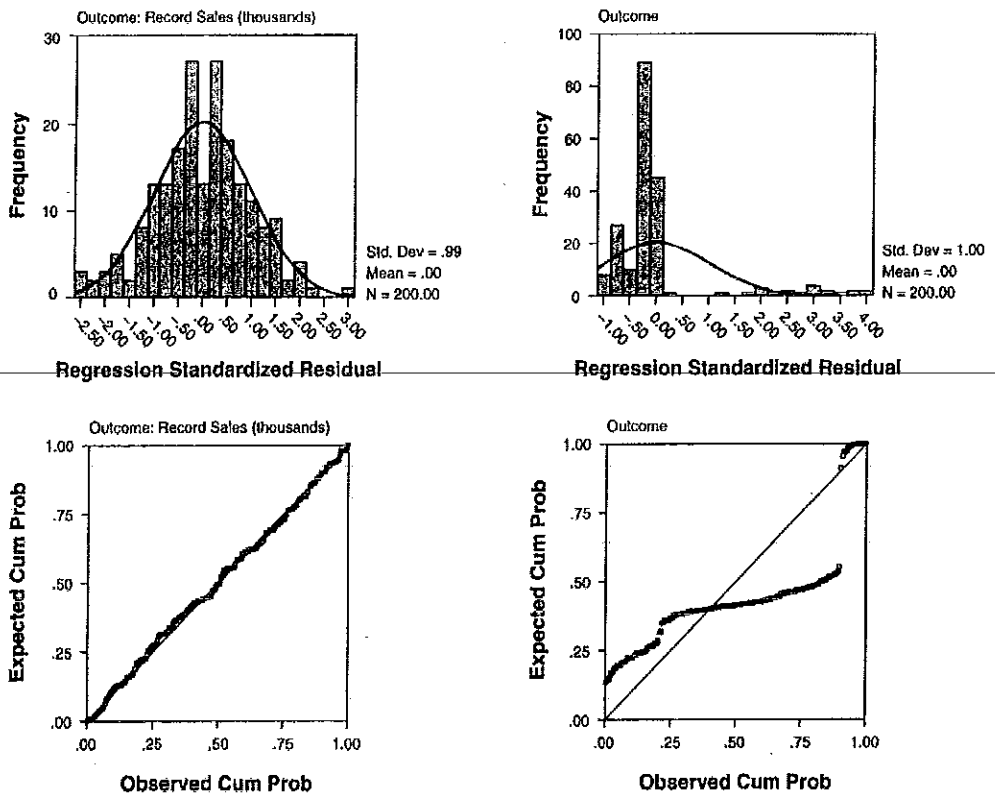

الشكل 19.5 مخططات تكرارية ومخططات P-P للبواقي الموزعة طبيعياً (القسم الأيسر) وبواقي موزعة بشكل غير طبيعي (القسم الأيمن)

ومن أجل عدد مرات البث الإذاعي فإن المخطط الجزئي يبين العلاقة الطردية القوية مع أرقام المبيعات. إن ميل الخط ونمط البيانات مشابه لميزانية الإعلانات (وهذا ما يجب أن نتوقعه نظراً لتشابه قيم بيتا المعيارية لهذين المتحولين التنبؤيين). ولا تبدو هناك نقاط منعزلة بديهية في هذا المخطط، كما أن غيمة النقاط متباعدة بشكل منتظم حول الخط مما يدل على تجانس التباين.

أما من أجل جاذبية الفرقة فإن المخطط الجزئي يعرض العلاقة الطردية مع أرقام المبيعات. وتبدو العلاقة أقل خطية من المتحولين الآخرين، وتبدو النقاط بشكل قمع مما يدل على تباين أكبر عند المستويات العليا للجاذبية. ليست هناك نقاط منعزلة بديهية في هذا المخطط، ولكن شكل القمع لغيمة النقاط يدل على عدم احترام فرضية تجانس التباين. وينبغي علينا جمع المزيد من البيانات حول الفرق غير الجذابة للتحقق من النموذج الحالي.

يمكننا تلخيص ذلك بالقول أن النموذج يبدو (من جميع النواحي) دقيقاً من أجل العينة وقابلاً للتعميم على المجتمع. والمأخذ الوحيد الذي يمكن أن نهتم به هو مدى احترام معدلات جاذبية الفرقة لفرضية تجانس التباين. ولذلك يمكننا أن نستنتج أن ميزانية الإعلانات وعدد مرات البث الإذاعي

للعينة هي متساوية الأهمية في التنبؤ بأرقام المبيعات. أما جاذبية الفرقة فهي متحول تنبؤي مهم في أرقام المبيعات ولكنه أقل أهمية من المتحولين التنبؤيين الآخرين (وربما يحتاج لمزيد من التدقيق بسبب عدم تجانس التباين المحتمل). تبدو هذه الفرضيات محققة ولذلك يمكننا أن نفترض أنه يمكن تعميم النموذج لأي أسطوانة سيتم إطلاقها.

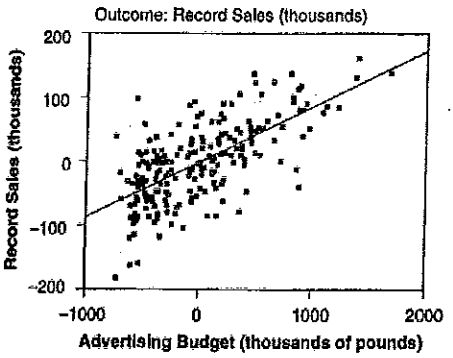

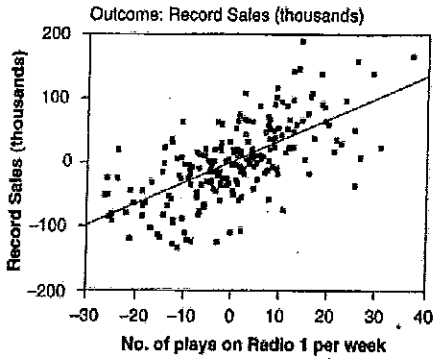

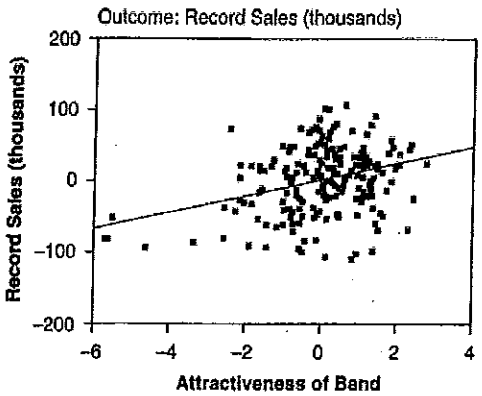

أفكار مهمة: يجب التحقق من فرضيات التراجع للتأكد من قابلية تعميم النموذج خارج العينة.

- انظر مخطط ZRESID* مقابل ZPRED*. فإذا بدا كصف عشوائي من النقاط فهذا جيد. إذا بدت النقاط موزعة بشكل قمع فمن المحتمل عدم تحقق فرضية تجانس التباين. وإذا كانت النقاط موزعة وفق نمط معين (كشكل منحني مثلاً) فهذا يعني احتمال عدم تحقق فرضية الخطية. أما إذا كانت النقاط موزعة وفق نمط ما ومنتشرة بشكل واسع في جزء معين من المخطط أكثر من الأجزاء الأخرى فقد يعكس ذلك عدم احترام كل من فرضيتي تجانس التباين والخطية. وإن أي من هذه السيناريوهات يضع مصداقية النموذج موضع تساؤل. كرر التحليل السابق على المخططات الجزئية أيضاً.
- انظر للمخطط التكراري ومخططات P-P. إذا بدا المخطط التكراري كتوزيع طبيعي (وبدا مخطط P-P كخط قطري) فإن ذلك جيد. أما إذا كان المخطط التكراري غير طبيعي

وكان المخطط P-P كمنحني متلوي حول الخط القطري فإن هناك أشياء ليست جيدة. وتذكر قد تبدو التوزيعات غير طبيعية في العينات الصغيرة لحد أكبر مما هي عليه في الواقع.

9.5 كيفية تقديم التراجع المتعدد

إذا اتبعنا توجيهات جمعية أطباء النفس الأمريكية لتقديم التراجع المتعدد فإن النتائج الجدولية هي الطريقة المثلى. وهي تفضل تقديم المعلومات التالية كحد أدنى: قيم بيتا المعيارية، ومستوى دلالتها وبعض الإحصائيات العامة حول النموذج (مثل R^2). إذا قررت إنشاء جدول فإن قيم بيتا وأخطائها المعيارية هي مفيدة جداً، وكذلك تضمين الحد الثابت بحيث يمكن للقراء إعادة كتابة نموذج التراجع بشكل كامل إذا أرادوا ذلك. إذا قمت بتراجع هرمي فيجب عليك تقديم هذه القيم عند كل مرحلة من مراحل التسلسل الهرمي. لذلك ينبغي عليك بشكل أساسي إنتاج الجدول المسمى Coefficients في خرج SPSS وإزالة بعض المعلومات غير الضرورية منه. ومن أجل المثال الذي درسناه في هذا الفصل فإنه يمكننا إنتاج الجدول المبين في (الجدول 2.5).

	B	SE B	β
الخطوة الأولى			
الحد الثابت	134.14	7.54	
ميزانية الاعلانات	0.10	0.01	0.58*
الخطوة الثانية			
الحد الثابت	-26.61	17.35	
ميزانية الاعلانات	0.09	0.01	0.51*
عدد مرات البث الإذاعي	3.37	0.28	0.51*
جاذبية الفرقة	11.09	2.44	0.19*

الجدول 2.5 كيفية تقديم التراجع المتعدد لاحظ أن R^2=.34 للخطوة الأولى، ΔR^2=.33 للخطوة الثانية (ps<.001). *p<.001

انظر فيما إذا كنت قادراً على معرفة مصدر هذه القيم من الخرج الذي يعطيه برنامج SPSS. هناك أمور يجب ملاحظتها: (1) قمنا بتدوير الأرقام لمنزلتين عشريتين. (2) تم وضع إشارة (*) للإشارة إلى دلالة المتحول مع وضع حاشية سفلية تبين مستوى الدلالة المستخدم (إذا استخدمت عدة مستويات للدلالة فيمكنك استخدام الإشارات (**) و(***) وغيرها بحيث يكون: *p<0.05 و**p<0.01 و***p<0.001. (3) تم وضع قيمة R^2 للنموذج الأولي والتغير في R^2 (المسمى ΔR^2) لكل الخطوات التالية في النموذج تحت الجدول.

10.5 المتحولات التنبؤية الفئوية والتراجع المتعدد

في تحليل التراجع غالباً ما تقوم بجمع البيانات حول مجموعات من الناس (وكأمثلة من العلوم الاجتماعية يمكن أن نذكر المجموعات العرقية، الجنس، المستوى الاجتماعي الاقتصادي، فئة تشخيص). قد ترغب بتضمين هذه المجموعات كمتحولات تنبؤية في نموذج التراجع، وقد رأيت من الفرضيات أن المتحولات يجب أن تكون مستمرة أو فئوية (مع فئتين فقط). ورأينا في الفقرة 6.5.4 أن الارتباط ثنائي التسلسل النقطي هو ارتباط Pearson (r) بين متحولين عندما يكون أحدهما مستمراً والآخر ثنائي الفئة مع الرمزين 0 و1. وقد تعلمنا أيضاً أن التراجع البسيط يعتمد على معامل Pearson (r)، ولن يكون إنشاء نموذج التراجع بمتحول تنبؤي ذي فئتين (الجنس مثلاً) أمراً صعباً. ولن يكون صعباً أيضاً توسيع هذا النموذج ليتضمن عدة متحولات تنبؤية أخرى لكل منها فئتين أيضاً. ولكن من المهم جداً ترميز الفئتين بالرمزين 0 و1. لماذا يكون وجود فئتين فقط ويحملان الترميز 0 و1 أمراً مهماً جداً؟ سنوضح ذلك في الفقرات 8.7 و2.8.2 وذلك لأن هذا الفصل أصبح طويلاً جداً.

1.10.5 الترميز المزيف

المشكلة البديهية عند استخدام المتحولات الفئوية كمتحولات تنبؤية هي أنها غالباً ما تكون بأكثر من فئتين. فعلى سبيل المثال إذا أردت معرفة الديانة في بريطانيا فيمكن أن تجد الفئات: الإسلام، اليهودية، الهندوسية، الكاثوليكية، البوذية، البروتستانت. ومن الواضح أنه لا يمكن التمييز بين هذه الفئات باستخدام متحول ترميز وحيد يأخذ القيم 0 و1 فقط. في هذه الحالات علينا استخدام ما يسمى المتحولات المزيفة (Dummy variables). والترميز المزيف هو طريقة لتمثيل المجموعات من الناس باستخدام الرمزين 0 و1 فقط. ولتنفيذ ذلك، نقوم بإنشاء عدة متحولات يكون عددها أقل من عدد المجموعات التي نريد ترميزها بمقدار 1. ونقدم فيما يلي الخطوات الأساسية لهذه العملية:

1. حساب عدد المجموعات التي تريد ترميزها ثم اطرح العدد 1 من هذا العدد.
2. أنشئ عدداً من المتحولات الجديدة يساوي العدد الناتج في الخطوة الأولى. وهذه هي المتحولات المزيفة.
3. اختر إحدى المجموعات كمجموعة أساس (مجموعة يمكن مقارنة جميع المجموعات الأخرى معها). يجب أن تكون هذه كمجموعة تحكم، أما إذا لم تكن لديك فرضية محددة فيجب أن تختار المجموعة التي تمثل غالبية الناس (لأنه قد يكون من المفيد مقارنة المجموعات الأخرى مع الغالبية).
4. بعد اختيار مجموعة الأساس، تعطي قيمة المجموعة القيمة 0 لجميع المتحولات المزيفة في هذه المجموعة.

5. بالنسبة للمتحول المزيف الأول، عيّن القيمة 1 للمجموعة الأولى التي تريد مقارنتها مع مجموعة الأساس. وعيّن القيمة 0 لبقية المجموعات الأخرى من أجل هذا المتحول.
6. بالنسبة للمتحول المزيف الثاني، عيّن القيمة 1 للمجموعة الثانية التي تريد مقارنتها مع مجموعة الأساس. وعيّن القيمة 0 لبقية المجموعات الأخرى من أجل هذا المتحول.
7. كرر ذلك حتى الانتهاء من المتحولات المزيفة.
8. ضع جميع المتحولات المزيفة في تحليل التراجع.

لنجرب هذه العملية على مثال. تعاملنا في الفصل 3 مع مثال تتم فيه دراسة الآثار الصحية المحتملة للحفلات الموسيقية. وقد ذهب الباحث فيه إلى مهرجان Glastonbury الموسيقي وقاس معدلات النظافة لجمهور المهرجان خلال الأيام الثلاثة باستخدام تقنية سمحت بالحصول على علامات النظافة كقيم محصورة بين 0 (وسخ جداً) و5 (نظيف جداً). وقد نظرنا في الفصل 3 على توزيع العلامات خلال أيام المهرجان، ولكن تخيل لو أراد الباحث النظر إلى المتحولات التنبؤية لما ستؤول إليه النظافة خلال المهرجان. يدعى ملف البيانات GlastonburyFestivalRegression.sav ويمكنك العثور عليه في القرص المضغوط المرافق. يحوي الملف علامات النظافة في كل من الأيام الثلاثة للمهرجان ولكنه يحوي أيضاً متحولاً يدعى Change وهو مقدار تغير النظافة خلال الأيام الثلاثة للمهرجان (أي أنه التغير من اليوم الأول حتى الثالث). أخيراً قام الباحث بتقسيم الناس إلى فئات حسب ميولهم الموسيقية فكانت هناك 4 فئات: indie kid لمن يحب الموسيقى البديلة، وmetaller لهواة الموسيقى المعدنية، وcrusty لهواة الموسيقى الشعبية، وno musical affiliation لمن لا يمكن تصنيفه في الفئات الثلاث السابقة. وقد تم ترميز هذه الفئات في ملف البيانات بالرموز 1 و2 و3 و4 على التوالي.

سنقوم أولاً بحساب عدد المتحولات المزيفة. لدينا 4 مجموعات ولذلك سيكون لدينا 3 متحولات مزيفة (3=1-4).

نختار بعد ذلك مجموعة الأساس. نهتم بمقارنة أصحاب الميول الموسيقية مع أولئك الذين ليس لديهم تفضيل معين من الموسيقى. لذلك نعطي هذه المجموعة القيمة 0 لجميع المتحولات المزيفة. من أجل المتحول المزيف الأول فإننا نختار المجموعة crusty ولهذا نعطي القيمة 1 لأي شخص من المجموعة crusty، والقيمة 0 لبقية الأشخاص. وبالنسبة للمتحول المزيف الثاني فإننا نختار المجموعة metaller، ولهذا نعطي القيمة 1 لأي شخص من المجموعة metaller، والقيمة 0 لبقية الأشخاص. وبالنسبة للمتحول المزيف الأخير فإننا نأخذ المجموعة المتبقية indie kid، ولذلك نعطي القيمة 1 لأي شخص من المجموعة indie kid، والقيمة 0 لبقية الأشخاص. يبين الجدول 5-3 مخطط الترميز الناتج. يجب أن نلاحظ أن كل مجموعة تملك الرمز 1 من أجل متحول مزيف واحد فقط (عدا مجموعة الأساس التي تأخذ الرمز 0 بشكل دائم).

	المتحول المزيف الأول	المتحول المزيف الثاني	المتحول المزيف الثالث
No Affiliation	0	0	0
Indie Kid	0	0	1
Metaller	0	1	0
Crusty	1	0	0

الجدول 3.5 الترميز المزيف لبيانات مهرجان Glastonbury

وكما قلنا في بداية الفقرة فإننا سننظر إلى آلية عمل الترميز المزيف في الفقرات 8.7 و2.2.8 ولكن سنكتفي حالياً بكيفية إعادة ترميز متحول التجميع للمتحولات المزيفة باستخدام برنامج SPSS. لإعادة ترميز المتحولات فإننا نستخدم الوظيفة Recode. استخدم أمر القائمة Transform ⇒ Recode ⇒ Into Different Variables للوصول إلى مربع الحوار المبين في (الشكل 20.5). يعرض مربع الحوار الأول جميع المتحولات في محرر البيانات، ويجب أن تختار المتحول الذي تريد إعادة ترميز (وفي هذه الحالة هو المتحول music) وتنقله إلى الحيز المسمى Numeric Variable → Output Variable بنقر زر السهم الموجود بين القسمين. عليك بعد ذلك تسمية المتحول الجديد (متحول الخرج كما يسميه برنامج SPSS) لذلك ننتقل إلى القسم المسمى Output Variable ونكتب في الحيز المسمى Name اسم المتحول المزيف الأول (وليكن music 1). ويمكنك أن تعطي تسمية وصفية أكثر دلالة لهذا المتحول بكتابة وصف معين في الحيز المسمى Label. عند الانتهاء من ذلك انقر الزر Change لنقل هذا المتحول الجديد إلى الحيز المسمى Numeric Variable → Output Variable (يجب أن يحوي هذا الحيز ما يلي music → music 1). بعد الانتهاء من تعريف المتحول المزيف الأول علينا أن نخبر برنامج SPSS بكيفية إعادة ترميز قيم المتحول music إلى القيم التي تريدها للمتحول الجديد music 1. ولتنفيذ ذلك انقر الزر Old and New Values... حيث يظهر مربع الحوار الثاني المبين في (الشكل 20.5). يستخدم مربع الحوار لتغيير قيم المتحول الأصلي إلى القيم المختلفة للمتحول الجديد. بالنسبة للمتحول المزيف الأول فإننا نريد أن يأخذ أي شخص من المجموعة crusty الرمز 1 أما بقية الأشخاص فيأخذوا الرمز 0. لقد كانت المجموعة crusty تأخذ القيمة 3 في المتحول الأصلي، لذلك يجب عليك كتابة الرقم 3 في الحيز المسمى Value في القسم Old Value. القيمة الجديدة هي 1، لذلك عليك كتابة الرقم 1 في الحيز المسمى Value في القسم New value. عند الانتهاء من ذلك انقر الزر Add لإضافة هذا التغيير إلى لائحة التغيرات التي تظهر في الحيز المسمى Old → New (يظهر الآن التغيير بالشكل 1 → 3). وما نريد تنفيذه الآن هو تغيير المجموعات المتبقية لتأخذ القيمة 0 من أجل المتحول المزيف الأول. لتنفيذ ذلك انقر الخيار All other Value واكتب القيمة 0 في الحيز المسمى New في القسم New Value. عند الانتهاء من ذلك انقر الزر Add لإضافة هذا التغيير إلى لائحة التغيرات (يظهر هذا التغيير بالشكل ELSE → 0). عند الانتهاء من ذلك انقر الزر Continue للعودة إلى مربع الحوار الأول

(الرئيسي) ثم انقر الزر OK لإنشاء المتحول المزيف الأول. يظهر المتحول الجديد في عمود جديد في محرر البيانات، ويجب أن تلاحظ أنه يملك القيم 1 لأي شخص كان مصنفاً في المجموعة crusty في الأصل، والقيمة 0 لبقية الأشخاص. حاول الآن إنشاء بقية المتحولات المزيفة (music2 و music3) باستخدام المبادئ ذاتها.

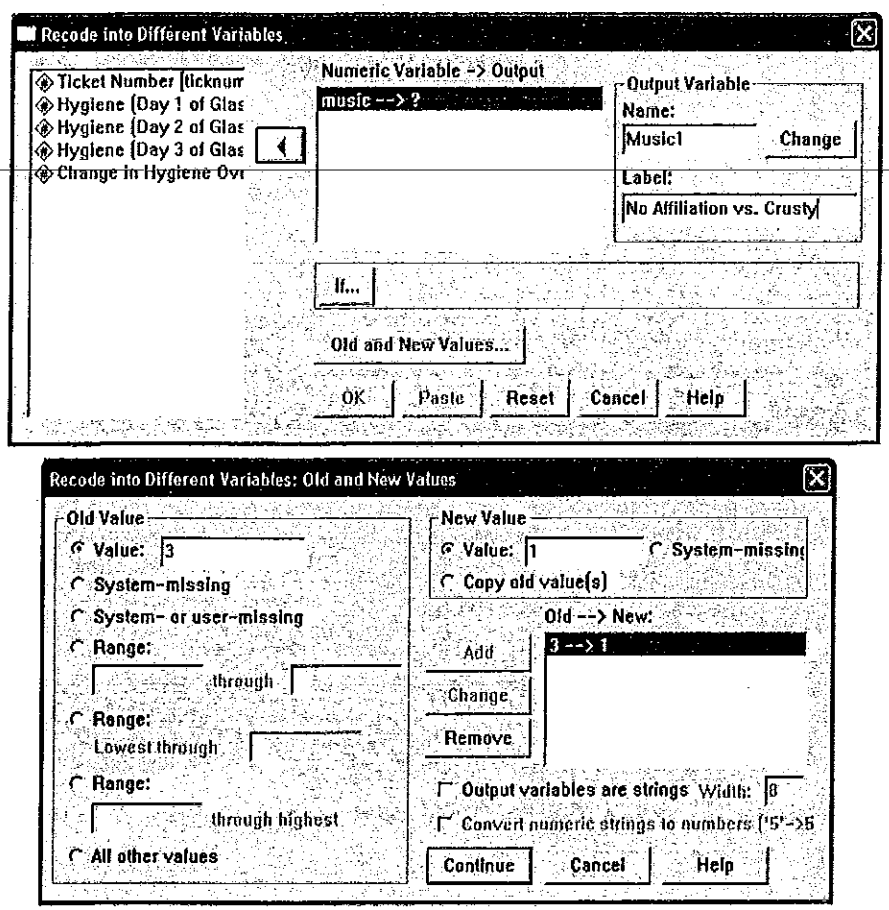

الشكل 20.5 مربعات الحوار للوظيفة Recode

المربع 3.5 استخدام القواعد لإعادة الترميز

إذا كنت تقوم بمجموعة من عمليات إعادة الترميز فقد يصبح استخدام مربعات الحوار مملاً. يحوي القرص المضغوط المرفق ملف قواعد يدعى Recode Glastonbury Data.sps تمت كتابته لإنشاء جميع المتحولات المزيفة التي تمت مناقشتها. افتح هذا الملف وشغل القواعد، أو افتح نافذة القواعد واكتب فيها ما يلي:

```
RECODE music (3=1) (ELSE=0) INTO Music1.
RECODE music (2=1) (ELSE=0) INTO Music2.
```

```
RECODE music (1=1) (ELSE=0) INTO Music3.
VARIABLE LABELS Music1 'No Affiliation vs. Crusty'.
VARIABLE LABELS Music2 'No Affiliation vs. Metaller'.
VARIABLE LABELS Music3 'No Affiliation vs. Indie Kid'.
EXECUTE.
```

تقوم كل تعليمة RECODE بما يكافئ ما تفعله باستخدام مربع الحوار في الشكل 20.5. لذلك فإن الأسطر الثلاث الأولى تطلب من برنامج SPSS إنشاء المتحولات الجديدة Music1 وMusic2 وMusic3 التي تعتمد على المتحول الأصلي music. و من أجل المتحول الأول، إذا كانت قيمة المتحول music تساوي 3 فإنها تصبح 1 أما بقية القيم فتصبح 0. ومن اجل المتحول الثاني إذا كانت قيمة المتحول music تساوي 2 فإنها تصبح 1 أما بقية القيم فتصبح 0. وكذلك الأمر بالنسبة للمتحول الثالث. أما الأسطر التي تبدأ بعبارة VARIABLE LABELS فهي تطلب من برنامج SPSS تعيين النص الموجود بين علامتي اقتباس كتسمية للمتحول الموجود بعدها. أما السطر الأخير فيحوي العبارة التي لا يمكن تنفيذ التعليمات السابقة بدونها EXECUTE. لاحظ أن كل سطر ينتهي نقطة.

2.10.5 خرج البرنامج SPSS للمتحولات المزيفة

لنفترض أنك قمت بإنشاء متحولات الترميز المزيفة (أو يمكنك استخدام ملف البيانات GlastorburyDummy.sav) في حالة المتحولات المزيفة عليك إدخال جميع المتحولات المزيفة المرتبطة في نفس الكتلة (استخدم الطريقة Enter). في هذه الحالة عليك إدخال المتحولات المزيفة في نفس الكتلة، وإذا كان لديك متحول آخر (كالحالة الاجتماعية الاقتصادية) وقد تم تحويله إلى متحولات مزيفة فإنه يمكنك إدخال هذه المتحولات المزيفة في كتلة مختلفة (يجب إدخال المتحولات المزيفة التي أعادت ترميز نفس المتحول ضمن نفس الكتلة). استخدم ما تعلمته في هذا الفصل لتنفيذ التراجع المتعدد باستخدام علامات التغيير مثل النتيجة، والمتحولات المزيفة التي تم إدخالها في نفس الكتلة كمتحولات تنبؤية. لنلقي نظرة على الخرج. يعرض (الخرج 12.5) إحصائيات النموذج. ويبين ذلك أن إدخال المتحولات المزيفة قد سمح بتفسير 7.6% من التباين في تغير علامات النظافة (قيمة R^2 *100). وبكلمة أخرى، يمكن تفسير 7.6% من التباين في تغير النظافة بالاهتمام الموسيقي للشخص أما تحليل التباين ANOVA (الذي يبين نفس النتيجة كإحصائية تغير R^2 لأن هناك خطوة واحدة في هذا التراجع) فيخبرنا أن النموذج أصبح أفضل في توقع التغير في علامات النظافة من حالة عدم وجود نموذج (أو بطريقة أخرى فإن 7.6% من التباين الذي يمكن تفسيره هو مقدار هام). ومعظم ذلك يجب أن يكون واضحاً مما قرأته في هذا الفصل، أما المتعة الأكبر فتأتي من تفسير المتحولات المزيفة المنفصلة.

Model Summary[b]

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Change Statistics					Durbin-Watson
					R Square Change	F Change	df1	df2	Sig. F Change	
1	.276[a]	.076	.053	.68818	.076	3.270	3	119	.024	1.893

a. Predictors: (Constant), No Affiliation vs. Indie Kid, No Affiliation vs. Crusty, No Affiliation vs. Metaller

b. Dependent Variable: Change In Hygiene Over The Festival

ANOVA[b]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	4.646	3	1.549	3.270	.024[a]
	Residual	56.358	119	.474		
	Total	61.004	122			

a. Predictors: (Constant), No Affiliation vs. Indie Kid, No Affiliation vs. Crusty, No Affiliation vs. Metaller

b. Dependent Variable: Change In Hygiene Over The Festival

الخرج 12.5

يعرض (الخرج 13.5) جدول المعاملات الأساسية للمتحولات المزيفة (ولقد استثنينا مجالات الثقة وإحصائيات الارتباط الخطي). إن أول ما يجب ملاحظته أن كل متحول مزيف يظهر في الجدول مع التسمية المناسبة (مثل Crusty vs. No Affiliation). وحدث ذلك لأنه عند إعادة ترميز المتحولات فإننا أعطينا هذه المتحولات التسميات المناسبة، ولو لم نقم بذلك لاحتوى الجدول تسميات أقل وضوحاً (مثل music1، music2، music3). يبين المتحول المزيف الأول الفرق بين التغير في علامة النظافة للمجموعة التي لا تملك اهتماماً موسيقياً معيناً والمجموعة crusty. تذكر أن قيم بيتا تخبرنا عن التغير في النتيجة العائد لتغير بمقدار وحدة واحدة في المتحول التنبؤي. في هذه الحالة فإن تغيراً بمقدار وحدة واحدة في المتحول التنبؤي هو التغير من القيمة 0 إلى 1. وهكذا يظهر أن الانزياح في التغير في علامات النظافة ينتج عن تغير المتحول المزيف من 0 إلى 1 (crusty). وبتضمين المتحولات المزيفة الثلاثة بنفس الوقت فإن فئة الأساس هي دائماً 0 ولذلك فإن هذا يمثل فعلياً الانزياح في التغير في علامات النظافة إذا كان الشخص دون اهتمام موسيقي معين مقارنة بشخص آخر من المجموعة crusty. وهذا الانزياح هو فعلياً الفرق بين متوسطي المجموعتين. لتوضيح ذلك فقد قدمنا جدولاً لقيم المتوسط للمجموعة لكل من المجموعات الأربع. يمثل المتوسط التغير الوسطي في علامات النظافة للمجموعات الثلاث. إذاً حسبنا الفرق في هذه القيم للمتوسط بين المجموعة بدون الاهتمام الموسيقي مع المجموعة crusty فإننا نحصل على: (0.5543)=-0.410 - (-0.9643). و بكلمات أخرى فإن التغير في علامات النظافة هو أكبر في المجموعة crusty من التغير في المجموعة No Affiliation (تنخفض علامات النظافة لمجموعة crusty خلال أيام المهرجان أكثر من انخفاض علامات النظافة للمجموعة No Affiliation). وهذه القيمة هي نفس قيمة بيتا في الخرج 13.5. لذلك فإن قيم بيتا تخبرنا بالفرق النسبي بين كل مجموعة و المجموعة

التي تم اختيارها كأساس. يتم تحويل قيم بيتا إلى إحصائية t والدلالة التي تعطيها إحصائية t. وتقوم الإحصائية t باختبار فيما إذا كانت قيمة بيتا هي 0 عندما نملك فئتين مع الترميز 0 و1، وهذا يعني أنه يختبر فيما إذا كان الفرق بين المجموعات يساوي 0. إذا كان ذا دلالة فهذا يعني أن المجموعة ذات الرمز 1 هي مختلفة بشكل كبير عن مجموعة الأساس، ولذلك فإنه يختبر الفرق بين المتوسطين، وهو الإطار الذي ستتعود عليه مع الإحصائية t (انظر الفصل 7). ومن أجل المتحول المزيف الأول فإن إحصائية t ذات دلالة، وقيمة بيتا سالبة لذلك يمكننا أن نقول أن التغير في علامات النظافة ينخفض عند تغير الشخص من الفئة No Affiliation إلى الفئة crusty. تذكر أن أي انخفاض في علامات النظافة يمثل تغيراً أكبر، لذلك فإن ما يعنيه ذلك فعلياً هو انخفاض النظافة بشكل كبير في المجموعة crusty مقارنة بأعضاء المجموعة No Affiliation.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients		
		B	Std. Error	Beta	t	Sig.
1	(Constant)	-.554	.090		-6.134	.000
	No Affiliation vs. Crusty	-.412	.167	-.232	-2.464	.015
	No Affiliation vs. Metaller	2.838E-02	.160	.017	.177	.860
	No Affiliation vs. Indie Kid	-.410	.205	-.185	-2.001	.048

a. Dependent Variable: Change in Hygiene Over The Festival

الخرج 13.5

لننتقل إلى المتحول المزيف الثاني الذي يقارن أعضاء المجموعة metaller مع أعضاء المجموعة No Affiliation. تمثل قيمة بيتا الانزياح في التغير في علامات النظافة إذا لم يكن للشخص اهتمام موسيقي معين مقارنة مع شخص آخر من المجموعة metaller. إذا حسبنا الفرق بين متوسطي المجموعتين فإننا نحصل على: 0.028= (-0.5543) - (-0.5259) = metaller - no affiliation. وهذه القيمة هي نفس قيمة بيتا في الخرج 13.5. ومن أجل المتحول المزيف الثاني فإن الإحصائية t ليست ذات دلالة، لذلك يمكننا أن نقول أن التغير في علامات النظافة هو نفسه إذا تغير الشخص من الفئة No Affiliation ليصبح metaller. وبكلمة أخرى، إن التغير في علامات النظافة لا يمكن التنبؤ به فيما إذا كان الشخص metaller مقارنة مع لو أنه من الفئة No Affiliation.

من أجل المتحول المزيف الأخير، قمنا بمقارنة أعضاء المجموعة indie kid مع أعضاء المجموعة No Affiliation. تمثل قيمة بيتا الانزياح في التغير في علامات النظافة إذا لم يكن للشخص اهتمام موسيقي معين مقارنة مع شخص آخر من المجموعة indie kid. إذا حسبنا الفرق بين متوسطي المجموعتين فإننا نحصل على: -0.410 = (-0.9643) - (-0.5543) = indie kid-no affiliation. وليست هناك مفاجأة في أن هذه القيمة تساوي قيمة بيتا في الخرج 13.5. إن الإحصائية t ذات دلالة، وقيمة بيتا سالبة لذلك يمكننا أن نقول (كما في حالة المتحول المزيف الأول) أن التغير في

علامات النظافة ينخفض عند تغير الشخص من الفئة No Affiliation إلى الفئة indie kid. تذكر أن أي انخفاض في علامات النظافة يمثل تغيراً أكبر لذلك فإن ما يعنيه فعلياً هو انخفاض النظافة بشكل كبير في المجموعة indie kid مقارنة بأعضاء المجموعة No Affiliation.

لذلك وبشكلٍ إجمالي، يبين هذا التحليل أن الأشخاص من المجموعة crusty وindie kid تزداد رائحتهم سوءاً بمرور أيام المهرجان مقارنة مع الأشخاص من المجموعة No Affiliation، بينما لا تتأثر رائحة الأشخاص من المجموعة metaller. لقد قدمت هذه الفقرة بعض الأفكار المعقدة التي سيتم توضيحها بالتفصيل في الفصلين 7 و8 (وخاصة الفقرتين 7-8 و8-2-2).

11.5 ما الذي اكتشفناه عن الإحصاء؟

لقد قدمنا الكثير من المعلومات حول التراجع في هذا الفصل، وهو ما يعتبر الأساس لعلم الإحصاء تقريباً. وما ستجده في بقية الفصول هو تغيير فقط لمواضيع هذا الفصل.

لقد بدأنا الفصل بإلقاء نظرة على الحالة التي يوجد فيها متحول تنبؤي وحيد ونتيجة واحدة. وقد سمح لنا ذلك بالنظر إلى بعض المبادئ الأساسية مثل معادلة الخط المستقيم، وطريقة المربعات الصغرى، وكيفية تقييم جودة ملاءمة النموذج للبيانات باستخدام بعض المقادير الهامة التي سنمر عليها بتفصيل أكبر في الفصول القادمة: مثل مجموع المربعات للنموذج SS_M، ومجموع المربعات للباقي SS_R، والمجموع الكلي للمربعات SS_T. وقد استخدمنا هذه القيم لحساب عدة إحصائيات هامة مثل R^2 والنسبة F. كما تعلمنا كيفية تنفيذ التراجع في برنامج SPSS وكيفية الاستفادة من قيم بيتا الناتجة وإدخالها في معادلة الخط المستقيم للقيام بتوقعات حول النتيجة.

بعد ذلك، عالجنا مسألة توسيع الخط المستقيم ليتضمن متحولات تنبؤية أخرى ونظرنا إلى الطرق المختلفة لوضع المتحولات التنبؤية في النموذج (هرمي، إدخال قسري، خطوي). كما بحثنا في العوامل التي يمكن أن تؤثر على دقة المنوال (النقاط المنعزلة والحالات المؤثرة) والطرق لتحديد هذه العوامل. انتقلنا بعد ذلك للنظر في الفرضيات الضرورية لتعميم النموذج خارج إطار عينة البيانات التي قمنا بجمعها وذلك قبل أن نكتشف كيفية تنفيذ التحليل في برنامج SPSS وكيفية تفسير الخرج، وإنشاء نموذج التراجع المتعدد واختبار وثوقية وقابلية تعميمه. وقد أنهينا الفصل بالنظر إلى كيفية استخدام المتحولات التنبؤية الفئوية في التراجع (وأثناء ذلك اكتشفنا المزيد عن الوظيفة Recode). وبشكل عام فإن التراجع المتعدد هو عملية طويلة يجب تنفيذها بحرص مع الانتباه للتفاصيل. هناك عدد من النقاط المهمة التي يجب أخذها بعين الاعتبار وأن تتم عملية التحليل بطريقة منهجية. نأمل أن يكون هذا الفصل مساعداً لك للقيام بتلك الأمور. هناك أمر لم ننظر فيه وهو إمكانية استخدام متحولات فئوية للنتيجة (بدلاً من المتحول التنبؤي) وسيبحث الفصل التالي في نوع خاص من التراجع يمكنك فيه استخدام هذا النوع من المتحولات.

12.5 المصطلحات الأساسية التي اكتشفناها

القيمة المتوقعة المعدّلة	(Adjusted predicted value)
قيمة R^2 المعدّلة	(Adjusted R^2)
الارتباط الذاتي	(Autocorrelation)
قيم b_i	(b_i)
قيم بيتا	(β_i)
مسافة Cook	(Cook's distance)
نسبة التباين المشترك	(Covariance ration (CVR))
التحقق المتصالب	(Cross-validation)
الباقي المحذوف	(Deleted residual)
إحصائية DFBeta	(DFBeta)
إحصائية DFFit	(DFFit)
المتحولات المزيفة	(Dummy variables)
اختبار Durbin-Watson	(Durbin-Watson test)
نسبة F	(F-ratio)
التعميم	(Generalization)
جودة التوافق	(Goodness-of-fit)
قيم القبعة	(Hat values)
تجانس التباين	(Homoscedasticity)
عدم تجانس التباين	(Heteroscedasticity)
الأخطاء المستقلة	(Independent errors)
الفعالية	(Leverage)
مسافات Mahalanobis	(Mahalanobis distances)
المربعات المتوسطة	(Mean squares)
مجموع المربعات للنموذج	(Model sum of squares)
مضاعف R	(Multiple R)

التراجع المتعدد	(Multiple regression)
الارتباط الخطي المتعدد	(Multicolliearity)
متحول النتيجة	(Outcome variable)
الارتباط الخطي المثالي	(Perfect collinearity)
المتحول التنبؤي	(Predictor variable)
الباقي	(Residual)
مجموع المربعات للباقي	(Residual sum of squares)
التقلص	(Shrinkage)
التراجع البسيط	(Simple regression)
إحصائية DFBeta المعيارية	(Standardized DFBeta)
إحصائية DFFit المعيارية	(Standardized DFFit)
البواقي المعيارية	(Standardized residuals)
التراجع الخطوي	(Stepwise regression)
البواقي المحذوفة Studentized	(Studentized deletes residuals)
البواقي Studentized	(Studentized residuals)
الآثار المخمدة	(Suppressor effects)
الإحصائية t	(t-statistics)
التسامح	(Tolerance)
المجموع الكلي للمربعات	(Total sum of squares)
البواقي غير المعيارية	(Unstandardized residuals)
عامل تضخم التباين	(variance inflation factor (VIF))

13.5 مهمات يجب إنجازها

يحوي الملف Answers(chapter5).pdf الإجابات على هذه المهمات.

- تهتم طالبة موضة بدراسة العوامل التي تتوقع براتب عارضات الأزياء. ولذلك قامت بجمع البيانات من 231 عارضة أزياء. وقد طرحت أسئلتها على عارضات الأزياء حول الراتب اليومي في أيام العمل (Salary) والعمر (age) وعدد السنوات التي قضتها في العمل كعارضة

أزياء (years)، ثم انتقلت لخبراء وكالات عرض الأزياء لتقييم جاذبية كل عارضة أزياء كنسبة مئوية حيث تمثل القيمة 100% الجاذبية الكاملة (beauty). يحوي الملف Supermodel.sav تلك البيانات. ولكن طالبة الموضة اشترت بعض كتب الإحصاء العادية ولذلك فهي لا تعرف كيف تقوم بتحليل البيانات التي جمعتها. هل يمكنك مساعدة تلك الطالبة للقيام بعملية التراجع المتعدد لمعرفة العامل الذي يتوقع راتب عارضة الأزياء؟ وكيف تتأكد من صحة نموذج التراجع؟.

- باستخدام بيانات مهرجان الموسيقى Glastonbury الموجودة في هذا الفصل (مع المتحولات المزيفة في الملف GlastonburyDummy.sav) والتي قمت بتحليلها سابقاً، اكتب تعليقاً عما تعتقده بوثوقية النموذج وإمكانية تعميمه.

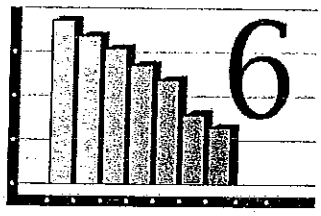

التراجع المنطقي

1.6 بماذا يخبرنا هذا الفصل

بحثنا في الفصل السابق كيفية إنشاء نموذج للعلاقة بين متحول تنبؤي أو أكثر مع متحول النتيجة. يوسّع هذا الفصل تلك الأفكار ليبحث في كيفية التنبؤ بمتحولات النتيجة التي تكون فئوية وذلك باستخدام التراجع المنطقي (logistic regression). إنه فصل صعب، ولذلك سنبدأ بلمحة نظرية لمساعدتك في فهم ما يتعامل معه التراجع المنطقي قبل أن ننتقل إلى المثال. ستتعلم كيفية تنفيذ التراجع المنطقي في برنامج SPSS وكيفية تفسير الخرج الناتج. وسننهي الفصل بمثال آخر، حيث نستخدم هذا المثال كطريقة لمعرفة كيف نواجه الارتباط الخطي المتعدد. وخلال هذه العملية ستعرف لماذا لا يسجل الفريق الانكليزي لكرة القدم ضربات الجزاء.

2.6 لمحة نظرية عن التراجع المنطقي

بكلمات قليلة، التراجع المنطقي هو تراجع متعدد يكون فيه متحول النتيجة فئوياً ثنائياً والمتحولات التنبؤية مستمرة أو فئوية. وبلغة بسيطة فإن هذا يعني أنه بإعطائنا بعض المعلومات يمكننا التنبؤ بانتماء شخص ما إلى أيّ من الفئتين. وكمثال بسيط يمكن أن نبحث لمعرفة المتحولات التي تتوقع جنس شخص ما (هل هو ذكر أم أنثى). قد نقيس مستوى الكسل والغرور واستهلاك الكحول وعدد مرات التحشؤ في اليوم. وباستخدام التراجع المنطقي فقد نجد أن جميع هذه المتحولات تتنبأ بجنس الشخص، ولكن هذه التقنية ستسمح لنا أيضاً بتوقّع فيما إذا كان شخص معين هو ذكر أم أنثى. ولذلك إذا أخذنا بشكل عشوائي شخصاً ما واكتشفنا أن علاماته مرتفعة في كل من الكسل والغرور واستهلاك الكحول وعدد مرات التحشؤ في اليوم فإن نموذج التراجع المنطقي قد يخبرنا، بناءً على هذه المعلومات، أنه من المرجح أن يكون ذلك الشخص ذكراً.

وللتراجع المنطقي تطبيقات هامة في الأبحاث الطبية كصياغة النماذج حول أنواع العوامل التي قد تحدد فيما إذا كان الورم سرطانياً أو غير خبيث. يمكن استخدام قاعدة البيانات للمرضى لمعرفة المتحولات المؤثرة على التنبؤ بالنمو السرطاني للورم. يمكن بعد ذلك قياس هذه المتحولات لمريض جديد ووضع هذه القيم في نموذج التراجع المنطقي، بحيث يمكن تقدير احتمال النمو السرطاني

للورم. إذا كانت قيمة الاحتمال لنمو الورم منخفضة بشكل مناسب فإن الطبيب قد يقرر عدم تنفيذ عملية جراحية مكلفة ومؤلمة في ضوء احتمال أنها غير ضرورية.

أما في العلوم الاجتماعية فإننا نادراً ما نصادف مثل هذه القرارات المهددة للحياة، ومع ذلك يبقى التراجع المنطقي أداة مفيدة جداً. ومن المؤسف أن تهمل العديد من الكتب التراجع المنطقي. نأمل في هذا الفصل أن نعيد التوازن وذلك بشرح مبادئ التراجع المنطقي وكيفية تنفيذ إجرائياته في برنامج SPSS.

3.6 ما هي مبادئ التراجع المنطقي؟

لن نسهب في شرح المبادئ العميقة للتراجع المنطقي لأنها ليست ضرورية لفهم الاختبار. ولكننا سنعتمد مفاهيم التوازي مع التراجع العادي في محاولة لصياغة التراجع المنطقي ضمن إطار عمل معروف لكل من عمل بالتراجع (ماذا تعني بأنك لم تقرأ الفصل 5 الخاص بالتراجع؟!). لقد رأينا في التراجع الخطي أنه يمكن التنبؤ بمتحول النتيجة Y من معادلة الخط المستقيم:

$$Y_i = b_0 + b_1X_1 + \varepsilon_i \qquad (1.6)$$

حيث يمثل b_0 اعتراض Y (المسافة المحصورة بين مبدأ جملة الإحداثيات ونقطة تقاطع الخط المستقيم مع المحور الشاقولي)، و b_1 ميل الخط المستقيم، وX_1 قيمة المتحول التنبؤي، وε الحد الباقي. إذا كانت قيم Y و X_1 معطاة فيمكننا تقدير البارامترات المجهولة في المعادلة بإيجاد حل يكون فيه مربع المسافة بين القيمة المشاهدة والقيمة المتوقعة للمتحول التابع أصغرياً (طريقة المربعات الصغرى).

وفي التراجع المتعدد، حيث توجد عدة متحولات تنبؤية، يمكن اشتقاق معادلة مشابهة يكون فيها لكل متحول تنبؤي معامله الخاص. وهكذا يمكن التنبؤ بمتحول النتيجة Y من تركيب لجداء كل متحول تنبؤي بمعامل التراجع الخاص به:

$$Y_i = b_0 + b_1X_1 + b_2X_2 + \cdots + b_nX_n + \varepsilon_i \qquad (2.6)$$

حيث يمثل b_n معامل التراجع للمتحول التنبؤي الموافق X_n. أما في التراجع المنطقي، فبدلاً من التنبؤ بقيمة المتحول Y من المتحول التنبؤي X_1 أو من عدة متحولات تنبؤية (Xs)، فإننا نتوقع احتمال حدوث Y بمعرفة قيمة X_1 (أو قيم Xs). وتحمل معادلة التراجع المنطقي عدداً من نقاط التشابه مع المعادلات التي تم عرضها سابقاً. وفي حالة متحول تنبؤي واحد X_1 فإن أبسط شكل لمعادلة التراجع المنطقي التي يمكن التنبؤ باحتمال حدوث Y فيها هو:

$$P(Y) = \frac{1}{1 + e^{-(b_0 + b_1X_1 + \varepsilon_i)}} \qquad (3.6)$$

يمثل P(Y) احتمال حدوث Y، و e أساس اللوغاريتم الطبيعي، والمعاملات الأخرى مماثلة لما نجده في التراجع البسيط. ربما لاحظت أن القسم الموجود داخل القوسين مطابق لمعادلة التراجع الخطي حيث

نجد الحد الثابت b_0 والمتحول التنبؤي X_1 والمعامل أو الثقل الخاص به b_1. وكما في حالة التراجع الخطي فإنه من الممكن توسيع هذه المعادلة لتتضمن عدة متحولات تنبؤية، حيث تأخذ الشكل:

$$P(Y) = \frac{1}{1 + e^{-(b_0 + b_1X_1 + b_2X_2 + \cdots + b_nX_n + \varepsilon_i)}} \qquad (4.6)$$

إن المعادلة (4.6) مماثلة للمعادلة المستخدمة في حالة وجود متحول تنبؤي واحد باستثناء أن التركيب الخطي قد تم توسيعه ليشمل أي عدد من المتحولات التنبؤية. ولذلك فإن معادلة التراجع المنطقي في حالة متحول تنبؤي واحد تحوي معادلة التراجع الخطي البسيط، أما معادلة التراجع المنطقي متعدد المتحولات التنبؤية فتحوي معادلة التراجع المتعدد.

وبرغم نقاط التشابه بين التراجع الخطي والتراجع المنطقي، فإن هناك سبباً قوياً لعدم تطبيق التراجع الخطي بشكل مباشر على حالة يكون فيها متحول النتيجة ثنائياً. وهذا السبب هو أن إحدى فرضيات التراجع الخطي هي وجود علاقة خطية بين المتحولات (انظر الفقرة 1.2.6.5). لقد رأينا في تلك الفقرة أهمية تحقيق الفرضيات لكي يكون النموذج دقيقاً. ولذلك، ولكي يكون التراجع الخطي نموذجاً صحيحاً يجب أن تحوي القيم المشاهدة علاقة خطية. وعندما يكون متحول النتيجة ثنائياً تصبح هذه الفرضية غير محققة. وللالتفاف على هذه المشكلة نقوم بتحويل البيانات باستخدام التحويل اللوغاريتمي (انظر الفصل 3). وتقوم هذه العملية بجعل شكل العلاقة خطياً مع الإبقاء على العلاقة ذاتها غير خطية (وهي بالتالي طريقة للتعبير عن العلاقة غير الخطية بطريقة خطية). تعتمد معادلة التراجع المنطقي المذكورة سابقاً على هذا المبدأ، فهي تعبر عن معادلة التراجع الخطي المنطقي بمصطلحات لوغاريتمية، وهكذا فهي تتغلب على مشكلة عدم تحقق فرضية الخطية.

يمكن ترتيب الشكل الدقيق للمعادلة بعدة طرق، وقد اخترنا الشكل السابق لأنه يعبر عن المعادلة بمصطلحات احتمال حدوث Y (أي احتمال أن تنتمي حالة ما إلى فئة معينة). وهكذا فإن القيمة الناتجة عن المعادلة هي قيمة احتمال تتراوح بين 0 و 1. وتعني القيمة القريبة من 0 أنه من غير المحتمل أن تحدث Y، أما القيمة القريبة من 1 فتعني أنه من المرجح جداً حدوث Y. وكما في التراجع الخطي، فإن لكل متحول تنبؤي معامله الخاص. وعند تنفيذ التحليل فإننا بحاجة لتقدير هذه المعاملات بحيث يمكننا حل المعادلة. يتم تقدير هذه البارامترات من نماذج التوافق للبيانات المشاهدة بناءً على المتحولات التنبؤية المتوفرة. وسيكون النموذج المختار هو النموذج الذي يعطي قيم Y الأقرب إلى القيم المشاهدة وذلك عند تعويض قيم المتحولات التنبؤية فيه. يتم تقدير قيم البارامترات باستخدام تقدير الاحتمال الأعظمي (maximum-likelihood estimation) الذي يختار المعاملات التي تجعل احتمال حدوث القيم المشاهدة أعظمياً. لذلك، وكما في حالة التراجع المتعدد، فإننا نحاول ملاءمة نموذج للبيانات بحيث يسمح لنا تقدير قيم متحول النتيجة من القيم المعلومة للمتحول أو للمتحولات التنبؤية.

1.3.6 تقييم النموذج: إحصائية لوغاريتم الاحتمال

رأينا أن نموذج التراجع المنطقي يتوقع احتمال حدوث حدث ما لشخص معين (نسمي ذلك $P(Y_i)$ وهو احتمال حدوث Y للشخص رقم i) بناءً على المشاهدات لحدوث أو عدم حدوث الحدث لذلك الشخص (يمكن أن نسمي ذلك Y_i النتيجة الفعلية للشخص رقم i). فمن أجل شخص معين تكون قيمة Y إما 0 (النتيجة لم تحدث) أو 1 (النتيجة حدثت)، والقيمة المتوقعة P(Y) ستكون قيمة محصورة بين 0 (ليس هناك أمل بحدوث النتيجة) و 1 (النتيجة سوف تحدث). وقد رأينا في التراجع المتعدد (انظر الفصل 5) أنه إذا أردنا تقييم فيما إذا كان النموذج يلائم البيانات فإنه يمكننا مقارنة القيم المشاهدة والقيم المتوقعة للنتيجة (وقد استخدمنا R^2 وهو ارتباط Pearson بين القيم المشاهدة للنتيجة والقيم المتوقعة من نموذج التراجع). وبشكل مشابه في التراجع المنطقي، فإنه يمكننا استخدام القيم المشاهدة والمتوقعة لتقييم ملائمة النموذج. يعرف هذا المقياس الذي نستخدمه باسم لوغاريتم الاحتمال (log-likelihood):

$$\text{log - likelihood} = \sum_{i=1}^{N}\{Y_i \ln(P(Y_i)) + (1 - Y_i)\ln[1 - P(Y_i)]\} \qquad (5.6)$$

يعتمد لوغاريتم الاحتمال على تجميع الاحتمالات المرتبطة مع النتائج المتوقعة والفعلية. ولذلك فإن إحصائية لوغاريتم الاحتمال مشابهة لمجموع المربعات للبواقي في التراجع المتعدد من حيث أنها دليل على مقدار المعلومات غير المبررة بعد أن تمت ملاءمة النموذج للبيانات. وينتج عن ذلك أن القيم الكبيرة لإحصائية لوغاريتم الاحتمال تدل على سوء التوافق للنماذج الإحصائية، لأنه كلما كانت قيمة لوغاريتم الاحتمال أكبر كانت المشاهدات غير المبررة أكثر.

من الممكن الآن حساب لوغاريتم الاحتمال للنماذج المختلفة ومقارنة هذه النماذج بالنظر إلى الفرق بين قيم لوغاريتم الاحتمال الخاصة بها. وأحد الاستخدامات هو مقارنة حالة نموذج التراجع المنطقي مع حالة مرجعية معينة. والحالة المرجعية المستخدمة عادة هي النموذج الذي يحوي الحد الثابت فقط. في التراجع المتعدد، كان النموذج المرجعي المستخدم هو المتوسط لكل العلامات (وهو التخمين الأفضل للنتيجة عندما لا تتوفر أي معلومات أخرى). في التراجع المنطقي، إذا أردنا التنبؤ بالنتيجة فماذا سيكون التخمين الأفضل؟ لا يمكننا استخدام قيمة المتوسط لأن النتيجة مكونة من قيم 0 و 1 ولذلك فلا معنى لقيمة المتوسط. وعلى كل حال، إذا عرفنا التكرار للقيم 0 و 1 فإن أفضل تخمين هو الفئة التي تحوي العدد الأكبر من الحالات. فعلى سبيل المثال، إذا كانت نتيجة ما قد حدثت 107 مرات، ولم تحدث 72 مرة، فإن أفضل تخمين للنتيجة سيكون أنها تحدث (لأنها حدثت 107 مرات ولم تحدث 72 مرة فقط). لذلك وكما في التراجع المتعدد، فإن النموذج المرجعي سيكون ذلك النموذج الذي يعطينا أفضل توقع عندما لا نعرف شيئاً سوى قيم النتيجة، ولذلك يكون النموذج المرجعي في التراجع المنطقي هو الذي يتوقع النتيجة التي تحدث غالباً. وهذا هو النموذج للتراجع المنطقي عندما يحوي الحد الثابت فقط. إذا أضفنا بعد ذلك متحولاً تنبؤياً أو أكثر إلى النموذج فإنه يمكننا حساب التحسّن في النموذج كما يلي:

$$\chi^2 = 2[LL(new) - LL(baseline)]$$
$$(df = k_{new} - k_{baseline}) \qquad (6.6)$$

لذلك نأخذ ببساطة النموذج الجديد ونطرح منه النموذج المرجعي (النموذج الذي يحوي الحد الثابت فقط). تلاحظ أننا نضاعف هذه القيمة (نضربها بالعدد 2) وذلك لأنها تعطي النتيجة كتوزيع كاي مربع χ^2 (انظر الفصل 16 والملحق A4) وتجعل حساب الدلالة لهذه القيمة أمراً سهلاً. لتوزيع كاي مربع الذي نستخدمه عدداً من درجات الحرية يساوي عدد البارامترات في النموذج الجديد مطروحاً منه عدد البارامترات في النموذج المرجعي. إن عدد البارامترات k في النموذج المرجعي هو 1 (لأن الحد الثابت هو البارامتر الوحيد الذي ينبغي تقديره)، أما في النماذج الجديدة فسيكون عدد درجات الحرية مساوياً لعدد المتحولات التنبؤية مضافاً إليه العدد 1 (الذي يمثل الحد الثابت).

2.3.6 تقييم النموذج: R و R^2

عندما تحدثنا عن التراجع الخطي، رأينا أن معامل الارتباط المتعدد R والإحصائية R^2 هي قياسات مفيدة لمدى ملاءمة النموذج للبيانات. وقد رأينا أن نسبة الاحتمال تعتمد أيضاً على مستوى التوافق بين القيم المتوقعة و الفعلية للنتيجة. على كل حال، يمكنك حساب النسخة الحرفية للارتباط المتعدد في التراجع المنطقي والمعروفة بالإحصائية R. إن الإحصائية R هي الارتباط الجزئي بين متحول النتيجة وكل من المتحولات التنبؤية ويمكن أن تتراوح قيمتها بين 1- و1+. تدل القيم الموجبة على أنه إذا ازداد المتحول التنبؤي فإن احتمال حدوث النتيجة يصبح أكبر. أما القيم السالبة فتعني أنه عند ازدياد المتحول التنبؤي ينخفض احتمال حدوث النتيجة. إذا كان لمتحول ما قيمة R صغيرة فإن مساهمته في النموذج صغيرة.

تعطي المعادلة (7.6) معادلة R. يمثل الحد 2LL- المقدار 2 log-likelihood- للنموذج الأصلي، ويمثل الحد Wald إحصائية Wald التي سيتم حسابها في الفقرة التالية، أما عدد درجات الحرية df فيمكن قراءته من الجدول الملخص للمتحولات في المعادلة. ونظراً لأن قيمة R تعتمد على إحصائية Wald فإنها لن تكون قياساً دقيقاً بأي حال من الأحوال (سترى في الفقرة التالية أن إحصائية Wald يمكن أن تكون غير دقيقة تحت بعض الشروط). ولهذا السبب يجب التعامل مع قيمة R بشيء من الحذر، ولن يكون صحيحاً تربيع هذه القيمة وتفسيرها كما فعلنا في حالة التراجع الخطي:

$$R = \pm\sqrt{\left(\frac{Wald - (2 \times df)}{-2LL(Original)}\right)} \qquad (7.6)$$

هناك جدل حول ما يمكن أن يكون تماثلاً مع قيمة R^2 في التراجع الخطي، ولكن يمكن بسهولة حساب القيمة التي أعطاها Hosmer & Lemeshow (1989). وفي مصطلحات برنامج SPSS يتم حساب Hosmer and Lemeshow's R^2_L من العلاقة (8.6):

$$R_L^2 = \frac{-2LL(Model)}{-2LL(Original)} \qquad (8.6)$$

إذاً يتم حساب R^2_L بتقسيم كاي مربع للنموذج (اعتماداً على لوغاريتم الاحتمال) على 2LL-الأصلية (لوغاريتم الاحتمال للنموذج قبل إدخال المتحولات التنبؤية فيه). تمثل R^2_L الانخفاض النسبي في القيمة المطلقة للوغاريتم الاحتمال، ولذلك فهي مقياس لمدى تحسن سوء التوافق نتيجة تضمين المتحولات التنبؤية. ويمكن أن تتغير قيمتها بين 0 (وتعني أن المتحولات التنبؤية عديمة الفائدة في التنبؤ بمتحول النتيجة) و1 (التي تدل على أن النموذج يتوقع النتيجة بشكل مثالي).

ولكن برنامج SPSS لا يستخدم هذا المقياس، وإنما يستخدم Cox & Snell's R^2_{CS} التي تعتمد على لوغاريتم الاحتمال للنموذج ((LL(new)) ولوغاريتم الاحتمال للنموذج الأصلي المرجعي ((LL(Baseline)) وعلى حجم العينة n:

$$R^2_{CS} = 1 - e^{\left[-\frac{2}{n}(LL(New)) - LL(Baseline))\right]} \qquad (9.6)$$

على كل حال، لا تصل هذه الإحصائية لقيمتها النظرية العظمى البالغة 1. لذلك اقترح Nagelkerke (1991) التعديل التالي (Nagelkerke's R^2_N):

$$R^2_N = \frac{R^2_{CS}}{1 - e^{\left[\frac{2(LL(Baseline))}{n}\right]}} \qquad (10.6)$$

ومع أن طرق حساب هذه القياسات مختلفة فإنه يمكن النظر إليها جميعاً بنفس الطريقة. أي أنه يمكن النظر إليها كقيمة مشابهة لقيمة R^2 في التراجع الخطي من حيث أنها توفر مقياساً للدلالة العملية للنموذج.

3.3.6 تقييم مساهمة المتحولات التنبؤية: إحصائية Wald

كما في التراجع الخطي، فإننا نرغب بمعرفة مدى ملائمة النموذج للبيانات بشكل إجمالي، ولكننا نريد أيضاً معرفة المساهمة المنفصلة لكل من المتحولات التنبؤية. وقد استخدمنا في التراجع الخطي معاملات التراجع المقدَّرة (b) والخطأ المعياري المرتبط بها لحساب الإحصائية t. في التراجع المنطقي هناك إحصائية مشابهة تدعى إحصائية Wald (الشكل 1.6) ولها توزيع خاص يدعى توزيع كاي مربع (chi-square distribution). وتخبرنا هذه الإحصائية فيما إذا كانت المعاملات b للمتحولات التنبؤية مختلفة كثيراً عن القيمة 0. إذا كانت قيمة المعامل مختلفة عن القيمة 0 فيمكننا أن نفترض أن المتحول التنبؤي يساهم بشكل هام في التنبؤ بقيمة النتيجة Y. تبين المعادلة (11.6) كيفية حساب إحصائية Wald ونرى بوضوح أنها مماثلة للإحصائية t في التراجع الخطي (انظر المعادلة (6.5))، إنها حاصل قسمة قيمة معامل التراجع على الخطأ المعياري المرتبط بها.

$$Wald = \frac{b}{SE_b} \qquad (11.6)$$

وتُستخدم إحصائية Wald عادة لتحديد فيما إذا كان متحول ما هو متنبؤ مهم بالنتيجة، وربما كانت أكثر دقة في فحص إحصائيات نسبة الاحتمال. والسبب في الدعوة لاستخدام إحصائية Wald بحذر أنه عندما يكون معامل التراجع b كبيراً، فإن الخطأ المعياري يصبح مضخّماً مما يجعل قيمة الإحصائية أدنى من قيمتها الفعلية. ويزيد تضخم الخطأ المعياري احتمال رفض متحول تنبؤي كمتحول مهم بينما هو يساهم فعلياً بشكل مهم في النموذج (أي أنه من المرجح أن ترتكب الخطأ من النوع الثاني).

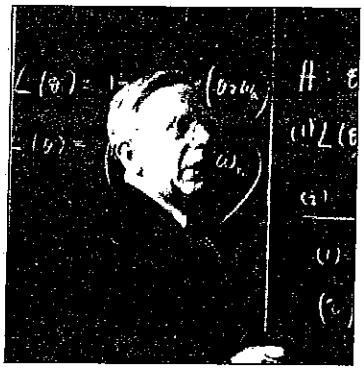

الشكل 1.6 Abraham Wald

Exp(B) 4.3.6

تعتبر قيمة Exp(B) من القيم الحرجة في تفسير التراجع المنطقي، وهي مؤشر على تغير الأرجحية الناتج عن تغير بمقدار الوحدة في المتحول التنبؤي. ولذلك فهي شبيهة بالمعامل b في التراجع المنطقي ولكنها أسهل فهماً (لأنها لا تتطلب تحويلاً لوغاريتمياً).

عندما يكون المتحول التنبؤي فئوياً يكون من الأسهل شرح Exp(B). تخيل أننا نحاول التنبؤ بحدوث الحمل عند امرأة ما أو عدم حدوثه وذلك عند استخدام أو عدم استخدام الواقي الذكري. إن أرجحية (Odds) حدوث حدث ما هي احتمال حدوث الحدث مقسوماً على احتمال عدم حدوثه (انظر المعادلة (12.6)) ويجب عدم الخلط بينهما وبين الاستخدام العامي أو الدارج لهذه الكلمة والذي يشير للاحتمال :

$$\text{odds} = \frac{P(\text{event})}{P(\text{no event})}$$

$$P(\text{event Y}) = \frac{1}{1 + e^{-(b_0 + b_1 X_1)}} \qquad (12.6)$$

$$P(\text{no event Y}) = 1 - P(\text{event})$$

ومن أجل المثال فإن أرجحية حدوث الحمل هي احتمال حدوث الحمل مقسوماً على احتمال عدم حدوثه. ولحساب التغير في الأرجحية الذي ينتج عن التغير بمقدار الوحدة في المتحول التنبؤي، يجب أن نحسب أولاً أرجحية حدوث الحمل عند عدم استخدام الواقي. ثم نحسب أرجحية الحمل عند استخدام الواقي. وأخيراً نحسب التغير المتناسب في هاتين الأرجحيتين.

لحساب المجموعة الأولى من الأرجحية، نحتاج للمعادلة (3.6) لحساب احتمال حدوث الحمل عند عدم استخدام الواقي. إذا كان لدينا أكثر من متحول تنبؤي فعلينا استخدام المعادلة (4.6). هناك ثلاثة مقادير مجهولة في هذه المعادلة هي: الحد الثابت (b_0)، المعامل للمتحول التنبؤي الأول (b_1) وقيمة المتحول التنبؤي ذاته X_1. سنعرف قيمة X من طريقة ترميزنا لمتحول استخدام الواقي (من المرجح أن نستخدم 0= عدم استخدام الواقي، 1= استخدام الواقي). وسيتم تقدير قيم b_1 وb_0. يمكننا حساب الأرجحية من المعادلة (12.6).

نقوم بعد ذلك بتكرار عملية الحساب السابقة بعد تغيير قيمة المتحول بمقدار الوحدة. في هذه الحالة، وبما أن المتحول التنبؤي ثنائي فإننا نحسب الأرجحية لحصول الحمل عند استخدام الواقي، ولذلك ستكون قيمة المتحول X هي 1 بدلاً من 0.

نعلم الآن الأرجحية قبل وبعد التغير بمقدار الوحدة في المتحول التنبؤي. وتصبح مسألة حساب التغير المتناسب في الأرجحية عملية بسيطة حيث نقسم الأرجحية بعد التغير بمقدار الوحدة في المتحول التنبؤي على الأرجحية قبل التغير :

$$\Delta Odds = \frac{\text{الأرجحية بعد التغير بمقدار الوحدة في المتحول التنبؤي}}{\text{الأرجحية الأصلية}} \qquad (13.6)$$

يدعى هذا التغير المتناسب في الأرجحية Exp(B)، ولذلك يمكننا تفسير Exp(B) بدلالة التغير في الأرجحية كما يلي: إذا كانت القيمة أكبر من 1 فهذا يدل على أنه عند ازدياد المتحول التنبؤي تزداد أرجحية حصول النتيجة. وبالعكس إذا كانت القيمة أصغر من 1 فهذا يدل على أنه عند ازدياد المتحول التنبؤي تنخفض أرجحية حصول النتيجة.

وسنرى كيفية عمل ذلك في مثال حقيقي بعد قليل.

5.3.6 طرق التراجع المنطقي

كما في حالة التراجع المتعدد، فإن هناك عدة طرق يمكن استخدامها في التراجع المنطقي.

1.5.3.6 طريقة الإدخال القسري

إن الطريقة الافتراضية لتنفيذ التراجع هي enter، وهي نفس طريقة الإدخال القسري المستخدمة في التراجع المتعدد حيث يتم وضع جميع المتغيرات المشتركة في نموذج التراجع ضمن كتلة واحدة، ويتم حساب تقديرات البارامترات لكل كتلة. يعتقد بعض الباحثين أن هذه الطريقة هي الوحيدة المناسبة لاختبار النظرية، وذلك لأن التقنيات الخطوية تتأثر بالتغير العشوائي في البيانات ونادراً ما تعطي نفس النتائج إذا تم اختبار النموذج مرة ثانية ضمن نفس العينة.

2.5.3.6 الطرق الخطوية

عند استخدام الطريقة التقدمية (forward) فإن البرنامج يبدأ بنموذج يحوي الحد الثابت فقط ثم يضيف إليه المتحولات التنبؤية بشكل منفرد بناءً على معيار محدد. وهذا المعيار هو قيمة لإحصائية العلامة (score): تتم إضافة المتحول ذو أعلى قيمة دلالة لإحصائية العلامة إلى النموذج. ويستمر البرنامج بإضافة المتحولات حتى لا يبقى متحول تنبؤي واحد ذو قيمة علامة ذات دلالة (تكون نقطة القطع للدلالة هي 0.05). وفي كل خطوة يقوم البرنامج بفحص المتحولات في النموذج لمعرفة إذا كانت هناك ضرورة لإزالة بعض المتحولات. ويقوم بهذه العملية وفق إحدى الطرق الثلاث التالية:

1. استخدام إحصائية نسبة الاحتمال المبينة في الفقرة 2.2.16 (طريقة Forward:LR) حيث تتم مقارنة النموذج الحالي بالنموذج عند إزالة متحول تنبؤي معين. إذا أحدثت عملية الإزالة للمتحول التنبؤي فرقاً مهماً في مدى ملاءمة النموذج للبيانات المشاهدة فإن البرنامج يحافظ على ذلك المتحول التنبؤي (لأن النموذج أفضل عندما كان المتحول التنبؤي ضمنه). أما إذا أحدثت عملية الإزالة للمتحول التنبؤي فرقاً صغيراً في النموذج فإن البرنامج يحذف ذلك المتحول التنبؤي من النموذج.
2. استخدام الإحصائية الشرطية كمعيار إزالة (Forward:Conditional). وهذه الإحصائية هي نسخة أخف رياضياً من إحصائية نسبة الاحتمال ولذلك لا يوجد ما يبرر تفضيلها على الطريقة الأولى.
3. استخدام إحصائية Wald حيث تتم إزالة المتحولات التنبؤية التي تملك قيماً مهمة لإحصائية Wald (أعلى من المعيار الافتراضي البالغ 1).

تعتبر طريقة نسبة الإحصاء هي الأفضل لأن إحصائية Wald تعطي أحياناً قيماً غير موثوقة (انظر الفقرة 3.3.6).

الطريقة المعاكسة للطريقة التقدمية هي الطريقة التراجعية (backward). وتستخدم هذه الطريقة نفس معايير الإزالة ولكن بدلاً من البدء بالنموذج بالحد الثابت فقط فإنها تبدأ بنموذج يحوي جميع المتحولات التنبؤية. ثم يقوم البرنامج باختبار فيما إذا كان ممكناً حذف بعض المتحولات التنبؤية من النموذج دون حدوث تأثير كبير على مدى ملاءمة النموذج للبيانات المشاهدة. والمتحول التنبؤي الذي تتم إزالته أولاً هو المتحول الذي يكون تأثيره منخفضاً جداً على ملاءمة النموذج للبيانات.

3.5.3.6 كيف نختار الطريقة؟

كما في حالة التراجع العادي (الفصل 5) فإن اختيار طريقة التراجع يعتمد على عدة اعتبارات. ويتعلق الاعتبار الأساسي بما إذا كان الهدف اختبار نظرية ما أو تنفيذ عمل استكشافي. وكما ذكرنا سابقاً، فإن بعض الناس يعتقدون أن الطرق الخطوية عديمة الفائدة في اختبار النظريات،

ولكن يمكن استخدام هذه الطرق في الحالات التي لا توجد فيها أعمال بحث سابقة يمكن اعتمادها لوضع فرضيات الاختبار، وفي الحالات التي لا تكون السببية موضع اهتمام، ويهدف البحث إلى إيجاد نموذج ملائم للبيانات فقط. وكما ذكرنا في حالة التراجع العادي، إذا قررت استخدام طريقة خطوية فإن الطريقة التراجعية هي المفضلة على الطريقة التقدمية. وذلك بسبب الآثار المخمّدة التي تحدث عندما يكون لمتحول تنبؤي أثر هام ولكن فقط عندما يكون المتحول التنبؤي الآخر ثابتاً. تفضل الطريقة التقدمية على الطريقة التراجعية لاستثناء المتحولات التنبؤية المرتبطة بالآثار المخمدة. وهكذا يتم تنفيذ الطريقة التقدمية مع مخاطرة كبيرة بارتكاب الخطأ من النوع الثاني. وفيما يتعلق بإحصائية الاختبار المستخدمة في الطرق الخطوية فإن إحصائية Wald تميل لعدم الدقة في بعض الظروف (انظر الفقرة 3.3.6) ولذلك فإن إحصائية نسبة الاحتمال هي الأفضل.

4.6 تنفيذ التحليل: مثال بحثي

سنأخذ مثالاً بسيطاً عن علم النفس التطويري. تعتبر حالة النجاح أو الفشل في الامتحان مثالاً جيداً عن التفرع الثنائي، وفي علم النفس التطويري فإنها ترتبط غالباً بامتلاك (أو عدم امتلاك) المقدرة الإدراكية. ينظر هذا المثال في فهم الأطفال لقواعد التعبير بناءً على عمر الطفل، وفيما إذا كان الطفل يمتلك نظرية المقدرة العقلية. وقاعدة التعبير هي اصطلاح لإظهار التعبير المناسب في حالة معينة. فعلى سبيل المثال، إذا تلقى الطفل هدية في عيد الميلاد و لم تعجبه فإن التعبير المناسب هو الابتسامة بأدب مع عبارة "شكراً عمي، لطالما أحببت أن يكون لدي هذا الشيء". أما التعبير غير المناسب فهو البكاء والصراخ "لماذا اشتريت لي مثل هذا الشيء التافه أيها الأناني". بديهي أن الأطفال يفتقدون لفهم قواعد التعبير الصحيحة وهذا يتعلق بتحصيل نظرية المقدرة العقلية (وهي ببساطة المقدرة على فهم ما يمكن للشخص الآخر أن يفكر به).

ومن أجل هذا المثال، يهتم الباحثون فيما إذا كان فهم المظاهر التعبيرية مرتبطاً بامتلاك نظرية المقدرة العقلية أم لا. ومن المنطقي أن يكون فَهمُ الطفل لآلية تفكير الشخص الآخر أمراً ضرورياً لفهم كيفية تأثير المظاهر على ذلك الشخص، فإذا لم تستطع أن تتخيل نفسك مكان الشخص الذي قدم الهدية فإنك لن تكون قادراً على معرفة حالته عندما تنعته بالأناني. ولاختبار هذه النظرية، تم إعطاء مهمة اعتقاد خاطئ قياسية لمجموعة من الأطفال (مهمة مستخدمة لقياس فيما إذا كان للشخص نظرية المقدرة العقلية) وتم قياس إمكانية أن ينجحوا أو يفشلوا في المهمة وكذلك قياس أعمارهم بالأشهر. بالإضافة لذلك تم إعطاء كل طفل قاعدة تعبير معينة حيث يمكن أن ينجحوا أو يفشلوا أيضاً. لذلك فقد تم قياس المتحولات التالية:

- **النتيجة (متحول تابع):** امتلاك فهم قاعدة التعبير (هل يجتاز الطفل الاختبار: نعم/لا ؟).
- **المتحول التنبؤي (متحول مستقل):** امتلاك نظرية المقدرة العقلية (هل يجتاز الطفل مهمة الاعتقاد الخاطئ: نعم/لا ؟)

- **المتحول التنبؤي (متحول مستقل):** العمر بالأشهر.

في هذه التجربة، هناك متحول نتيجة ثنائي، ومتحول تنبؤي فئوي، ومتحول تنبؤي مستمر. وهو سيناريو مثالي لحالة تراجع منطقي.

1.4.6 التحليل الأساسي

لتنفيذ التراجع المنطقي، يجب إدخال البيانات كما في حالة التراجع العادي حيث تكون البيانات مرتبة في محرر البيانات في ثلاثة أعمدة (عمود لكل متحول). يمكن أن تستخدم الملف display.sav من القرص المضغوط المرفق الذي يحوي تلك البيانات. إذا نظرت في محرر البيانات فإنك تلاحظ أن المتحولين الفئويين قد تم إدخالهما كمتحولات ترميز (انظر الفقرة 4.4.2)، حيث تم تعريف الأرقام لتمثيل الفئات. ولسهولة التفسير فقد تم ترميز متحول النتيجة بالقيمة 1 (حدوث الحدث) والقيمة 0 (عدم حدوث الحدث)، وفي هذه الحالة فإن القيمة 1 تمثل فهم قاعدة التعبير، أما القيمة 0 فتمثل عدم فهم قاعدة التعبير. وبالنسبة لمهمة الاعتقاد الخاطئ فقد تم استخدام ترميز مشابه (1=اجتياز مهمة الاعتقاد الخاطئ، 0=الفشل في مهمة الاعتقاد الخاطئ)، يمكن الوصول إلى التراجع المنطقي عبر أمر القائمة Analyze ⇒ Regression ⇒ Binary logistic... حيث يظهر مربع الحوار للتراجع المنطقي Logistic Regression المبين في (الشكل 2.6).

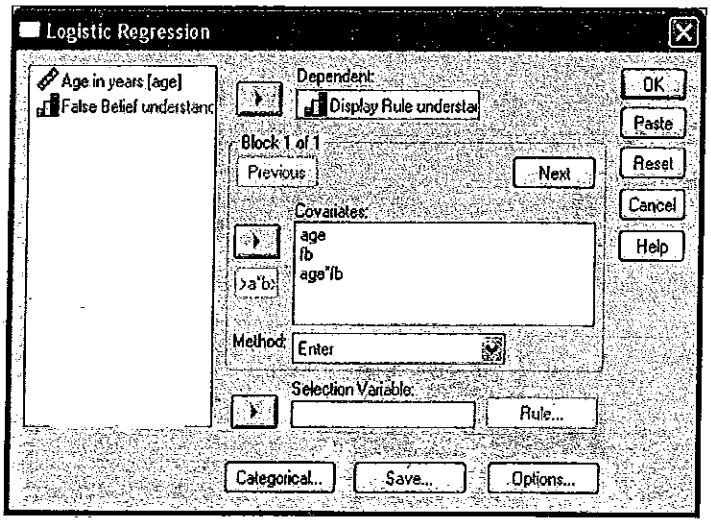

الشكل 2.6 مربع الحوار الرئيسي للتراجع المنطقي

يشبه مربع الحوار الرئيسي للتراجع المنطقي مربع الحوار للتراجع القياسي. هناك حيز لوضع المتحول التابع (أو متحول النتيجة). في المثال فإن متحول النتيجة هو مهمة قاعدة التعبير لذلك يمكننا نقر المتحول display ونقله إلى الحيز Dependent بنقر زر السهم الموجود بين القسمين. هناك أيضاً

حيز لتحديد المتحولات التنبؤية. من الممكن تحديد الأثر الرئيسي والآثار المتبادلة في التراجع المنطقي. لتحديد الأثر الرئيسي نختار أحد المتحولات التنبؤية (وليكن age) وننقله إلى الحيز المسمى Covariates بنقر زر السهم بين القسمين. لإدخال تفاعل أو أثر متبادل ننقر اثنين أو أكثر من المتحولات التنبؤية في القسم الأيسر من مربع الحوار ثم ننقر الزر >a*b< لنقلها إلى الحيز Covariates. في هذا المثال، هناك متحولان تنبؤيان ولذلك فإن هناك إمكانية واحدة للأثر المتبادل وهي agexfb، ولكن إذا كان لدينا 3 متحولات تنبؤية فيمكن اختيار تفاعلات ثنائية الاتجاه متعددة وكذلك تفاعلات ثلاثية الاتجاه.

2.4.6 طريقة التراجع

كما في حالة التراجع المتعدد، يمكنك استخدام عدة طرق مختلفة للتراجع المنطقي (انظر الفقرة 5.3.6). يمكنك تحديد طريقة معينة للتراجع بنقر السهم في المربع المسمى Method. يبين (الشكل 3.6) جزء من قائمة التراجع المنطقي عند تفعيل طرق التراجع. ومن أجل هذا المثال فإننا نختار الطريقة Forward:LR. لقد أمضيت وقتاً طويلاً في إقناعك بعدم استخدام التحليل الخطوي، ولذلك فقد تستغرب اقتراحي باستخدام تراجع تقدمي في هذا المثال. حسناً، السبب الأول الذي يدعو لاستخدام تراجع خطوي هو أن هذه الدراسة هي الأولى من نوعها ولا توجد أبحاث سابقة تدلنا على المتحولات التي يمكن أن تكون متحولات تنبؤية موثوقة. والسبب الثاني هو أننا لم نقدّم حتى الآن مثالاً عن التراجع الخطوي، ومن المفيد في هذه المرحلة عرض آلية عمل الإجرائية الخطوية في التراجع.

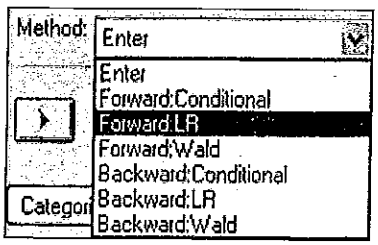

الشكل 3.6 طريقة التراجع

3.4.6 المتحولات التنبؤية الفئوية

في هذا المثال، هناك متحول تنبؤي فئوي واحد. ويتقبل التراجع المنطقي المتحولات التنبؤية الفئوية دون مشاكل ولكن يجب إعلام برنامج SPSS عن هذه المتحولات وذلك بنقر الزر Categorical في مربع الحوار الرئيسي للتراجع المنطقي حيث يتم فتح مربع الحوار المبين في (الشكل 4.6). في مربع الحوار يتم عرض المتحولات التنبؤية في القسم الأيسر، وهناك حيز في القسم الأيمن لوضع المتحولات الفئوية. ننقر المتحول الفئوي في القسم الأيسر (في هذا المثال، المتحول fb) وننقله إلى القسم الأيسر بنقر زر السهم الموجود بين القسمين. في (الشكل 4.6) تم تحديد المتحول fb ونقله.

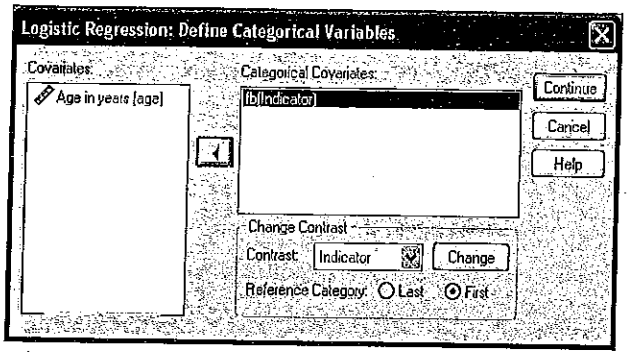

الشكل 4.6 تعريف المتحولات الفئوية في التراجع المنطقي

هناك عدة طرق يمكن من خلالها التعامل مع المتحولات التنبؤية الفئوية، فبرنامج SPSS يستخدم بشكل افتراضي مقارنات الانحراف مع جميع المتحولات الفئوية. وقد رأينا في الفقرة 10.5 أنه يمكن تضمين المتحولات التنبؤية الفئوية في التراجع بتسجيلها في الترميز المزيف كقيم 0 و1. والآن هناك طرق مختلفة لترتيب هذا الترميز بناءً على ما نريد مقارنته، ولبرنامج SPSS عدة طرق قياسية يمكنك الاختيار بينها (سنمر على هذه الطرق بالتفصيل في الفصل 8). يستخدم برنامج SPSS بشكل افتراضي مقارنة المؤشر (Indicator) وهو ترميز المتحول المزيف القياسي الذي شرحناه في الفقرة 10.5 (ويمكنك تحديد الفئة الأولى أو الأخيرة كفئة مرجعية). لاختيار نوع آخر من المقارنات، انقر السهم على القائمة المنسدلة Contrast في القسم Change Contrast. يبين (الشكل 5.6) أنه من الممكن اختيار المقارنة البسيطة (Simple) أو مقارنة الفرق (Difference) وغيرها كما في تحليل التباين ANOVA (انظر الجدول 6.8). ستتم مناقشة هذه التقنيات في الفصل 8 ويتم شرح عملها بالتفصيل. ولكننا لن نتعرض بالتفصيل لمقارنة المؤشر في ذلك الفصل لذلك سنستخدمه هنا (كما في الشكل 4.6). ونكرر هنا أنه عند استخدام مقارنة المؤشر فإنه يتم إعادة ترميز مستويات المتحول الفئوي باستخدام ترميز المتحول المزيف القياسي (انظر الفقرات 10.5 و8.7).

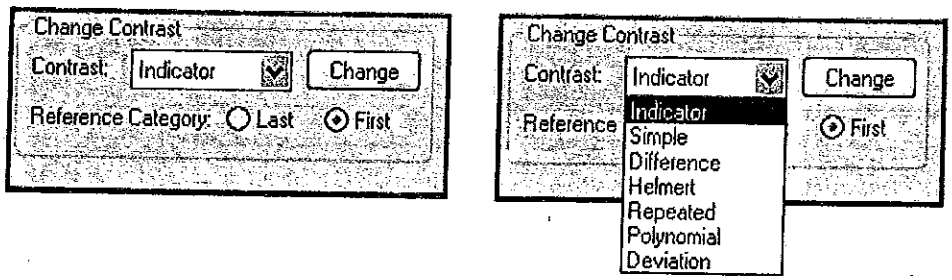

الشكل 5.6 اختيار التفاوت للمتحولات التنبؤية الفئوية

4.4.6 الحصول على البواقي

لقد رأينا في حالة التراجع الخطي أنه من الممكن أن نطلب من برنامج SPSS حفظ مجموعة من البواقي كمتحولات جديدة في محرر البيانات. يمكن بعد ذلك فحص متحولات البواقي لمعرفة مدى توافق النموذج مع البيانات المشاهدة. لحفظ البواقي انقر الزر ...Save في مربع الحوار الرئيسي للتراجع المنطقي (الشكل 2.6). يقوم برنامج SPSS بحفظ المتحولات المحددة في محرر البيانات ويمكن أيضاً عرضها في عارض الخرج باستخدام التعليمة Case Summaries (انظر الفقرة 6.8.5) واختيار متحولات البواقي المطلوبة. يوفر مربع حوار البواقي المبين في (الشكل 6.6) عدة خيارات. ومعظم هذه الخيارات مشابه لما وجدناه في التراجع المتعدد (انظر الفقرة 4.7.5). هناك باقيان خاصان بالتراجع المنطقي هما الاحتمالات المتوقعة (Predicted Probabilities) وأعضاء المجموعة المتوقعة (Predicted group memberships) . والاحتمالات المتوقعة هي احتمالات حدوث Y عند إعطاء القيم لكل متحول تنبؤي من أجل مشترك محدد. ولذلك فهي مشتقة من المعادلة (4.6) من أجل حالة معينة. أما أعضاء المجموعة المتوقعة فهي تتوقع انتماء مشترك ما لأي من الفئتين Y بناءً على النموذج. ويعتمد أعضاء المجموعة على الاحتمالات المتوقعة وسنشرح هذه القيم بتفصيل أكبر عندما سنقوم بتفسير البواقي. ومن الأفضل تحديد جميع الخيارات المتوفرة أو على الأقل الخيارات المحددة في الشكل 6.6.

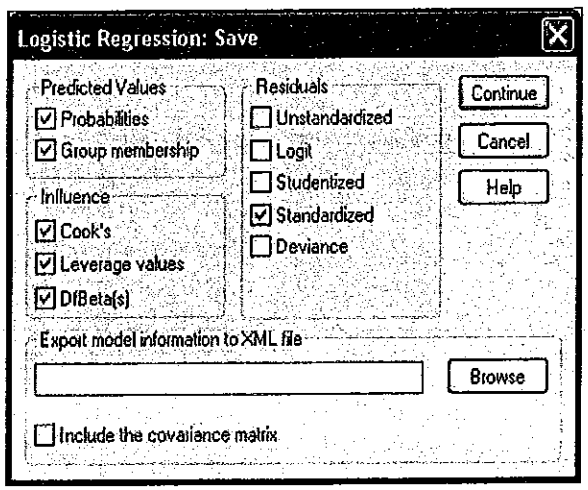

الشكل 6.6 مربع الحوار للحصول على البواقي في التراجع المنطقي

ولا يمكننا إلا أن نشدّد على أهمية فحص البواقي بعد القيام بأية عملية تحليل. فمن المزايا العديدة لاستخدام البرامج الحاسبية مقارنةً بعملية التحليل اليدوية أنه يمكن بسهولة كبيرة الحصول على إحصائيات تشخيص البواقي، وهي عملية تتطلب الكثير من الوقت والفهم العميق لعلم الجبر. وربما لم يقابل التطور في مجال الحاسب تطورٌ مناسب في الاهتمام بالبواقي، إذ أهمل علماء الاجتماع غالباً

فحص البواقي أثناء اهتمامهم بالحصول على قيم الاحتمالات الأدنى من 0.05. لقد شددنا على أهمية بناء النماذج الدقيقة، ولذلك فإن تنفيذ التراجع دون التحقق من مدى توافق النموذج مع البيانات يشبه تماماً عملية شراء بنطال دون تجربته. فقد يبدو البنطال جميلاً على الحمّالة ولكن عند العودة إلى المترل قد تكتشف أنه ضيق جداً. لقد قام البنطال بعمله في حماية الساقين وتغطيتهما، ولكن قيمته في الحياة الفعلية معدومة إذ سيؤثر على جريان الدم في الساقين وبعض الأماكن الحساسة الأخرى. وبشكل مشابه فإن التراجع يقوم بعمله بغض النظر عن البيانات فهو يقوم بإنشاء النموذج، ولكن القيمة الحقيقية لهذا النموذج قد تكون محدودة جداً.

إن اختبار درجة توافق النموذج مع البيانات المجمعة هو الأساس في إحصائيات التشخيص. إذا كان النموذج يتوافق جيداً مع البيانات فإنه يمكننا أن نكون أكثر ثقة بأن معاملات النموذج هي دقيقة ولا تتأثر بعدة نقاط شاردة. وفي أفضل الحالات قد يقود الفشل في فحص البواقي إلى إهمال عدم دقة المعاملات في النموذج. أما في أسوأ الحالات فإن النموذج غير الدقيق قد يستخدم في قبول فرضيات نظرية هي في الحقيقة ليست صحيحة.

5.4.6 المزيد من الخيارات

هناك مربع حوار أخير يقدم المزيد من الخيارات. وهذا المربع مبين في الشكل 7.6 يمكن الوصول إليه بنقر الزر ...Options في مربع الحوار الرئيسي للتراجع المنطقي. ومعظم الخيارات الافتراضية هي جيدة. وقد ذكرنا في الفقرة 2.4.6 أنه عند اختيار طريقة خطوية فإن هناك معايير افتراضية لاختيار وإزالة المتحولات الافتراضية من النموذج. تظهر الإعدادات الافتراضية في مربع الحوار Options في القسم Probability for Stepwise. يمكن تغيير عتبة الاحتمال ولكن ليست هناك حاجة فعلية لهذا التغيير ما لم يتوفر سبب مقنع لاستخدام معيار أقسى. والقيمة الافتراضية الأخرى هي الوصول إلى النموذج بعد 20 محاولة كحد أقصى. عندما نقوم بملاءمة نموذج للبيانات فإننا نبحث عن أفضل نموذج ممكن ويتم تعريف العدد الأقصى للمحاولات بأنه العدد الأقصى للمحاولات التي يقوم بها البرنامج لإيجاد النموذج الأفضل. وما لم يكن لديك نموذج معقد جداً فإن العدد 20 سيكون مناسباً جداً. لقد رأينا في الفصل 5 أن معادلات التراجع تحوي حداً ثابتاً يمثل اعتراض Y (قيمة Y عندما تكون قيم المتحولات التنبؤية مساوية 0). يضع برنامج SPSS هذا الحد الثابت في النموذج بشكل افتراضي، ولكن من الممكن تنفيذ التحليل بدون الحد الثابت ولهذه العملية تأثير في جعل النموذج يمر من نقطة المبدأ (Y تساوي الصفر عندما X تساوي الصفر). وبما أننا نرغب بالحصول على نموذج يلائم البيانات بأفضل شكل فلا تعتبر عملية التحليل دون وجود الحد الثابت ذات أهمية عملية.

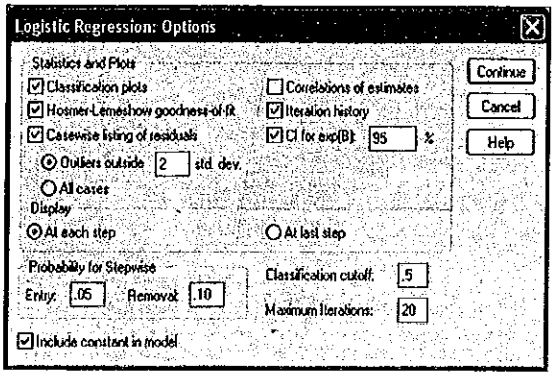

الشكل 7.6 مربع الحوار لخيارات التراجع المنطقي

هناك خيار مفيد جداً وهو المخطط البياني للتصنيف، وهو عبارة عن مخطط تكراري للقيم الفعلية والمتوقعة لمتحول النتيجة. وهذا المخطط مفيد في تقييم توافق النموذج مع البيانات المشاهدة. من الممكن أيضاً تنفيذ Casewise listing of residuals إما من أجل أية حالة تكون البواقي المعيارية فيها أكبر من ضعفي الانحراف المعياري (ويمكن تغيير هذه القيمة، ولكن القيمة الافتراضية معقولة)، أو من أجل جميع الحالات. وننصح بفحص معمّق للبواقي ولكن هذا الخيار مفيد من أجل عملية التحقق السريعة. يمكن أن تطلب من برنامج SPSS أن يعرض مجال الثقة (انظر الفقرة 2.6.1) من أجل إحصائية Exp(B)، ويقوم البرنامج بعرض مجال الثقة 95% وهي قيمة مناسبة (إذا كانت القيمة مختلفة فيمكنك تغييرها لتكون 95%) وهي إحصائية مفيدة. وأهم من ذلك، يمكنك طلب إحصائية Hosmer-Lemeshow لجودة التوافق التي يمكن استخدامها لتقييم مدى توافق النموذج مع البيانات. أما بقية الخيارات فهي غير مهمة تقريباً، حيث يمكنك اختيار جميع الإحصائيات والمخططات في كل مرحلة من التحليل (القيمة الافتراضية) أو بعد النموذج النهائي فقط. وأخيراً يمكنك عرض مصفوفة الارتباط لتقدير البارامترات للحدود في النموذج، كما يمكنك عرض المعاملات وقيم لوغاريتم الاحتمال عند كل محاولة في عملية تقدير البارامترات.

5.6 تفسير التراجع المنطقي

بعد تحديد جميع الخيارات التي قمنا بوصفها، انقر الزر OK وراقب الخرج في نافذة العارض. سنقوم بشرح كل قسم من التحليل بدوره. كان الخرج للتراجع المنطقي في الإصدارات السابقة من برنامج SPSS غير منسق (يظهر كنص فقط) ولكن تم حالياً تنسيقه بحيث يبدو جميلاً.

1.5.6 النموذج الأولي

يعرض (الخرج 1.6) ترميز البارامترات للمتحول التنبؤي الفئوي. لقد تم اختيار ترميز المؤشر Indicator مع فئتين ولذلك فإن الترميز مشابه للقيم في محرر البيانات. لو تم اختيار ترميز الانحراف

Deviation فإن الترميز سيأخذ القيم 1- (fb نعم) و1+ (fb لا). ومع المقارنة البسيطة (Simple) فإن الترميز سيكون 0.5- (fb لا) و0.5 (fb نعم) عند اختيار الفئة الأخيرة كفئة مرجعية، وبالعكس عند اختيار الفئة الأولى كفئة مرجعية. إن ترميز البارامترات مهم في حساب احتمال متحول النتيجة (P(Y)) ولكننا سنأتي على ذلك لاحقاً.

Dependent Variable Encoding

Original	Internal Value
No	0
Yes	1

Categorical Variable Codings

		Frequency	Parameter coding (1)
False Belief understanding	No	29	.000
	Yes	41	1.000

الخرج 1.6

من أجل التحليل الأولي اخترنا الطريقة الخطوية التقدمية لذلك فإنه يتم اشتقاق النموذج الأولي باستخدام الحد الثابت فقط في معادلة التراجع. يخبرنا (الخرج 2.6) عن النموذج عند تضمين الحد الثابت فقط (بإهمال جميع المتحولات التنبؤية). ومع أن برنامج SPSS لا يعرض قيمة لوغاريتم الاحتمال للنموذج المرجعي فإن قيمته هي 96.124. وهذا يمثل توافق النموذج الأساسي مع البيانات. عند تضمين الحد الثابت فقط فإن البرنامج يعتمد النموذج على أساس تعيين جميع المشتركين إلى فئة واحدة من متحول الخرج. وفي هذا المثال يمكن أن يقرر البرنامج التنبؤ بأن كل طفل قد فهم قاعدة التعبير، أو بأن جميع الأطفال لم يفهموا قاعدة التعبير. ويمكن أن يتم هذا القرار بشكل اعتباطي، ولكن بما أن من الضروري محاولة الحصول على أفضل نموذج متوافق مع البيانات المشاهدة فإن برنامج SPSS سيتوقع أن ينتمي جميع الأطفال إلى الفئة التي تحوي معظم الحالات المشاهدة. وفي هذا المثال، هناك 39 طفلاً قد أظهروا فهماً لقاعدة التعبير بينما فشل 31 طفلاً. ولذلك إذا توقع برنامج SPSS أن جميع الأطفال قد أظهروا فهماً لقاعدة التعبير فإن هذا التوقع سيكون صحيحاً 39 مرة من أصل 70 (أي 56%)، أما إذا توقّع أن يفشل جميع الأطفال في فهم قاعدة التعبير فإن هذا التوقع سيكون صحيحاً 31 مرة من أصل 70 (أي 44%). ومن بين الخيارين المتوفرين فإنه من الأفضل أن يتوقع البرنامج فهم جميع الأطفال لقاعدة التعبير لأن هذا يعطي عدداً أكبر من التوقعات الصحيحة. يُظهر الخرج جدول الحدث المتوقع للنموذج في حالته الأولية. يمكنك أن ترى أن برنامج SPSS قد توقع أن ينجح جميع الأطفال في فهم قاعدة التعبير، مما يعطي 0% من الدقة للأطفال الذين تمت مراقبتهم ولم يُظهروا فهماً لقاعدة التعبير، و100% من الدقة للأطفال الذين تمت

مراقبتهم ونجحوا في فهم قاعدة التعبير. وبشكل إجمالي فإن النموذج قد نجح في تصنيف 55.71% من الأطفال. يلخص الجزء التالي من الخرج النموذج، وعند هذه المرحلة فإن ذلك يعطي قيمة الحد الثابت (b_0) التي تساوي 0.23.

أما الجدول الثالث في الخرج فيسمى Variables not in the Equation (المتحولات غير الموجودة في المعادلة). يقدم السطر الأخير في الجدول إحصائية كاي مربع للباقي وتساوي 26.257 وهي قيمة ذات دلالة عند مستوى $p<0.0001$ (وقد تمت تسميتها الإحصائيات الإجمالية Overall Statistics). تفيد هذه الإحصائيات بأن المعاملات للمتحولات غير الموجودة في النموذج مختلفة تماماً عن القيمة 0، وبكلمة أخرى فإن إضافة متحول تنبؤي أو أكثر من هذه المتحولات إلى النموذج سيؤثر بشكل كبير على قدرته التوقعية. إذا كان الاحتمال لإحصائية كاي مربع للباقي أكبر من 0.5 فإن ذلك قد يعني أن المتحولات المستثناة من النموذج لا تساهم بشكل كبير في القدرة التوقعية للنموذج. ولذلك فإن التحليل ينتهي عند هذه المرحلة.

Classification Table[a,b]

Observed			Predicted		
			Display Rule understanding		Percentage Correct
			No	Yes	
Step 0	Display Rule understanding	No	0	31	.0
		Yes	0	39	100.0
	Overall Percentage				55.7

a. Constant is included in the model.

b. The cut value is .500

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 0	Constant	.230	.241	.910	1	.340	1.258

Variables not in the Equation

			Score	df	Sig.
Step 0	Variables	age	15.956	1	.000
		fb(1)	24.617	1	.000
		age by fb(1)	23.987	1	.000
	Overall Statistics		26.257	3	.000

الخرج 2.6

يعرض الجزء الباقي من الجدول كلاً من المتحولات التنبؤية مع قيمة إحصائية العلامة الفعالة (Rao's efficient score statistic) (العمود المسمى Score). في العينات الكبيرة وعندما تكون فرضية العدم صحيحة فإن إحصائية العلامة تكون مماثلة لإحصائية Wald وإحصائية نسبة الاحتمال. وتستخدم عند هذه المرحلة من التحليل لأنها رياضياً أقل كثافة من إحصائية Wald ويمكن حسابها في الحالات التي تكون فيها إحصائية Wald كبيرة جداً. وكأي إحصائية فإن لإحصائية العلامة الفعّالة توزيعاً خاصاً يمكن من خلاله الحصول على الدلالة الإحصائية. في هذا المثال، كان لجميع المتحولات المستثناة إحصائية علامة مهمة عند مستوى $p<0.001$ ولذلك فإن المتحولات الثلاثة قد تساهم في النموذج. على كل حال، وكما ذكرنا سابقاً في الفقرة 2.4.6 فإن الحسابات الخطوية هي نسبية ولذلك فإن المتحول الذي سيتم اختياره ليدخل في النموذج هو المتحول صاحب القيمة الأعلى لإحصائية العلامة عند مستوى 0.05 للدلالة. في هذا المثال، سيكون المتحول fb هو المرشح لدخول النموذج وذلك لأنه صاحب أعلى قيمة لإحصائية العلامة.

2.5.6 الخطوة الأولى: فهم الاعتقاد الخاطئ

تتم في الخطوة الأولى إضافة متحول فهم الاعتقاد الخاطئ (fb) إلى النموذج كمتحول تنبؤي. وهكذا فإن الطفل سيتم تصنيفه الآن على أنه أظهر فهماً لقاعدة التعبير اعتماداً على أنه نجح أو فشل في مهمة الاعتقاد الخاطئ.

يمكن شرح ذلك بسهولة إذا نظرنا إلى الجدول المتقاطع للمتحولين fb وdisplay (يمكن الحصول عليه بتنفيذ أمر القائمة Analyze ⇒ Descriptive Statistics ⇒ Crosstabs). يَستخدم النموذج فهم الاعتقاد الخاطئ ليتوقع فيما إذا كان الطفل قد فهم قاعدة التعبير وذلك بتطبيق الجدول المتقاطع الموضح في (الجدول 1.6). ولذلك فإن النموذج يتوقع أن جميع الأطفال الذين نجحوا في فهم الاعتقاد الخاطئ سيفهمون قاعدة التعبير. كان هناك 41 طفلاً قد فهموا التعبير الخاطئ ولذلك فإن النموذج يتوقع أن هؤلاء الأطفال (41) قد فهموا قاعدة التعبير (وهذا صحيح في 33 مرة من أصل 41، وغير صحيح في 8 مرات من أصل 41). بالإضافة لذلك فإن النموذج يتوقع أن الطلاب الذين لم ينجحوا في فهم الاعتقاد الخاطئ وعددهم 29 لم ينجحوا في فهم قاعدة التعبير (وهذا صحيح في 23 مرة من أصل 26، وغير صحيح في 6 مرات من أصل 29).

		فهم الاعتقاد الخاطئ	
		لا	نعم
فهم قاعدة التعبير	لا	23	8
	نعم	6	33

الجدول 1.6 الجدول المتقاطع لفهم قاعدة التعبير مع فهم الاعتقاد الخاطئ

يعرض الخرج 3.6 الإحصائيات الملخصة للنموذج الجديد (الذي يحوي المتحول fb). يتم تقييم التوافق الإجمالي للنموذج باستخدام إحصائية لوغاريتم الاحتمال (انظر الفقرة 1.3.6). وبدلاً من عرض قيمة لوغاريتم الاحتمال ذاتها، يقوم برنامج SPSS بضرب هذه القيمة بالمقدار 2 (ولذلك تدعى 2LL-)، وتتم هذه العملية لأن للمقدار 2LL- توزيع كاي مربع تقريباً مما يجعل مقارنته مع القيم المتوقعة أمراً بسيطاً. تذكر أن القيم الكبيرة لإحصائية لوغاريتم الاحتمال تدل على نماذج إحصائية ضعيفة التوافق مع البيانات.

Omnibus Tests of Model Coefficients

		Chi-square	df	Sig.
Step 1	Step	26.083	1	.000
	Block	26.083	1	.000
	Model	26.083	1	.000

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	70.042[a]	.311	.417

a. Estimation terminated at iteration number 4 because parameter estimates changed by less than .001.

Classification Table[a]

			Predicted		
			Display Rule understanding		Percentage Correct
	Observed		No	Yes	
Step 1	Display Rule understanding	No	23	8	74.2
		Yes	6	33	84.6
	Overall Percentage				80.0

a. The cut value is .500

الخرج 3.6

عند هذه المرحلة من التحليل، يجب أن تكون قيمة 2LL- أقل من القيمة للنموذج عند احتوائه على الحد الثابت فقط (وذلك لأن القيمة الأقل تدل على أن النموذج يتوقع متحول النتيجة بدقة أكبر). عندما كان النموذج يضم الحد الثابت فقط كانت تلك القيمة 2LL=96.124- ولكن بعد إدخال المتحول fb فإن هذه القيمة قد انخفضت إلى 70.042. ويدل هذا الانخفاض على أن النموذج أصبح أفضل في توقع الفهم لقاعدة التعبير مما كان عليه قبل إضافة fb. ويتم تقييم مدى هذا التحسن في توقع

النموذج لمتحول النتيجة باستخدام إحصائية كاي مربع للنموذج (model chi-square statistic) والتي تقيس الفرق بين النموذج الحالي والنموذج عندما كان يحوي الحد الثابت فقط. وقد رأينا في الفقرة 1.3.6 أنه يمكننا تقييم دلالة التغير في النموذج بحساب لوغاريتم الاحتمال للنموذج الجديد وطرح قيمة لوغاريتم الاحتمال للنموذج المرجعي منها. وتعمل قيمة إحصائية كاي مربع للنموذج على هذا المبدأ وهي بذلك تساوي 2LL- للنموذج الذي يحوي fb مطروحاً منها قيمة 2LL- للنموذج الذي يحوي الحد الثابت فقط (96.124-70.042=26.083) ولهذه القيمة توزيع كاي مربع ولذلك يمكن بسهولة حساب دلالتها الإحصائية (عدد درجات الحرية هو عدد البارامترات في النموذج الجديد+1، وهو في هذه الحالة 2=1+1، مطروحاً منه عدد البارامترات في النموذج الأصلي، وهو الحد الثابت فقط، لذلك فإن 1=1-2= df).

في هذا المثال، القيمة ذات دلالة عند مستوى 0.05 ويمكننا أن نقول بشكل إجمالي أن النموذج يتوقع أن يكون فهم الاعتقاد الخاطئ أفضل بشكل كبير من حالة النموذج عند احتوائه على الحد الثابت فقط. إن إحصائية كاي مربع للنموذج شبيهة لاختبار F في التراجع الخطي (انظر الفصل 5). في عالم مثالي نريد أن نرى قيمة 2LL- بدون دلالة (مما يدل على أن مقدار البيانات غير المبررة أصغري) وإحصائية كاي مربع للنموذج عالية الدلالة (مما يدل على أن النموذج الذي يتضمن المتحولات التنبؤية أفضل بكثير من النموذج الذي لا يحويها). وعلى كل حال، فإن كلتا الإحصائيتين قد تكونان عاليتي الدلالة في الواقع.

هناك إحصائية ثانية تدعى إحصائية الخطوة Step التي تدل على التحسن الذي طرأ على القدرة التوقعية للنموذج منذ المرحلة السابقة. في هذه المرحلة هناك خطوة واحدة في التحليل ولذلك فإن قيمة إحصائية التحسن هي ذاتها إحصائية كاي مربع للنموذج. أما في النماذج الأكثر تعقيداً التي تحوي ثلاث أو أربع مراحل فإن هذه الإحصائية تعطي قياساً للتحسن في القدرة التوقعية للنموذج منذ الخطوة السابقة. وتساوي قيمتها 2LL- في الخطوة الحالية مطروحاً منها 2LL- في الخطوة السابقة. إذا كانت إحصائية التحسن ذات دلالة فإنها تدل على أن النموذج أصبح الآن يتوقع النتيجة بشكل أفضل بكثير مما كان يفعله في الخطوة السابقة، وفي التراجع التقدمي يمكن أن يكون ذلك مؤشراً على مساهمة متحول تنبؤي ما في القدرة التوقعية للنموذج. وبشكل مشابه توفر إحصائية الكتلة block التغير في 2LL- منذ الكتلة السابقة (وتستخدم في التحليل الهرمي أو الكتلي).

أخيراً، يدل جدول التصنيف في نهاية هذا القسم من الخرج على مدى توقع النموذج لعناصر المجموعة. وبما أن النموذج يستخدم فهم الاعتقاد الخاطئ ليتوقع متحول النتيجة فإن جدول التصنيف هو ذاته المبين في الجدول 1.6 يقوم النموذج الحالي بتصنيف صحيح لعدد يبلغ 23 طالباً ممن فشلوا في فهم قاعدة التعبير، وبتصنيف غير صحيح للطلاب الآخرين وعددهم 8 (أي أنه يصنف 74.19% من الحالات بشكل صحيح). أما بالنسبة للطلاب الذين فهموا قاعدة التعبير فإن النموذج يقوم بتصنيف 33 منهم بشكل صحيح وبتصنيف 6 بشكل غير صحيح (أي أنه يصنف

84.62% من الحالات بشكل صحيح). إن الدقة الإجمالية للتصنيف هي المتوسط المثقّل لهاتين القيمتين (80%). عندما كان النموذج يحوي الحد الثابت فإنه قام بتصنيف 56% من الحالات بشكل صحيح أما الآن وبعد إدخال المتحول fb كمتحول تنبؤي فقد ارتفعت هذه القيمة إلى 80%.

إن القسم التالي من الخرج (الخرج 4.6) أساسي لأنه يدلنا على تقديرات المعاملات للمتحولات التنبؤية المضمنة في النموذج. يعطي هذا القسم من الخرج المعاملات والإحصائيات للمتحولات التي تم تضمينها في النموذج عند هذه المرحلة (الحد الثابت والمتحول fb). إن قيم b هي ذاتها الموجودة في حالة التراجع الخطي، هناك القيم التي نعوضها في المعادلة (4.6) للحصول على احتمال أن تقع حالة ما في فئة معينة. وقد رأينا في التراجع الخطي أن قيم b تمثل التغير في النتيجة والناتج عن تغير بمقدار الوحدة في المتحول التنبؤي. إن تفسير هذا المعامل في التراجع المنطقي شبيه جداً بذلك فهو يمثل التغير في اللوغاريتم الطبيعي logit لمتحول النتيجة والمرتبط بتغير بمقدار الوحدة في المتحول التنبؤي. إن logit للنتيجة هو اللوغاريتم الطبيعي لأرجحية حدوث Y.

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 1[a]	fb(1)	2.761	.605	20.857	1	.000	15.812
	Constant	-1.344	.458	8.592	1	.003	.261

a. Variable(s) entered on step 1: fb.

الخرج 4.6

إن الإحصائية الحرجة هي إحصائية Wald ذات توزيع كاي مربع والتي تخبرنا فيما إذا كانت المعاملات b للمتحول التنبؤي مختلفة بشكل كبير عن الصفر. إذا كان المعامل مختلفاً بشكل كبير عن الصفر فإنه يمكننا أن نفترض أن ذلك المتحول التنبؤي يقدم مساهمة كبير في التوقع بالنتيجة Y. لقد رأينا في الفقرة 3.3.6 أنه يجب استخدام إحصائية Wald بحذر، لأنه عندما يكون المعامل b كبيراً فإن الخطأ المعياري يميل للتضخم مما يؤدي لتقدير أقل من الفعلي لإحصائية Wald. وعلى كل حال، فإنه من أجل هذه البيانات، يبدو أن فهم الاعتقاد الخاطئ هو متحول تنبؤي مهم في فهم قاعدة التعبير (لاحظ أن دلالة إحصائية Wald أقل من 0.05).

رأينا في الفقرة 2.3.6 أنه يمكننا حساب قيمة مشابهة للقيمة R باستخدام المعادلة (7.6). ومن أجل هذه البيانات، فإن إحصائية Wald وعدد درجات الحرية المرتبط بها يمكن قراءتهما من الخرج 4.6 (وهي القيم 20.856 و 1 على التوالي)، أما قيمة 2LL- الأصلية فكانت 96.124، ولذلك يمكن حساب R من المعادلة كما يلي:

$$R = \pm\sqrt{\left(\frac{20.856 - (2 \times 1)}{96.124}\right)} = 0.4429 \qquad (14.6)$$

ورأينا في نفس الفقرة أنه يتم حساب R^2_L (مقياس Hosmer and Lemeshow) بتقسيم إحصائية كاي مربع للنموذج على قيمة 2LL- الأصلية. في هذا المثال تبلغ قيمة كاي مربع بعد إدخال المتحولات في النموذج 26.083 وكانت القيمة الأصلية قبل إدخال المتحولات 96.124 ولذلك فإن R^2_L=0.271 وهي مختلفة عن القيمة التي نحصل عليها لو قمنا بتربيع قيمة R ($R^2=(0.4429)^2=0.196$).

في الخرج 3.6 حصلنا على قياسين آخرين لـــ R^2 التي تم وصفها في الفقرة 2.3.6. القيمة الأولى هي قيمة Cox and Snell التي يعطيها برنامج SPSS بالقيمة 0.311، والثانية هي قيمة Nagelkerke المعدّلة والتي يعطيها برنامج SPSS بالقيمة 0.417، وكما ترى فإن هناك فروقاً هامة بين هاتين القيمتين. المقدار الأخير الذي يجب النظر إليه هو القيمة Exp(B) التي تم وصفها في الفقرة 4.3.6. لحساب التغير في الأرجحية الناتج عن التغير بمقدار الوحدة في المتحول التنبؤي لهذا المثال، يجب علينا أولاً حساب الأرجحية ليكون الطفل ناجحاً في فهم قاعدة التعبير مع العلم أنه لم ينجح في فهم الاعتقاد الخاطئ. نقوم بعد ذلك بحساب الأرجحية ليكون الطفل ناجحاً في فهم قاعدة التعبير مع العلم أنه نجح في فهم الاعتقاد الخاطئ. ثم نحسب أخيراً التغير المتناسب في هاتين الأرجحيتين.

لحساب المجموعة الأولى من الأرجحية، نستخدم المعادلة (12.6) لحساب احتمال أن يكون الطفل ناجحاً في فهم قاعدة التعبير مع أنه فشل في مهمة الاعتقاد الخاطئ. إن بارامتر الترميز في بداية الخرج يخبرنا بأن الأطفال الذين فشلوا في مهمة الاعتقاد الخاطئ قد تم ترميزهم بالقيمة 0، ولذلك يمكننا أن نستخدم هذه القيمة عوضاً عن المتحول X. وقد تم تقدير b_1 بالقيمة 2.7607 (انظر جدول المتحولات في المعادلة المبين في الخرج 4.6) وتم أخذ معامل الحد الثابت من نفس الجدول وقيمته 1.3437-. ويمكننا الآن حساب الأرجحية من المعادلة (15.6):

$$P(\text{event Y}) = \frac{1}{1+e^{-(b_0+b_1X_1)}} = \frac{1}{1+e^{-[-1.3437+(2.7607\times 0)]}} = 0.2069$$
$$P(\text{no event Y}) = 1 - P(\text{event Y}) = 1 - 0.2069 = 0.7931 \qquad (15.6)$$
$$\text{odds} = \frac{P(\text{event Y})}{P(\text{no event Y})} = \frac{0.2069}{0.7931} = 0.2609$$

نقوم الآن بنفس الحسابات بعد تغيير المتحول التنبؤي بمقدار الوحدة. في هذه الحالة، ولأن المتحول ثنائي فإننا سنحسب الأرجحية لينجح الطفل في مهمة قاعدة التعبير مع العلم أنه قد نجح في مهمة الاعتقاد الخاطئ. لذلك فإن قيمة متحول الفهم الخاطئ X هي 1 (بدلاً من 0)، وتبين المعادلة (16.6) نتائج الحسابات:

$$P(\text{event Y}) = \frac{1}{1+e^{-(b_0+b_1X_1)}} = \frac{1}{1+e^{-[-1.3437+(2.7607\times 1)]}} = 0.8049$$
$$P(\text{no event Y}) = 1 - P(\text{event Y}) = 1 - 0.8049 = 0.1951 \qquad (16.6)$$
$$\text{odds} = \frac{P(\text{event Y})}{P(\text{no event Y})} = \frac{0.8049}{0.1951} = 4.1256$$

نعلم الآن قيم الأرجحية قبل وبعد التغير بمقدار الوحدة في المتحول التنبؤي. لذلك يمكننا بسهولة حساب التغير المتناسب في الأرجحية وذلك بتقسيم الأرجحية بعد التغير بمقدار الوحدة في المتحول التنبؤي على الأرجحية قبل التغير:

$$\Delta Odds = \frac{\text{الأرجحية بعد التغير بمقدار الوحدة في المتحول التنبؤي}}{\text{الأرجحية الأصلية}}$$

$$= \frac{4.1256}{0.2609} = 15.8129 \qquad (17.6)$$

يجب أن تلاحظ أن قيمة التغير المتناسب في الأرجحية هي نفس القيمة التي يعطيها برنامج SPSS للقيمة Exp(B). يمكننا تفسير Exp(B) حسب التغير في الأرجحية. إذا كانت القيمة أكبر من 1 فإن ذلك يدل على أنه عند ازدياد المتحول التنبؤي تزداد أرجحية حدوث النتيجة. وبالعكس إذا كانت القيمة أصغر من 1 فإن ذلك يدل على أنه عند ازدياد المتحول التنبؤي تنخفض أرجحية حدوث النتيجة. وفي هذا المثال يمكننا القول أن أرجحية أن يكون الطالب الناجح في فهم الاعتقاد الخاطئ ناجحاً أيضاً في فهم قاعدة التعبير هي أكبر بـــ 15 مرة من فشله في فهم الاعتقاد الخاطئ.

أثناء ضبط الخيارات (انظر الفقرة 5.4.6) طلبنا مجال الثقة للمقدار Exp(B) ولذلك نجده في الخرج. والطريقة لتفسير مجال الثقة هي القول أنه إذا نفّذنا 100 تجربة وحسبنا مجالات الثقة لقيمة Exp(B) فإن هذه المجالات ستحيط بالقيمة الفعلية للمقدار Exp(B) في المجتمع (بدلاً من العينة) في 95 مرة. لذلك فإنه في هذه الحالة، يمكننا أن نكون على ثقة بأن قيمة Exp(B) للمجتمع ستقع بين 4.84 و51.71. وعلى كل حال، فإن هناك احتمال 5% بأن تعطي عينة ما مجال ثقة لا يحوي القيمة الصحيحة.

يحوي (الخرج 5.6) إحصائيات الاختبار للمتحول fb إذا تمت إزالته من النموذج. لقد شرحنا سابقاً كيف يقوم التراجع بوضع المتحولات في المعادلة ثم يقوم باختبار لمعرفة فيما إذا كانت تحقق معيار الإزالة. يخبرنا القسم Model if Term Removed (النموذج إذا تمت إزالة الحد) بآثار الحذف. إن أهم ما يجب ملاحظته هو قيمة الدلالة لنسبة لوغاريتم الاحتمال (Log LR). إن قيمة Log LR لهذا النموذج عالية الدلالة ($p<0.0001$) مما يدل على أن إزالة fb من النموذج سيكون لها أثر كبير على المقدرة التوقعية للنموذج، وبعبارة أخرى فإن إزالة هذا المتحول هي فكرة سيئة جداً.

أخيراً، يخبرنا الخرج عن المتحولات غير الموجودة حالياً في النموذج. وتدلنا إحصائية كاي مربع للباقي (وتسمى الإحصائيات الإجمالية Overall Statistic في الخرج)، وهي بدون دلالة، على عدم وجود متحولات باقية ذات معاملات مختلفة كثيراً عن الصفر. كما يتم عرض كل متحول مع إحصائية العلامة الخاصة به وقيمة الدلالة، ومن أجل المتحولين يتم عرض معاملاتهما التي لا تختلف كثيراً عن الصفر (كما تدل قيم الدلالة حيث نجد 0.128 لمتحول العمر age و0.126 للتفاعل المتبادل بين العمر وفهم الاعتقاد الخاطئ). ولذلك لن تتم إضافة أية متحولات جديدة إلى المعادلة.

Model if Term Removed

Variable		Model Log Likelihood	Change in -2 Log Likelihood	df	Sig. of the Change
Step 1	fb	-48.062	26.083	1	.000

Variables not in the Equation

			Score	df	Sig.
Step 1	Variables	age	2.313	1	.128
		age by fb(1)	1.260	1	.262
	Overall Statistics		2.521	2	.284

الخرج 5.6

يعرض القسم التالي من (الخرج 6.6) مخطط التصنيف الذي طلبناه في مربع الحوار Options. وهذا المخطط هو مخطط تكراري للاحتمالات المتوقعة لينجح الطفل في مهمة قاعدة التعبير. إذا كان النموذج يوافق البيانات بشكل مثالي، فإن هذا المخطط البياني يجب أن يعرض جميع الحالات التي يحدث فيها الحدث على الجانب الأيمن وجميع الحالات التي لم يحدث فيها الحدث على الجانب الأيسر. وبعبارات أخرى، جميع الأطفال الذين نجحوا في مهمة قاعدة التعبير يجب أن تظهر حالتهم في الجانب الأيمن، وجميع الأطفال الذين فشلوا يجب أن تظهر حالتهم في الجانب الأيسر. في هذا المثال، فإن المتحول التنبؤي الوحيد المهم هو ثنائي ولذلك فهناك عمودان فقط للحالات على المخطط. إذا كان المتحول التنبؤي مستمراً فإن الحالات تكون منتشرة على عدة أعمدة. وكقاعدة عملية يمكن أن نقول، كلما كانت الحالات محتشدة في أحد طرفي المخطط كان ذلك أفضل. وهذه العبارة صحيحة لأن مثل هذا المخطط سيبين أنه عندما تحدث النتيجة فعلياً (أي أن الطفل ينجح في مهمة قاعدة التعبير) فإن الاحتمالات المتوقعة لحدوث الحدث تكون مرتفعة أيضاً (قريبة من القيمة 1). وعند الطرف الآخر للمخطط فإن المخطط سيبين أنه عندما لا يحدث الحدث (أي أن الطفل يفشل في مهمة قاعدة التعبير) فإن الاحتمالات المتوقعة لحدوث الحدث تكون منخفضة أيضاً (قريبة من القيمة 0). وهذه الحالة تمثل نموذجاً يتوقع بشكل صحيح بيانات النتيجة المشاهدة. وعلى كل حال، إذا كان هناك عدد من النقاط المحتشدة في وسط المخطط فإن ذلك يبين أنه من أجل عدد من الحالات فإن النموذج يتوقع احتمالاً قدره 0.5 بأن الحدث سيحدث. وبعبارة أخرى، من أجل هذه الحالات هناك احتمال أكبر بقليل من 50:50 بأن البيانات متوقعة بشكل صحيح. ومع أن النموذج الجيد يضمن أن عدداً قليلاً من الحالات سيكون تصنيفه غير صحيح، ففي هذا المثال هناك حالتي N (لا) على يمين النموذج وحالة Y (نعم) على يسار النموذج. هناك عدد من الحالات المصنفة بشكل غير صحيح، وكلما كان عدد هذه الحالات أقل كان النموذج أفضل.

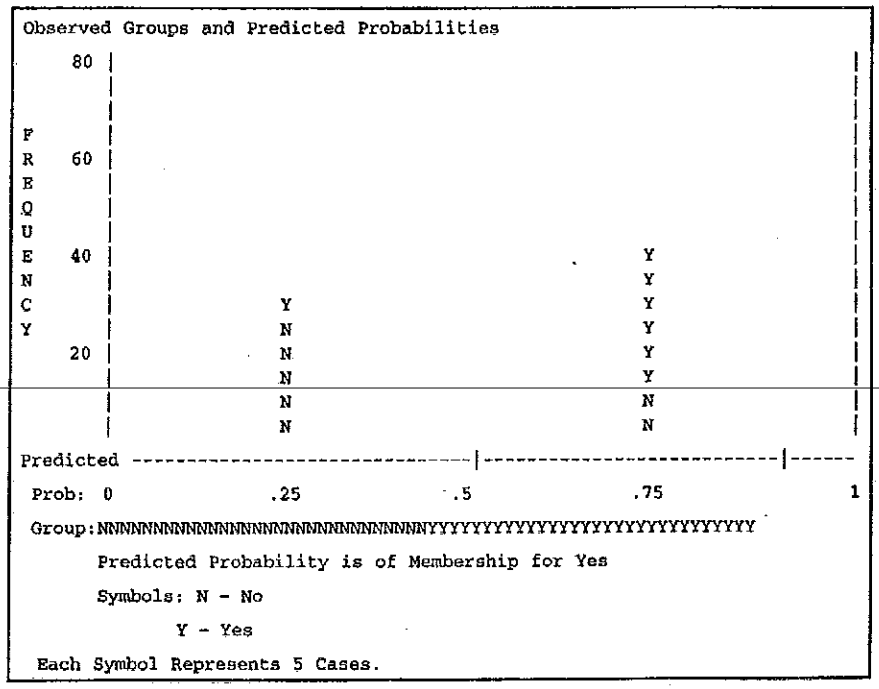

الخرج 6.6

أفكار مفيدة

- إن التوافق الإجمالي للنموذج النهائي تبينه إحصائية 2LL- وإحصائية كاي مربع المرتبطة بها. إذا كان مستوى الدلالة لإحصائية كاي مربع أقل من 0.05 فإن النموذج يتوافق بشكل جيد مع البيانات.
- تحقق من الجدول المسمى Variables in the Equation (المتحولات في المعادلة) لمعرفة المتحولات التي تتوقع النتيجة بشكل فعال.
- من أجل متحول في النموذج، انظر إلى إحصائية Wald ومستوى دلالتها (التي يجب أن تكون أقل من 0.05). واستخدم قيمة Exp(B) للتفسير. إذا كانت القيمة أكبر من 1 فإنه عند ازدياد المتحول التنبؤي تزداد أرجحية حدوث الحدث، وبالعكس إذا كانت القيمة أصغر من 1 فإنه عند ازدياد المتحول التنبؤي تنخفض أرجحية حدوث الحدث. ولكي يكون التفسير السابق موثوقاً يجب أن لا يحوي مجال الثقة للمقدار Exp(B) القيمة 1.
- تحقق من الجدول المسمى Variables not in the Equation (المتحولات غير الموجودة في المعادلة) لمعرفة المتحولات التي لا تتوقع النتيجة بشكل فعّال.

3.5.6 عرض الاحتمالات المتوقعة

من الممكن عرض الاحتمالات المتوقعة لحدوث متحول النتيجة بناءً على النموذج النهائي. وقد رأينا في الفقرة 4.4.6 أنه يمكن لبرنامج SPSS حفظ البواقي وكذلك الاحتمالات المتوقعة. يقوم برنامج SPSS بحفظ هذه الاحتمالات المتوقعة وعناصر المجموعة المتوقعة كمتحولات في محرر البيانات ويسميها PRE_1 وPGR_1 على التوالي. يمكن عرض هذه الاحتمالات باستخدام مربع الحوار الذي يمكن الوصول إليه عبر أمر القائمة ...Analyze ⇒ Reports ⇒ Case Summaries (انظر الفقرة 6.8.5). يبين (الخرج 7.6) قسماً مختاراً من الاحتمالات المتوقعة (نظراً لأن المتحول التنبؤي المهم الوحيد هو متحول ثنائي فستكون هناك قيمتي احتمال مختلفتين فقط). ويمكن أيضاً عرض المتحولات التنبؤية لتوضيح مصدر الاحتمالات المتوقعة.

Case Summaries[a]

	Case Number	Age in years	False Belief understanding	Display Rule understanding	Predicted probability	Predicted group
1	1	24.00	No	No	.20690	No
2	5	36.00	No	No	.20690	No
3	9	34.00	No	Yes	.20690	No
4	10	31.00	No	No	.20690	No
5	11	32.00	No	No	.20690	No
6	12	30.00	Yes	Yes	.80488	Yes
7	20	26.00	No	No	.20690	No
8	21	29.00	No	No	.20690	No
9	29	45.00	Yes	Yes	.80488	Yes
10	31	41.00	No	Yes	.20690	No
11	32	32.00	No	No	.20690	No
12	43	56.00	Yes	Yes	.80488	Yes
13	60	63.00	No	Yes	.20690	No
14	66	79.00	Yes	Yes	.80488	Yes
Total N		14	14	14	14	14

a Limited to first 100 cases

الخرج 7.6

لقد وجدنا من النموذج أن المتحول التنبؤي الوحيد المهم في فهم قاعدة التعبير هو فهم الاعتقاد الخاطئ. ويمكن أن تكون قيمته 1 (النجاح في مهمة الاعتقاد الخاطئ) أو 0 (الفشل في مهمة الاعتقاد الخاطئ). إذا وضعنا هاتين القيمتين في المعادلة (4.6) مع معاملات التراجع المناسبة فإنه يمكن الحصول على قيمتي الاحتمال. لقد قمنا عملياً بحساب هذه القيم كجزء من المعادلة (15.6) والمعادلة (16.6) ويجب أن تلاحظ أن الاحتمالات المحسوبة توافق القيم للمتحول PRE_1. وتخبرنا هذه القيم أنه عندما لا ينجح الطفل في فهم الاعتقاد الخاطئ (fb=0، لا) فإن هناك احتمالاً قدره 0.2069 بأنه سينجح في مهمة قاعدة التعبير أي 20% تقريباً (طفل واحد من بين كل 5 أطفال). وعلى كل حال، إذا نجح الطفل في مهمة الاعتقاد الخاطئ (fb=1 ، نعم) فإن هناك احتمالاً قدره 0.8049 بأنه سينجح في مهمة قاعدة التعبير أي 80.5% تقريباً (4 أطفال من بين كل 5 أطفال).

إذا اعتبرنا أن الاحتمال 0 يدل على عدم وجود أمل في نجاح الطفل في مهمة قاعدة التعبير، والاحتمال 1 يدل على أن الطفل سينجح حتماً في مهمة قاعدة التعبير. ولذلك فإن القيم التي نحصل عليها توفر دليلاً قوياً لدور فهم الاعتقاد الخاطئ كتحصيل مسبق لفهم قاعدة التعبير. لنفترض أننا اقتنعنا بأن النموذج دقيق وأن لفهم الاعتقاد الخاطئ دلالة مهمة فإنه يمكننا أن نستنتج أن فهم الاعتقاد الخاطئ هو المتحول التنبؤي الأفضل والوحيد لفهم قاعدة التعبير. أما العمر والفعل المتبادل بين العمر وفهم الاعتقاد الخاطئ فليس لهما أي دور في توقع فهم قاعدة التعبير. ونقترح أن تقوم بإعادة تنفيذ هذا التحليل باستخدام طريقة الإدخال القسري للتحليل، هل ستتغير الاستنتاجات؟

إن الخلاصة جيدة بحد ذاتها، ولكن لكي نكون متأكدين من أن النموذج جيد، من المهم فحص البواقي. لقد رأينا في الفقرة 4.4.6 كيف يمكننا أن نطلب من برنامج SPSS حفظ البواقي في محرر البيانات. يمكننا الآن عرض هذه البواقي باستخدام مربع الحوار الذي نحصل عليه بتنفيذ أمر القائمة Analyze ⇒ Reports ⇒ Case Summaries... وتفسيرها.

4.5.6 تفسير البواقي

إن الأهداف الأساسية لفحص البواقي في التراجع المنطقي هي: (1) عزل النقاط التي يقوم النموذج بملاءمتها بشكل ضعيف. (2) عزل النقاط التي لها تأثير قوي على النموذج. ولتقييم الهدف الأول نقوم بفحص البواقي وخاصة إحصائيات باقي Studentized، والباقي المعياري، وإحصائية الحيدان (Deviance). ولجميع هذه الإحصائيات الخاصية المشتركة بأن 95% من الحالات في عينة موزعة طبيعياً تملك قيمة تقع في المجال ±1.96، وأن 99% من الحالات لها قيم واقعة في المجال ±2.58. ولذلك فإن أية قيمة تقع خارج المجال ±3 ستكون موضع اهتمام، أما القيم التي تقع خارج مجال ±2.5 فيجب فحصها عن قرب أكثر. ولتقييم تأثير الحالات المنفصلة فإننا نستخدم إحدى إحصائيات التأثير مثل مسافة Cook (التي يتم تفسيرها بنفس الطريقة كما في التراجع الخطي: إنها مقياس للتغيير في معامل التراجع إذا تم حذف حالة ما من النموذج). كما أن قيمة DFBeta التي هي نسخة معيارية من إحصائية Cook تخبرنا عن تأثير حالات معينة، فأي قيمة أكبر من 1 تدل على حالة مؤثرة محتملة. بالإضافة لذلك فإن إحصائية الفعالية أو قيم القبعة والتي يجب أن تقع بين 0 (عدم وجود تأثير للحالة) و 1 (الحالة ذات تأثير كامل على النموذج) تخبرنا عما إذا كانت بعض الحالات تمارس تأثير كبيراً على النموذج. يتم تعريف القيمة المتوقعة للفعالية كما في التراجع الخطي. وقد تم شرح هذه الإحصائيات بالتفصيل في الفصل 5.

إذا طلبت إحصائيات البواقي فإن برنامج SPSS سيحفظها كمتحولات في أعمدة جديدة في محرر البيانات، ويعرض (الجدول 2.6) أسماء هذه المتحولات وماذا تمثل. إضافةً لتعليق يلخص القيم المتوقعة لهذه الإحصائيات.

التسمية	الاسم	التعليق
PRE_1	القيمة المتوقعة	
PGR_1	المجموعة المتوقعة	
COO_1	مسافة كوك	يجب أن تكون أصغرمن 1
LEV_1	الفعالية	تقع بين 0 (عدم التأثير) و 1 (تأثير كامل). تحسب الفعالية المتوقعة من المعادلة (k+1)/N حيث k عدد المتحولات التنبؤية، و N حجم العينة. وفي هذا المثال يجب أن تكون قيمتها 2/70=0.03
RES_1	الباقي	
LRE_1	اللوغاريتم الطبيعي للباقي	
SRE_1	الباقي Studentized	يجب أن تقع 5% في المجال 1.96±، و يجب أن تقع 1% في المجال 2.58± أما الحالات التي تكون أكبر من 3 فهي مصدر قلق، والحالات القريبة من 3 تستدعي الفحص والتفتيش.
ZRE_1	الباقي المعياري	
DEV_1	الحيدان	
DFB0_1	DFBeta للحد الثابت	يجب أن تكون أصغر من 1
DFB1_1	DFBeta للمتحول التنبؤي الأول (fb)	

الجدول 2.6 ملخص لإحصائيات البواقي التي يحفظها برنامج SPSS

يعرض (الخرج 8.6) إحصائيات الباقي الأساسية لهذا المثال (مسافة Cook، الفعالية، البواقي المعياري وقيم DFBeta). لاحظ أن جميع الحالات تملك قيم DFBeta أصغر من 1، وإحصائيات الفعالية (LEV_1) قريبة من القيمة المتوقعة المحسوبة 0.03. وليست هناك قيم كبيرة غير عادية لمسافة Cook (COO_1) وهذا يعني عدم وجود حالات مؤثرة على النموذج. إن مسافة Cook ليست قياساً معيارياً ولذلك لا توجد قيمة مطلقة يمكن اعتمادها لكي نقول أن لحالة ما تأثير على النموذج. وبدلاً من ذلك يمكنك البحث عن قيم مسافة Cook التي تكون كبيرة مقارنةً بالقيم للحالات الأخرى في العينة. وقد اقترح Stevens (1992) أنه عندما تكون القيمة أكبر من 1 فإنها تكون إشكالية. إن أكثر من نصف قيم الفعالية هي مرتفعة قليلاً ولكن بما أن الإحصائيات الأخرى جيدة فربما لا يوجد أي سبب للقلق.

لجميع البواقي المعيارية قيم أصغر من المجال 2.5±، ومعظمها أصغر من 2±، ولهذا لا يوجد سبب للقلق. يجب أن تلاحظ أن هذه البواقي غير عادية نوعاً ما وذلك لأنها تعتمد على متحول تنبؤي وحيد وهو متحول فئوي. ولهذا السبب لا توجد تغايرية كبيرة في قيم البواقي. وإذا تم عزل القيم المنعزلة أو الحالات المؤثرة فهذا لا يبرر حذف تلك الحالات لجعل النموذج أفضل توافقاً. وإنما يجب دراسة هذه الحالات بشكل معمّق لمحاولة معرفة السبب الحقيقي لكونها منعزلة أو غير عادية. ربما يكون السبب خطأ في إدخال البيانات أو قد تكون الحالة المعنية هي إحدى الحالات التي هناك

سبب معين لكونها غير عادية فربما كان الطفل غير منتبه لمهمة الاعتقاد الخاطئ وتكون قد لاحظت ذلك أثناء تنفيذ التجربة. في مثل هذه الحالة، قد يكون لديك سبب وجيه لاستثناء تلك الحالة مع ذكر سبب الحذف.

أفكار مفيدة: يجب النظر إلى الحالات التي قد تؤثر على نموذج التراجع المنطقي.

- التحقق من قيم البواقي المعيارية: يجب أن لا تزيد نسبة البواقي التي تتجاوز قيمتها المطلقة 2 عن 5%، وأن لا تزيد نسبة البواقي التي تتجاوز قيمتها المطلقة 2.5 عن 1%. أما الحالات التي تكون قيمة الباقي المعياري لها أكبر من 3 فتعتبر نقطة منعزلة.
- البحث في محرر البيانات عن قيم مسافة Cook: أي قيمة أكبر من 1 تدل على أن الحالة قد تكون مؤثرة على النموذج.
- حساب الفعالية الوسطى (عدد المتحولات التنبؤية +1 مقسوماً على حجم العينة) والبحث عن القيم التي تكون أكبر من ضعفي أو ثلاثة أضعاف هذه القيمة الوسطى.
- البحث عن القيم المطلقة للإحصائية DFBeta التي تكون أكبر من 1.

5.5.6 حساب حجم الأثر

لقد رأينا في الفقرة 2.3.6 أن برنامج SPSS يعطي قيمة R لكل من المتحولات التنبؤية، بناءً على إحصائية Wald. وهذا هو مقياس حجم الأثر، ويجب أن لا تنسى أننا ذكرنا سابقاً أنه لن يكون دقيقاً عندما تكون إحصائية Wald غير دقيقة.

6.6 كيفية تقديم التراجع المنطقي

نظراً لقلة استخدام التراجع المنطقي فمن الصعب العثور على أية توجيهات حول طريقة تقديمه. لذلك فإن ما تراه هنا هو وجهة نظر شخصية حول ما يجب تقديمه بناءً على توجيهات الجمعية الأميركية لعلماء النفس في تقديم التراجع المتعدد (انظر الفقرة 9.5). وكما في حالة التراجع المتعدد فإننا نفضل تقديم النتائج بشكل جدولي ما لم يكن النموذج بسيطاً جداً. وكحد أدنى يجب تقديم قيم بيتا والخطأ المعياري المرتبط بها وقيمة الدلالة وبعض الإحصائيات العامة حول النموذج (مثل R^2 وإحصائية جودة التوافق). كما ننصح بتقديم Exp(B) ومجال الثقة لها. وكذلك وضع الحد الثابت لأن بعض القرّاء قد يرغبون بإعادة بناء نموذج التراجع بكامله. قد ترغب أيضاً بتقديم المتحولات غير المعتبرة في النموذج وهي بأهمية المتحولات التنبؤية المهمة في النموذج 0 ومن أجل المثال في هذا الفصل فإن (الجدول 3.6) يقدم هذا التراجع المنطقي.

Case Summaries[a]

	Case Number	Analog of Cook's influence statistics	Leverage value	Normalized residual	DFBETA for constant	DFBETA for fo(1)
1	1	.00932	.03448	-.51075	-.04503	.04503
2	2	.00932	.03448	-.51075	-.04503	.04503
3	3	.00932	.03448	-.51075	-.04503	.04503
4	4	.00932	.03448	-.51075	-.04503	.04503
5	5	.00932	.03448	-.51075	-.04503	.04503
6	6	.13690	.03448	1.95789	.17262	-.17262
7	7	.00932	.03448	-.51075	-.04503	.04503
8	8	.00932	.03448	-.51075	-.04503	.04503
9	9	.13690	.03448	1.95789	.17262	-.17262
10	10	.00932	.03448	-.51075	-.04503	.04503
11	11	.00932	.03448	-.51075	-.04503	.04503
12	12	.00606	.02439	.49237	.00000	.03106
13	13	.00932	.03448	-.51075	-.04503	.04503
14	14	.10312	.02439	-2.03101	.00000	-.12812
15	15	.00932	.03448	-.51075	-.04503	.04503
16	16	.00932	.03448	-.51075	-.04503	.04503
17	17	.13690	.03448	1.95789	.17262	-.17262
18	18	.00932	.03448	-.51075	-.04503	.04503
19	19	.00606	.02439	.49237	.00000	.03106
20	20	.00932	.03448	-.51075	-.04503	.04503
21	21	.00932	.03448	-.51075	-.04503	.04503
22	22	.00606	.02439	.49237	.00000	.03106
23	23	.00606	.02439	.49237	.00000	.03106
24	24	.10312	.02439	-2.03101	.00000	-.12812
25	25	.00932	.03448	-.51075	-.04503	.04503
26	26	.00932	.03448	-.51075	-.04503	.04503
27	27	.00932	.03448	-.51075	-.04503	.04503
28	28	.00932	.03448	-.51075	-.04503	.04503
29	29	.00606	.02439	.49237	.00000	.03106
30	30	.00932	.03448	-.51075	-.04503	.04503
31	31	.13690	.03448	1.95789	.17262	-.17262
32	32	.00932	.03448	-.51075	-.04503	.04503
33	33	.00606	.02439	.49237	.00000	.03106
34	34	.00606	.02439	.49237	.00000	.03106
35	35	.00606	.02439	.49237	.00000	.03106
36	36	.00606	.02439	.49237	.00000	.03106
37	37	.10312	.02439	-2.03101	.00000	-.12812
38	38	.00606	.02439	.49237	.00000	.03106
39	39	.13690	.03448	1.95789	.17262	-.17262
40	40	.10312	.02439	-2.03101	.00000	-.12812
41	41	.00606	.02439	.49237	.00000	.03106
42	42	.00606	.02439	.49237	.00000	.03106
43	43	.00606	.02439	.49237	.00000	.03106
44	44	.00606	.02439	.49237	.00000	.03106
45	45	.00606	.02439	.49237	.00000	.03106
46	46	.10312	.02439	-2.03101	.00000	-.12812
47	47	.00606	.02439	.49237	.00000	.03106
48	48	.00932	.03448	-.51075	-.04503	.04503
49	49	.00932	.03448	-.51075	-.04503	.04503
50	50	.10312	.02439	-2.03101	.00000	-.12812
51	51	.00606	.02439	.49237	.00000	.03106
52	52	.00606	.02439	.49237	.00000	.03106
53	53	.00606	.02439	.49237	.00000	.03106
54	54	.00606	.02439	.49237	.00000	.03106
55	55	.00606	.02439	.49237	.00000	.03106
56	56	.00606	.02439	.49237	.00000	.03106
57	57	.10312	.02439	-2.03101	.00000	-.12812
58	58	.00606	.02439	.49237	.00000	.03106
59	59	.00606	.02439	.49237	.00000	.03106
60	60	.13690	.03448	1.95789	.17262	-.17262
61	61	.00606	.02439	.49237	.00000	.03106
62	62	.00606	.02439	.49237	.00000	.03106
63	63	.00606	.02439	.49237	.00000	.03106
64	64	.00606	.02439	.49237	.00000	.03106
65	65	.00606	.02439	.49237	.00000	.03106
66	66	.00606	.02439	.49237	.00000	.03106
67	67	.00606	.02439	.49237	.00000	.03106
68	68	.10312	.02439	-2.03101	.00000	-.12812
69	69	.00606	.02439	.49237	.00000	.03106
70	70	.00606	.02439	.49237	.00000	.03106
Total N	70	70	70	70	70	70

a. Limited to first 100 cases.

الخرج 8.6

	B(SE)	95% من مجال الثقة للمقدار Exp(B)		
		الحد الأدنى	Exp(B)	الحد الأعلى
المضمنة				
الحد الثابت	-1.34*	4.84	15.81	51.71
	(0.46)			
فهم الاعتقاد الخاطئ	2.76**			
	(0.60)			

الجدول 3.6 كيفية تقديم التراجع المنطقي

ملاحظة: قيم R^2 هي 0.27 (Hosmer & Lemeshow) و0.31 (Cox & Snell) و 0.42 (Nagelkerke). $\chi^2(1)=26.08$, $p<0.001$, *$p<0.01$, **$p<0.001$ للنموذج

كما في حالة التراجع المتعدد، لقد قمنا بتدوير الأرقام لمترلتين عشريتين، وتم وضع (*) و(**) لتقديم مستوى الدلالة للمتحول مع حاشية سفلية للإشارة لمستوى الدلالة المستخدم.

7.6 مثال آخر

هذا المثال مستوحى من نهائيات كأس العالم لكرة القدم لعام 1998 حيث خرج الفريق الانكليزي من النهائيات لعدم نجاحه في تسديد ضربة جزاء، وتكررت هذه المأساة في نهائيات كأس الأمم الأوربية في عام 2004.

لو كنت المدرب الانكليزي، ربما بحثت عن العوامل التي تتوقع أن يسجل لاعب ما ضربة الجزاء. وهذه المسألة هي مثالية للتراجع المنطقي لأن متحول النتيجة ثنائي، إذ يمكن تسجيل هدف من ضربة الجزاء أو عدم تسجيل الهدف. وقد أظهرت الأبحاث السابقة أن هناك عاملين يتوقعان بشكل موثوق فيما إذا كانت ضربة الجزاء ستكون هدفاً أم لا. العامل الأول هو فيما إذا كان اللاعب الذي يسدد ضربة الجزاء مضطرباً (يمكن قياس هذا العامل باستخدام استبيان Pen State Worry والذي يدعى اختصاراً PSWQ). والعامل الثاني هو معدل النجاح السابق لهذا اللاعب في تسجيل الأهداف من ضربات الجزاء. ومقبول تماماً أن للقلق آثاراً ضارة على الأداء في مهمات متنوعة ولذلك فمن المتوقع أن تساهم حالة القلق في التباين غير المبرر في النجاح بتسديد ضربة الجزاء.

وهذا المثال هو حالة تقليدية لبناء نموذج جيد لأننا نعرف اثنين من المتحولات التنبؤية، ونريد اختبار أثر متحول جديد. لذلك تم اختيار 75 لاعب كرة قدم بشكل عشوائي، وقبل تسديدهم لضربة جزاء في مباراة معينة طُلب منهم الإجابة على استبيان حالة القلق (لتقييم حالة القلق قبل تسديد ضربة الجزاء). كما طُلب من هؤلاء اللاعبين الإجابة على الاستبيان PSWQ لقياس مدى اضطرابهم وتخوفهم من الأشياء بشكل عام، أما معدل نجاحهم السابق في تسديد ضربات الجزاء فقد تم الحصول عليه من قاعدة بيانات. أخيراً تم وضع ملاحظة حول نجاح أو فشل ضربة الجزاء. يحوي

الملف Penalty.sav على القرص المضغوط المرفق هذه البيانات، ويحوي 4 متحولات، كل منها في عمود منفصل:

- **Scored:** متحول النتيجة وقد تم ترميزه بالشكل 0=عدم نجاح ضربة الجزاء، 1=نجاح ضربة الجزاء.
- **PSWQ:** المتحول التنبؤي الأول، ويحوي درجة اضطراب اللاعب.
- **Previous:** المتحول التنبؤي الثاني، وهو النسبة المئوية لضربات الجزاء الناجحة للاعب معين خلال مرحلة احترافه. ويمثل إذاً النجاح السابق في تسديد ضربات الجزاء.
- **Anxious:** المتحول التنبؤي الثالث، وهو المتحول الذي لم يستخدم في التنبؤ بنجاح ضربة الجزاء. يقيس Anxious حالة القلق للاعب ما قبل تسديد ضربة الجزاء.

1.7.6 تنفيذ التحليل: التراجع ذو الإدخال الكتلي

لتنفيذ التحليل، يجب علينا أولاً اختيار مربع الحوار الرئيسي للتراجع المنطقي وذلك بتنفيذ أمر القائمة Analyze ⇒ Regression ⇒ Binary Logistic... في هذا المثال، نعرف أهمية اثنين من المتحولات التنبؤية ولذلك يمكننا أن ندخل هذين المتحولين في النموذج ضمن كتلة واحدة. يمكننا بعد ذلك إضافة المتحول التنبؤي الجديد في كتلة ثانية (وبذلك نقوم عملياً بفحص نموذج قديم ثم إضافة متحول جديد إلى النموذج لمعرفة فيما إذا النموذج قد تحسّن). تُعرف هذه الطريقة بالإدخال الكتلي ويبين (الشكل 8.6) كيفية تحديده.

من السهل تنفيذ التراجع ذو الإدخال الكتلي. نقوم أولاً باختيار المتحول scored من المتحولات في القسم الأيسر من مربع الحوار وننقله إلى الحيز المسمى Dependent بنقر زر السهم بين القسمين. ثم نقوم باختيار المتحولين المعروفين سابقاً بأهميتهما وهما PSWQ وPrevious وننقلهما إلى الحيز المسمى Covariates. لقد تم تحديد الكتلة الأولى من المتحولات، ولتعريف الكتلة الثانية ننقر الزر Next لتنظيف الحيز Covariates حيث تظهر عبارة Block 2 of 2. نختار المتحول anxious من لائحة المتحولات في القسم الأيسر وننقله إلى الحيز المسمى Covariates. نستطيع في هذه المرحلة تضمين بعض التفاعلات المتبادلة في النموذج، ولكن ما لم يكن هناك سبب نظري وجيه للاعتقاد بوجود تفاعل بين المتحولات التنبؤية فلا داعي لإدخال مثل تلك التفاعلات. تأكد من اختيار الطريقة Enter كطريقة للتراجع (إنها الطريقة الافتراضية ويجب أن تكون محددة سلفاً).

بعد تحديد المتحولات، يجب تحديد الخيارات التي تم وصفها في الفقرتين 4.4.6 و 5.4.6 ولكن بما أن المتحولات التنبؤية غير فئوية فلا حاجة لاستخدام الخيار Categorial... بعد اختيار الخيارات والبواقي التي تريدها يمكنك العودة إلى مربع الحوار الرئيسي للتراجع المنطقي ونقر الزر OK.

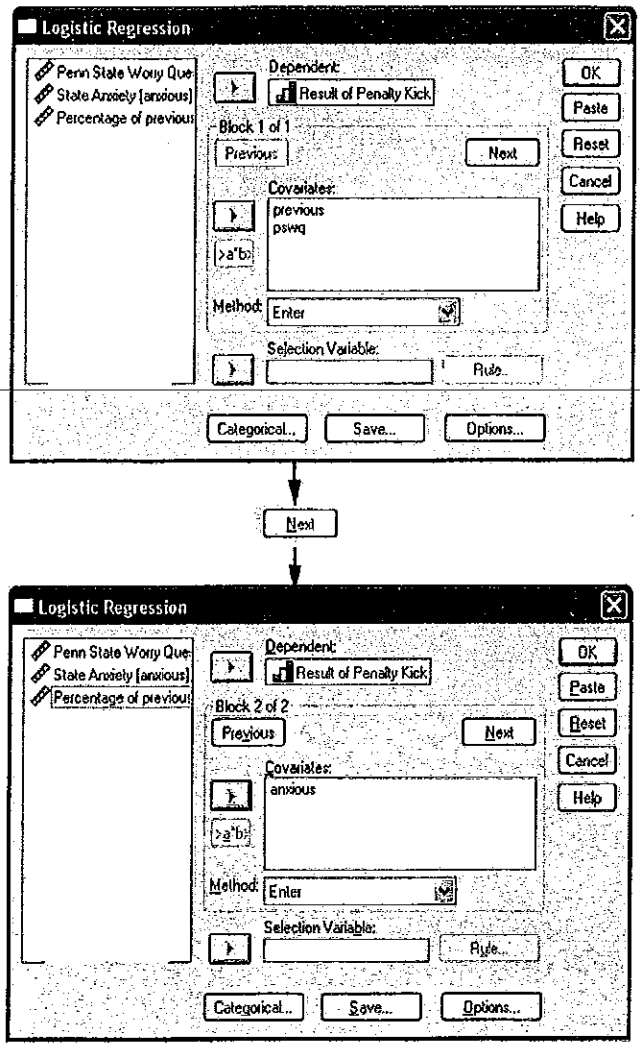

الشكل 8.6 طريقة الإدخال الكتلي للتراجع

2.7.6 تفسير الخرج

يتم ترتيب الخرج للتراجع المنطقي حسب الكتل التي تم تحديدها. وبعبارة أخرى، يقوم برنامج SPSS بإنتاج نموذج التراجع للمتحولات المحددة في الكتلة الأولى ثم إنتاج نموذج ثان يحوي المتحولات للكتلتين 1 و2. يعرض الخرج 9.6 النتائج من الكتلة 0، ويخبرنا بأن 75 حالة تم قبولها وأن المتحول التابع (النتيجة) قد تم ترميزه بالقيم 0 و1 (لأن هذا المتحول قد تم ترميزه بالقيم 0 و1 في محرر البيانات، ويوافق هذا الترميز تماماً البيانات في SPSS). كما يُعلمنا بالمتحولات الموجودة ضمن المعادلة وخارجها. وفي هذه المرحلة فقد تم تضمين الحد الثابت فقط في النموذج، وهي معلومات غير مهمة.

Dependent Varible Encoding

Original Value	Internal Value
Missed Penalty	0
Scored Penalty	1

Block 0: Beginning Block

Classification Table[a,b]

			Predicted		
			Result of Penalty Kick		
	Observed		Missed Penalty	Scored Penalty	Percentage Correct
Step 0	Result of Penalty Kick	Missed Penalty	0	35	.0
		Scored Penalty	0	40	100.0
	Overall Percentage				53.3

a. Constant is included in the model.

b. The cut value is .500

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)
Step 0	Constant	.134	.231	.333	1	.564	1.143

Variables not in the Equation

			Score	df	Sig.
Step 0	Variables	previous	34.109	1	.000
		pswq	34.193	1	.000
	Overall Statistics		41.558	2	.000

الخرج 9.6

يعرض الخرج 10.6 النتائج من الكتلة 1، وفي هذا التحليل أجبرنا برنامج SPSS على إدخال المتحولين PSWQ و previous في نموذج التراجع. ولذلك فإن هذا القسم من الخرج يوفر المعلومات عن النموذج بعد إضافة المتحولين PSWQ و previous. وأول ما يجب ملاحظته هو أن قيمة 2LL- تبلغ 48.66 وهي تغيرٌ بمقدار 54.98 (وهي القيمة المعطاة بإحصائية كاي مربع للنموذج). تخبرنا هذه القيمة عن النموذج ككل حيث يدل السطر block على مدى التحسن في النموذج منذ الكتلة السابقة. إن التغير في مقدار المعلومات المبررة من قبل النموذج ذو دلالة ($p<0.0001$) ولذلك فإن استخدام الاضطراب والخبرة السابقة للاعب كمتحولات هامة قد حسّن مقدرتنا على التنبؤ بنجاح ضربة الجزاء. يعرض القسم قبل الأخير من الخرج جدول التصنيف الذي يبين أن 84% من الحالات يمكن تصنيفها بشكل صحيح باستخدام المتحولين PSWQ و previous.

في المثال السابق الخاص بقاعدة التعبير، لم يقدم برنامج SPSS اختبار Hosmer & Lemeshow لجودة التوافق وذلك لأنه لا يمكن حساب هذا الاختبار عند وجود متحول تنبؤي وحيد، وهذا المتحول فئوي ثنائي! أما في هذا المثال فيمكن حساب هذا الاختبار. إن الجزء الهام من هذا الاختبار هو إحصائية الاختبار بحد ذاتها (7.93) وقيمة الدلالة (0.339). تختبر هذه الإحصائية فرضية أن البيانات المشاهدة مختلفة بشكل كبير عن القيم المتوقعة من قبل النموذج. لذلك فإننا نريد قيمة غير مهمة لهذا الاختبار. ولدينا قيمة غير مهمة مما يدل على أن النموذج يتوقع بيانات العالم الحقيقي بشكل جيد. يخبرنا الجزء المسمى Variables in the Equation (المتحولات في المعادلة) في الخرج 10.6 ببارامترات النموذج عند استخدام PSWQ وprevious كمتحولات تنبؤية. وتشير قيم الدلالة لإحصائية Wald لكل متحول تنبؤي على أن كلا المتحولين PSWQ وprevious يتوقعان بشكل جيد نجاح ضربة الجزاء ($p<0.01$). وتشير قيمة Exp(B) للمتحول previous إلى انه إذا ارتفعت النسبة المئوية للنجاح السابق في تسديد ضربات الجزاء بمقدار 1 فإن أرجحية تسجيل هدف من ضربة الجزاء ترتفع أيضاً (لأن قيمة Exp(B) أكبر من 1). ويتراوح مجال الثقة لهذه القيمة بين 1.02 و1.11 لذلك يمكن أن نكون واثقين جداً بأن قيمة Exp(B) في المجتمع ستقع بين هاتين القيمتين. وبما أن القيمتين أكبر من 1 فإننا واثقون بأن العلاقة بين previous ونجاح ضربة الجزاء في هذه العينة هي علاقة صحيحة لمجتمع لاعبي كرة القدم بكامله. تشير قيمة Exp(B) للمتحول PSWQ إلى أنه إذا ارتفع مستوى الاضطراب بنقطة واحدة على مقياس الاضطراب Pen State فإن أرجحية تسجيل ضربة الجزاء تنخفض (لأن قيمة Exp(B) أصغر من 1). ويتراوح مجال الثقة لهذه القيمة بين 0.68 و 0.93 لذلك يمكن أن نكون واثقين جداً بأن قيمة Exp(B) في المجتمع ستقع بين هاتين القيمتين. بالإضافة لذلك وبما أن هاتين القيمتين أصغر من 1 فإننا واثقون بأن العلاقة بين PSWQ ونجاح ضربة الجزاء في هذه العينة هي علاقة صحيحة لمجتمع لاعبي كرة القدم بكامله. إذا وجدنا أن مجال الثقة يتراوح بين قيمة أصغر من 1 إلى قيمة أكبر من 1 فإن ذلك سيحد من تعميم النتائج التي نحصل عليها لأن قيمة Exp(B) في المجتمع تدل إما على علاقة طردية (Exp(B)>1) أوعلاقة عكسية (Exp(B)<1).

إن النظر إلى مخطط التصنيف (الخرج 11.6) يفيدنا بأخبار سارة أيضاً وذلك لأن معظم الحالات محتشدة عند أحد طرفي المخطط، وهناك عدة حالات فقط في منتصف المخطط. وهذا يكرر ما نعلمه سابقاً، وهو أن النموذج يصنف معظم الحالات بشكل صحيح. ويمكننا في هذه المرحلة حساب R^2 (انظر الفقرة 2.3.6) بتقسيم إحصائية كاي مربع للنموذج على قيمة 2LL- الأصلية. وتبين المعادلة (18.6) هذه النتيجة ويمكننا تفسيرها بأن النموذج يمكن أن يساهم بمقدار 53% من التباين في نجاح ضربة الجزاء (أي أن نصف ما يجعل ضربة الجزاء ناجحة مازال غير معروف):

$$R^2 = \frac{model\ chi\text{-}square}{original\ -2LL} = \frac{54.977}{103.6385} = 0.53 \qquad (18.6)$$

Block 1: Method=Enter

Omnibus Tests of Model Coefficients

		Chi-square	df	Sig.
Step 1	Step	54.977	2	.000
	Block	54.977	2	.000
	Model	54.977	2	.000

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	48.662[a]	.520	.694

a. Estimation terminated at iteration number 6 because parameter estimates changed by less than .001.

Hosmer and Lemeshow Test

Step	Chi-square	df	Sig.
1	7.931	7	.339

Contingency Table for Hosmer and Lemeshow Test

		Result of Penalty Kick =Missed Penalty		Result of Penalty Kick =Scored Penalty		
		Observed	Expected	Observed	Expected	Total
Step 1	1	8	7.904	0	.096	8
	2	8	7.779	0	.221	8
	3	8	6.705	0	1.295	8
	4	4	5.438	4	2.562	8
	5	2	3.945	6	4.055	8
	6	2	1.820	6	6.180	8
	7	2	1.004	6	6.996	8
	8	1	.298	7	7.702	8
	9	0	.108	11	10.892	11

Classification Table[a]

			Predicted		
			Result of Penalty Kick		
	Observed		Missed Penalty	Scored Penalty	Percentage Correct
Step 1	Result of Penalty Kick	Missed Penalty	30	5	85.7
		Scored Penalty	7	33	82.5
	Overall Percentage				84.0

a. The cut value is .500

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)	95.0% C.I.for EXP(B)	
								Lower	Upper
Step 1[a]	previous	.085	.022	8.609	1	.003	1.087	1.022	1.114
	pswq	.230	.080	8.309	1	.004	.794	.679	.929
	Constant	1.280	1.670	.588	1	.443	3.598		

a. Variable(s) entered on step 1: previous, pswq.

الخرج 10.6

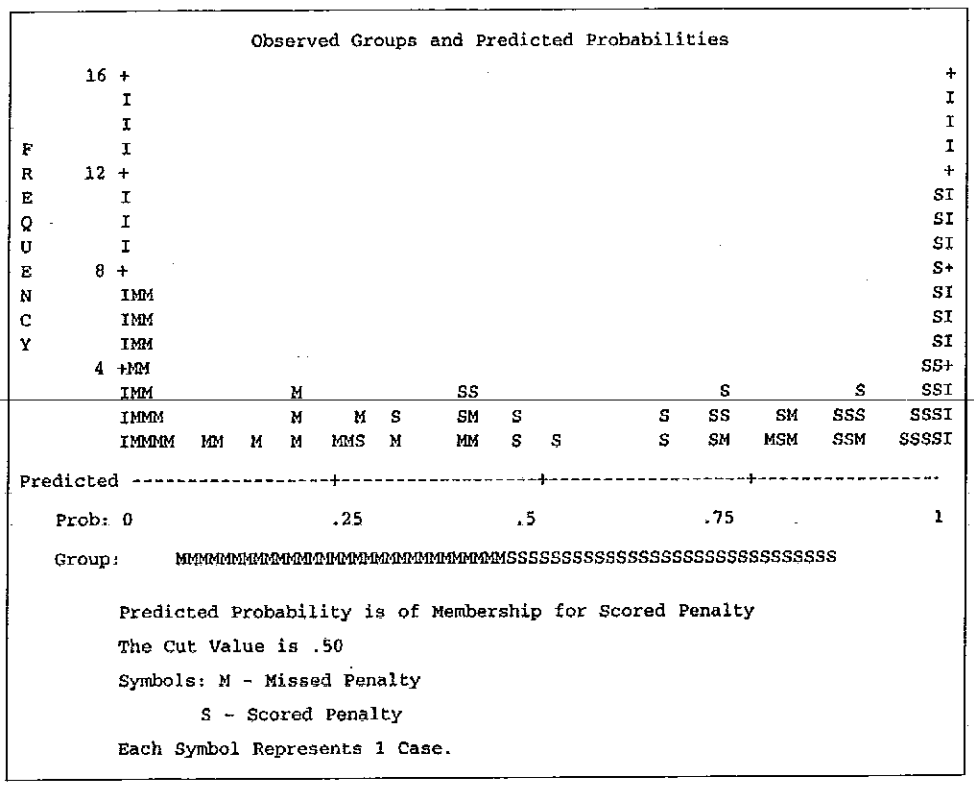

الخرج 11.6

يعرض (الخرج 12.6) ما يحدث في النموذج عند إضافة المتحول التنبؤي الجديد anxious. يصف هذا الجزء من الخرج الكتلة الثانية، أي النموذج الذي تم وصفه في الكتلة الأولى بعد إضافة المتحول التنبؤي الجديد. إن تأثير إضافة المتحول anxious إلى النموذج هو تقليل 2LL- إلى القيمة 47.416 (انخفاض بمقدار 1.246 عن النموذج في الكتلة الأولى كما تبين إحصائية كاي مربع للنموذج والإحصائية block). إن هذا التحسن غير مهم مما يدل على أن تضمين المتحول anxious في النموذج لم يحسّن كثيراً مقدرتنا على التنبؤ بنجاح ضربة الجزاء أو فشلها. يخبرنا جدول التصنيف بأن النموذج يصنف الآن 85.33% من الحالات بنجاح. تذكر أنه في الكتلة الأولى كان النموذج قادراً على تصنيف 84% من الحالات بنجاح، وأن الزيادة هي 1.33% فقط (وبالنظر للجدول فإننا نجد أن حالة إضافية واحدة قد تم تصنيفها بنجاح).

يحوي القسم المسمى Variables in the Equation المتحولات التنبؤية الثلاثة، وقد حدث أمر مهم جداً، فمازال المتحول PSWQ متحولاً هاماً لنجاح ضربة الجزاء، ولكن الخبرة السابقة previous لم تعد كذلك. وقد بدت حالة القلق anxious وكأنها لا تساهم بشكل كبير في التنبؤ بنجاح ضربة الجزاء. كيف يمكن أن نفسر أن الخبرة السابقة لم تعد تتنبأ بنجاح ضربة الجزاء وأن حالة القلق لا تساهم في التنبؤ، ومع ذلك فإن قدرة النموذج على التنبؤ بنجاح ضربة الجزاء قد تحسنت قليلاً؟! إن

مخطط التصنيف (الخرج 13.6) مشابه لما سبق ولم تتغير تقريباً مساهمة PSWQ في التوقع بنجاح ضربة الجزاء. وما تغير هو مساهمة الخبرة السابقة. إذا فحصنا قيم Exp(B) لكل من المتحولين anxious وprevious فمن الواضح أن لكليهما علاقة طردية محتملة بنجاح ضربة الجزاء (عند التغير بمقدار الوحدة تتحسن أرجحية النجاح). ولكن مجال الثقة لهذه القيم يمر عبر القيمة 1 مما يدل على أن اتجاه العلاقة قد يكون غير مستقر في المجتمع بكامله (أي أن قيمة Exp(B) في العينة قد تكون مختلفة تماماً عن القيمة إذا تم أخذ البيانات من المجتمع بكامله).

Block 2: Method=Enter

Omnibus Tests of Model Coefficients

		Chi-square	df	Sig.
Step 1	Step	1.246	1	.264
	Block	1.246	1	.264
	Model	66.223	3	.000

Model Summary

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	47.416[a]	.527	.704

a. Estimation terminated at iteration number 6 because parameter estimates changed by less than .001.

Hosmer and Lemeshow Test

Step	Chi-square	df	Sig.
1	9.937	7	.192

Contingency Table for Hosmer and Lemeshow Test

		Result of Penalty Kick = Missed Penalty		Result of Penalty Kick = Scored Penalty		
		Observed	Expected	Observed	Expected	Total
Step 1	1	8	7.926	0	.074	8
	2	8	7.769	0	.231	8
	3	9	7.649	0	1.351	9
	4	4	5.425	4	2.575	8
	5	1	3.210	7	4.790	8
	6	4	1.684	4	6.316	8
	7	1	1.049	7	6.951	8
	8	0	.222	8	7.778	8
	9	0	.067	10	9.933	10

الخرج 12.6

Classification Table[a]

Observed			Predicted: Result of Penalty Kick		
			Missed Penalty	Scored Penalty	Percentage Correct
Step 1	Result of Penalty Kick	Missed Penalty	30	5	85.7
		Scored Penalty	6	34	85.0
	Overall Percentage				85.3

a. The cut value is .500

Variables in the Equation

		B	S.E.	Wald	df	Sig.	Exp(B)	95.0% C.I.for EXP(B)	
								Lower	Upper
Step 1[a]	previous	.203	.129	2.454	1	.117	1.225	.950	1.578
	pswq	-.251	.084	8.954	1	.003	.778	.660	.917
	anxious	.276	.253	1.193	1	.275	1.318	.803	2.162
	Constant	-11.493	11.802	.948	1	.330	.000		

a. Variable(s) entered on step 1: anxious.

الخرج 12.6 تكملة

```
                Observed Groups and Predicted Probabilities

     16 +                                                                +
        I                                                                I
        I                                                                I
F       I                                                                I
R    12 +                                                                +
E       I                                                               SI
Q       I                                                               SI
U       I                                                               SI
E     8 +M                                                              S+
N       IM                                                              SI
C       IM                                                              SI
Y       IMM                                                             SSI
      4 +MM                 M                                      S    SS+
        IMM                 M     S                                SS   SSI
        IMMMM               M     S              S               S MS  SS  SSSI
        IMMMMMM  MM   M     M     S  S     MM  MMS    S     S    SSMSMM  SSSS   M  SSSSI
Predicted  ----------------+----------------+----------------+----------------
    Prob:    0              .25              .5              .75             1
    Group:   MMMMMMMMMMMMMMMMMMMMMMMMMMMMMMMMSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSSS

        Predicted Probability is of Membership for Scored Penalty
        The Cut Value is .50
        Symbols: M - Missed Penalty
                 S - Scored Penalty
        Each Symbol Represents 1 Case.


    CASE Observed
          SCORED      Pred      PGroup      Resid      ZResid
         58 S M**     .9312       S         -.9312     -3.6790

        S = Selected U=Unselected cases
        ** = Misclassified cases

* Cases with Studentized residuals greater than 2 are listed.
          The Cut Value is .50
```

الخرج 13.6

قد يغريك استخدام هذا النموذج النهائي بالقول أنه مع أن الاضطراب هو متحول تنبؤي مهم في نجاح ضربة الجزاء فإن النتيجة السابقة بأن الخبرة تلعب دوراً هي غير صحيحة. وسيكون هذا الاستنتاج خطيراً وسنرى لماذا.

8.6 الاختبار من أجل الارتباط الخطي المتعدد

رأينا في الفقرة 4.2.6.5 كيف يمكن للارتباط الخطي المتعدد أن يؤثر على بارامترات نموذج التراجع. والتراجع المنطقي معرّض كذلك للتأثر بالارتباط الخطي ومن الضروري اختبار الارتباط الخطي بعد القيام بعملية تحليل التراجع المنطقي. لسوء الحظ، لا يوفر برنامج SPSS خياراً لإنتاج إحصائيات الارتباط الخطي في التراجع المنطقي (مما يعطي انطباعاً خاطئاً بأنه غير ضروري). على كل حال، يمكنك الحصول على الإحصائيات مثل التسامح ومعامل تضخم التباين VIF بتنفيذ التراجع الخطي وباستخدام نفس متحول النتيجة والمتحولات التنبؤية. ومن أجل المثال الحالي، نستخدم أمر القائمة Analyze ⇒ Regression ⇒ Linear... لفتح مربع الحوار الرئيسي للتراجع الخطي. يبين الشكل 9.6 الحالة النهائية لمربع الحوار. ومن غير الضروري تحديد مجموعة كبيرة من الخيارات (لأننا نستخدم هذه التقنية من أجل الحصول على اختبارات الارتباط الخطي فقط)، ولكن من الضروري نقر الزر Statistics... وتحديد Collinearity diagnostics في مربع الحوار لاختيار إحصائيات الارتباط الخطي. بعد الانتهاء من تحديد ذلك الاختيار، ألغِ اختيار جميع الخيارات الافتراضية وانقر الزر Continue للعودة إلى مربع الحوار الرئيسي للتراجع الخطي. انقر الزر OK لتنفيذ عملية التحليل.

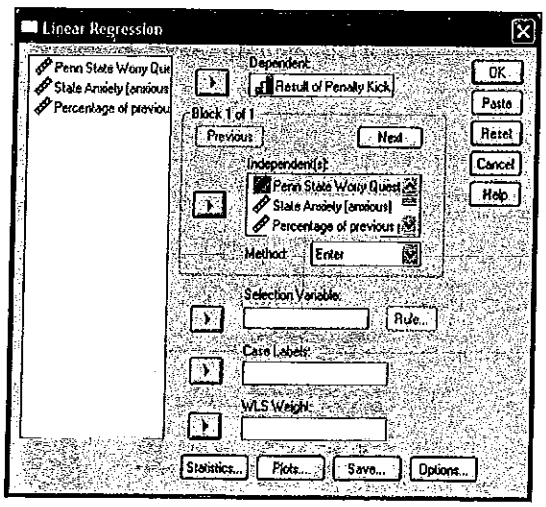

الشكل 9.6 مربع الحوار الرئيسي للتراجع الخطي من أجل بيانات ضربات الجزاء

يبين (الخرج 14.6) نتائج تحليل التراجع الخطي. من الجدول الأول يمكن أن نجد أن قيمة التسامح هي 0.014 للمتحولين previous وanxious، و0.575 للمتحول PSWQ. وقد رأينا في الفصل 5

معايير مختلفة لتقييم الارتباط الخطي، إذ يقترح Menard (1995) أن قيمة التسامح التي تكون أصغر من 0.1 تدل بشكل أكيد على مشكلة جدية في الارتباط الخطي. ويقترح Myers (1990) أن قيم VIF التي تكون أكبر من 10 هي سبب للاهتمام، ومن أجل هذه البيانات فإن لدينا قيماً أكبر من 70 لكل من anxious و previous. ويبدو من هذه القيم أن هناك مشكلة ارتباط خطي بين هذين المتحولين التنبؤيين. يمكننا دراسة هذه المسألة بتعمق أكبر وذلك من خلال دراسة إحصائيات الارتباط الخطي.

Coefficients[a]

Model		Collinearity Statistics	
		Tolerance	VIF
1	Penn State Worry Questionnaire	.575	1.741
	State Anxiety	.014	71.764
	Percentage of previous penalties scored	.014	70.479

a. Dependent Variable: Result of Penalty Kick

Collinearity Diagnostics[a]

Model	Dimension	Eigenvalue	Condition Index	Variance Proportions			
				(Constant)	Penn State Worry Questionnaire	State Anxiety	Percentage of previous penalties scored
1	1	3.434	1.000	.00	.01	.00	.00
	2	.492	2.641	.00	.04	.00	.00
	3	.073	6.871	.00	.95	.01	.00
	4	.001	81.303	1.00	.00	.99	.99

a. Dependent Variable: Result of Penalty Kick

الخرج 14.6 إحصائيات الارتباط الخطي لبيانات ضربات الجزاء

يعرض الخرج 14.6 جدولاً يحمل التسمية Collinearity Diagnostics. ويحوي هذا الجدول القيم الخاصة لمصفوفة الجداء المتصالب اللامركزي، دليل الحالة (Condition index) ونسب التباين لكل متحول تنبؤي. إذا كانت أي من القيم الخاصة في هذا الجدول أكبر بكثير من بقية القيم فإن مصفوفة الجداء المتصالب اللامركزي تكون ill-conditioned، وهذا يعني أن الحلول لبارامترات التراجع يمكن أن تتأثر بشكل كبير بالتغيرات الصغيرة في المتحولات التنبؤية أو النتيجة. وبلغة أبسط فإن هذه القيم تعطينا فكرة عن مدى دقة نموذج التراجع، فإذا كانت القيم الخاصة متشابهة تقريباً فإن النموذج المشتق لن يتأثر بالتغيرات الصغيرة في المتحولات المقاسة. أما أدلة الحالة فهي طريقة أخرى للتعبير عن القيم الخاصة، وتساوي الجذر التربيعي لنسبة القيمة الخاصة الكبرى إلى القيمة الخاصة موضوع الدراسة. ومن أجل هذا المثال فإن للبعد الأخير دليل حالة 81.3 وهي قيمة كبيرة مقارنة ببقية الأبعاد. ومع أنه لا توجد قواعد صارمة وسريعة لتحديد مقدار دليل الحالة الذي يدل على مشاكل الارتباط الخطي فإن هذه الحالة تبين بوضوح وجود مشكلة ما.

الخطوة الأخيرة في تحليل هذا الجدول هي النظر إلى نسب التباين. يمكن أن يتوزع التباين لكل معامل من معاملات التراجع بين القيم الخاصة، وتخبرنا نسب التباين عن نسبة التباين لكل معامل من معاملات التراجع للمتحول التنبؤي التي يعطيها لكل قيمة خاصة. يمكن تحويل هذه النسب إلى نسب مئوية وذلك بضربها بالعدد 100، فعلى سبيل المثال 95% من التباين في معامل التراجع للمتحول PSWQ مرتبط بالقيمة الخاصة رقم 3، و 4% مرتبط بالقيمة الخاصة رقم 2، و1% مرتبط بالقيمة الخاصة رقم 1. وفيما يتعلق بالارتباط الخطي فإننا نبحث عن المتحولات التنبؤية ذات النسب المرتفعة من أجل نفس القيمة الخاصة الصغيرة، لأن ذلك يشير إلى أن التباينات لمعاملات التراجع الخاصة بها هي مستقلة. ولذلك فإننا نهتم بشكل أساسي بالأسطر القليلة الأخيرة في الجدول (التي تمثل القيم الخاصة الصغيرة). وفي هذا المثال 99% من التباين في معامل التراجع لكل من المتحولين previous و anxious مرتبط بالقيمة الخاصة رقم 4 (القيمة الخاصة الأصغر)، مما يدل بشكل واضح على التبعية بين هذين المتحولين. إن نتيجة هذا التحليل واضحة تماماً، هناك ارتباط خطي بين حالة القلق والخبرة السابقة في تنفيذ ضربات الجزاء، وتعطي هذه التبعية تأثيراً على النموذج. ولتوضيح مصدر هذا الارتباط الخطي فإن الخرج 15.6 يبين معامل Pearson للارتباط بين جميع المتحولات في تحليل التراجع (يمكنك تنفيذ مثل ذلك التحليل بنفسك). ومن هذا الخرج يمكن أن نعرف شدة الارتباط العكسي بين المتحولين previous وanxious (r=-0.99)، أي أن هناك ارتباط شبه مثالي بينهما. ويرتبط كل من previous وanxious مع نجاح ضربات الجزاء ولكن بما أنهما مرتبطان فيما بينهما بقوة فمن غير الواضح أيهما يتوقع نجاح ضربات الجزاء في نموذج التراجع.

Correlations

		Penn State Worry Questionnaire	State Anxiety	Percentage of previous penalties scored	Result of Penalty Kick
Penn State Worry Questionnaire	Pearson Correlation	1.000	.652**	-.644**	-.675**
	Sig. (2-tailed)		.000	.000	.000
	N	75	75	75	75
State Anxiety	Pearson Correlation	.652**	1.000	-.993**	-.668**
	Sig. (2-tailed)	.000		.000	.000
	N	75	75	75	75
Percentage of previous penalties scored	Pearson Correlation	-.644**	-.993**	1.000	.674**
	Sig. (2-tailed)	.000	.000		.000
	N	75	75	75	75
Result of Penalty Kick	Pearson Correlation	-.675**	-.668**	.674**	1.000
	Sig. (2-tailed)	.000	.000	.000	
	N	75	75	75	75

**. Correlation is significant at the 0.01 level (2-tailed).

الخرج 15.6

وتطرح هذه المناقشة السؤال لمعرفة ما يمكن عمله عند تحديد الارتباط الخطي. حسناً، ليس هناك الكثير مما يمكننا عمله. والحل البديهي هو إهمال أحد المتحولات (فعلى سبيل المثال يمكننا المحافظة على النموذج في الكتلة الأولى الذي يهمل حالة القلق). والمشكلة في ذلك ستكون بديهية، إذ لا توجد طريقة لمعرفة المتحول الذي ينبغي إهماله. والاستنتاجات النظرية تكون بالتالي عديمة المعنى إحصائياً، إذ يمكن إهمال أي متحول له علاقة بالارتباط الخطي. وباختصار ليست هناك أرضية إحصائية لإهمال متحول معين بدلاً من متحول آخر. وحتى لو تمت إزالة أحد المتحولات التنبؤية فإن Bowerman & O'Connell (1990) ينصحان بأن يتم وضع متحول تنبؤي آخر مهم بنفس القدر وليس له ارتباط خطي متعدد بتلك القوة بدلاً من ذلك المتحول. كما يقترحان جمع المزيد من البيانات لمعرفة فيما إذا كان ممكناً تخفيف الارتباط الخطي المتعدد. وهناك إمكانية أخرى وذلك عندما تكون مجموعة من المتحولات التنبؤية مشتركة في الارتباط الخطي وهي تنفيذ تحليل العوامل على هذه المتحولات التنبؤية واستخدام علامات العامل الناتج كمتحول تنبؤي (انظر الفصل 15)، إن العلاج الآمن (ولكنه غير كاف) هو معرفة عدم وثوقية النموذج. لذلك إذا أردنا تقديم التحليل لمعرفة العوامل التي تتوقع نجاح ضربة الجزاء فإن علينا معرفة أن الخبرة السابقة تتوقع بشكل جيد نجاح ضربة الجزاء في النموذج الأول، مع اقتراح أن تلك الخبرة قد تؤثر على ضربة الجزاء المنفّذة مع ازدياد حالة القلق. إن هذه العبارة ستكون عالية الافتراضية لأن الارتباط بين المتحولين previous وanxious لا يخبرنا بشيء عن اتجاه السببية، ولكنها تعطي معلومات عن الصلة غير المفسرة بين هذين المتحولين التنبؤيين.

9.6 التعامل مع الأخطاء الممكنة

يحل برنامج SPSS مسائل التراجع المنطقي وفق إجرائية تكرارية، إنه يخمن حلاً محتملاً ويتحقق من مدى توافق الحل مع البيانات ثم يعيد العملية في محاولة لتحسين التوافق. ويتوقف عندما يظن أن تخمينه أصبح قريباً جداً من الحل الصحيح. وفي بعض الأحيان، وبدلاً من الوصول إلى الحل الصحيح بسرعة، تلاحظ عدم حصول تقدم، إذ يبدأ برنامج SPSS بالتقدم ببطء شديد، أو أنه يبدو ساكناً دون أي تقدم. إذا لم يعثر على حل صحيح فإنه يستسلم أحياناً ويقدم لك حلاً غير صحيح أبداً. ويكشف ذلك عادة قيمة الخطأ المعياري الكبير غير المقنعة. ويمكن أن ينتج ذلك عن حالتين اثنتين:

1.9.6 معلومات ناقصة عن المتحولات التنبؤية

تخيل أنك تحاول التنبؤ بسرطان الرئة بسبب التدخين (العادة السيئة التي يُعتقد أنها تزيد خطر السرطان) وفيما إذا كنت تأكل البندورة أم لا (والتي يعتقد أنها تقلل خطر السرطان). تقوم بجمع البيانات من الأشخاص المدخنين وغير المدخنين، ومن الأشخاص الذين يأكلون البندورة والذين لا

يأكلونها، وعلى كل حال إن ذلك لا يكفي ما لم تجمع البيانات من جميع التراكيب المحتملة للتدخين وأكل البندورة.

هل تدخن؟	هل تأكل البندورة؟	هل أنت مصاب بالسرطان؟
نعم	لا	نعم
نعم	نعم	نعم
لا	لا	نعم
لا	نعم	؟؟؟؟

إن مراقبة الإمكانيات الثلاث الأولى لا تسمح لك بتوقع النتيجة للإمكانية الرابعة. ليست هناك طريقة لمعرفة فيما إذا كان الشخص الأخير سيصاب بالسرطان أم لا بناءً على البيانات الأخرى التي جمعتها. ولذلك فإن برنامج SPSS سيصادف مشكلة ما لم يتم جمع البيانات من جميع التراكيب المحتملة للمتحولات. ويجب التحقق من ذلك قبل تنفيذ التحليل باستخدام الجدول التصالبي، وسنقدم كيفية تنفيذ ذلك في الفصل 16.

تنطبق هذه النقطة على المتحولات الفئوية وكذلك على المتحولات المستمرة. لنفترض أنك تريد البحث عن العوامل المرتبطة بسعادة الإنسان. قد يتضمن ذلك العمر والجنس والمعتقدات الدينية ومستويات القلق وفيما إذا كان الإنسان يستخدم يده اليمنى أو اليسرى. لنفترض أنك أجريت مقابلات مع 1000 شخص وسجلت إجاباتهم وفيما إذا كانوا سعداء أم لا ("نعم" أو"لا"). ومع أن عينة مؤلفة من 1000 تبدو كبيرة نوعاً ما، فهل من المحتمل أنها تشمل سيدة تبلغ من العمر 80 عاماً، قلقة جداً وتستخدم يدها اليسرى وتؤمن بالبوذية؟ إذا وجدت مثل هذه السيدة وكانت سعيدة، فهل يمكنك أن تستنتج أن جميع الأشخاص الآخرين في نفس الفئة هم سعداء؟ من الأفضل أن يوجد عدة أشخاص في نفس الفئة لكي يمكننا أن نؤكد أن تركيباً من هذه المميزات يحقق السعادة.

وبشكل عام إذا كانت العينات مقسمة إلى فئات وكان واحد من التراكيب أو أكثر فارغاً فإنه يخلق مشكلة. وقد تتم الإشارة لذلك بمعاملات تكون أخطاؤها المعيارية كبيرة بشكل غير معقول. يقوم الباحثون المتقنون لعملهم بإنتاج الجداول المتصالبة متعددة الطرق لجميع المتحولات الفئوية المستقلة والتحقق منها. أما الكسالى والحريصون بآن واحد فلا يزعجون أنفسهم بإنتاج الجداول المتصالبة ولكنهم ينظرون بحذر للأخطاء المعيارية. أما الذين لا يقومون بأي من العملين السابقين فعليهم أن يتوقعوا المشاكل.

2.9.6 الانفصال التام

الحالة الثانية التي ينهار فيها التراجع المنطقي قد تكون مفاجئة، وتحدث عندما يتم توقّع متحول النتيجة بشكل مثالي بواحد أو بتركيب من المتحولات. وتعرف هذه الحالة بالانفصال التام (Complete Separation).

لنأخذ المثالي التالي: تخيل أنك وضعت وسادة ضغط تحت مفرش باب منزلك ووصلتها مع نظام الأمان بحيث يمكنك اكتشاف اللصوص الذين يحاولون التسلل في الليل. وعلى كل حال، بما أن الأولاد المراهقين وأصدقائهم يتسللون بعد منتصف الليل إلى المنزل، ويدوسون على وسادة الضغط فإنك سترغب في أن يعمل نظام الأمان عندما يتسلل لص ما وليس الأولاد. لذلك يمكنك أن تقيس وزن أحد اللصوص ووزن أحد أولادك ثم تستخدم التراجع المنطقي للتنبؤ بالنتيجة اعتماداً على الوزن. يجب أن يعطي المخطط خطاً من المثلثات عند القيمة 0 (نقاط البيانات لجميع المراهقين الذي قمت بوزنهم) وخطاً آخر من المثلثات عند القيمة 1 (نقاط البيانات لجميع اللصوص الذين قمت بوزنهم). لاحظ أن هذين الخطين يتطابقان أحياناً (وزن بعض المراهقين يساوي وزن بعض اللصوص). وقد رأينا في التراجع المنطقي أن البرنامج SPSS يحاول التنبؤ باحتمال حدوث النتيجة عند معرفته قيمة المتحول التنبؤي. في هذه الحالة، من أجل الأوزان الصغيرة يجب أن يتبع الاحتمال الخط السفلي على المخطط، ومن أجل الأوزان الكبيرة فإنه يتبع الخط العلوي. ومن أجل القيم البينية فإنه يحاول أن يتبع الاحتمال عند تغيره.

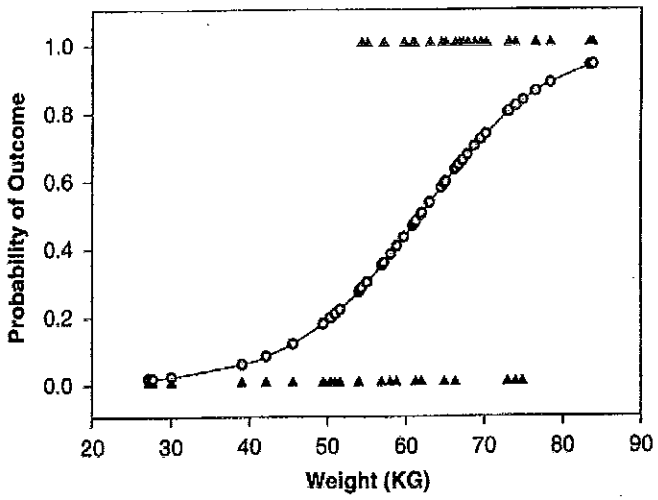

تخيل أن لدينا نفس وسادة الضغط ولكن أولادنا المراهقين كبروا وغادروا المنزل إلى الجامعة. إن ما يهمنا حالياً هو التمييز بين اللصوص والقطط اعتماداً على الوزن. نقوم بوزن بعض القطط وبعض اللصوص. وفي هذه الحالة هناك خطان أيضاً، الخط السفلي عند القيمة 0 (أوزان القطط)، والخط العلوي عند القيمة 1 (أوزان اللصوص) ولكن الخطين لا يتطابقان أبداً، إذ لا يمكن أن يتساوى وزن اللص مع وزن إحدى القطط. تعرف هذه الحالة بالانفصال التام، إذ يمكن أن نتوقع النتيجة (القطط واللصوص) اعتماداً على الوزن (فالكائن الذي يكون وزنه أقل من 15كغ هو قطة، والذي يزيد وزنه على 40كغ هو لص).

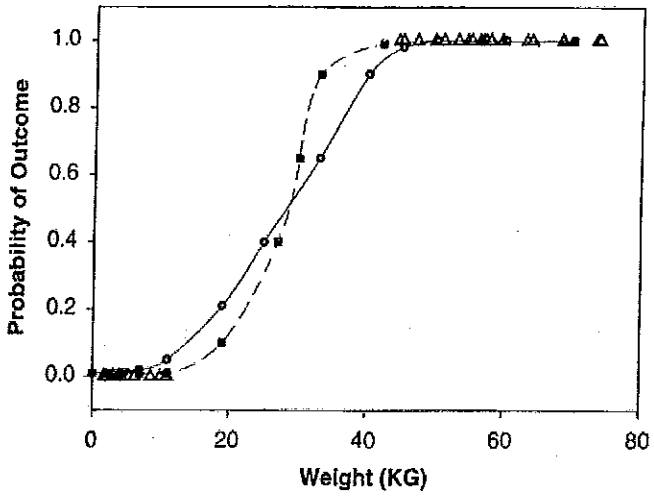

إذا أردنا حساب احتمالات النتيجة عند معرفتنا لوزن معين فإننا نقع في مشكلة. إذا كان الوزن منخفضاً فإن الاحتمال هو 0، وإذا كان الوزن مرتفعاً كان الاحتمال 1، ولكن ماذا يحدث في المجال بينهما؟ لا تتوفر لدينا أية بيانات في المجال من 15 كغ حتى 40 كغ لكي تستند إليها هذه الاحتمالات. يبين المخطط بعض منحنيات الاحتمال الممكنة التي يمكن أن توافق البيانات، أحدهما أكثر انحداراً من الآخر. إن أحد هذين المنحنيين هو صحيح اعتماداً على البيانات المتوفرة. إن نقص البيانات يعني أن برنامج SPSS لن يكون متأكداً من مقدار انحدار المنحني الواصل بين الخطين السفلي والعلوي، إنه يحاول أن يجعل المركز قريباً من الوضع الشاقولي قدر الإمكان، وستنحرف تقديراته بشكل غير مستقر باتجاه اللانهاية (ومن هنا الأخطاء المعيارية الكبيرة).

تظهر هذه المشكلة غالباً عند استخدام متحولات عديدة لتوافق عدداً قليلاً من الحالات. وغالباً ما يكون الحل المقنع هو جمع المزيد من البيانات، ولكن في بعض الأحيان نعثر على جواب منظم عبر اعتماد نموذج أبسط.

10.6 ما الذي اكتشفناه عن الإحصاء؟

بدأنا الفصل بالبحث في عدم إمكانية استخدام التراجع الخطي (الفصل 5) عندما يكون متحول النتيجة ثنائياً. ثم بحثنا في الأسس النظرية للتراجع المنطقي وذلك بالنظر إلى معادلة التراجع وماذا تعنيه. انتقلنا بعد ذلك إلى تقييم النموذج والتحدث عن إحصائية لوغاريتم الاحتمال واختبار كاي مربع المرتبط بها. تحدثنا أيضاً عن الطرق المختلفة للحصول على مكافئات R^2 في التراجع. كما اكتشفنا إحصائيات Wald و(Exp(B. أما بقية الفصل فقد بحث في مثالين عن استخدام SPSS لتنفيذ التراجع المنطقي. ولذلك نأمل أنك حصلت على فكرة جيدة حول تنفيذ التراجع المنطقي وتفسير نتائجه.

11.6 المصطلحات الأساسية التي اكتشفناها

المقدار -2LL	(-2LL)
توزيع كاي مربع	(Chi-square distribution)
الانفصال التام	(Complete separation)
الإحصائية R^2_{CS}	(Cox & Snell's R^2_{CS})
الإحصائية Exp(B)	(Exp(B))
الإحصائية R^2_L	(Hosmer & Lemeshow's R^2_L)
التراجع المنطقي	(Logistic regression)
لوغاريتم الإحتمال	(Log-likelihood)
تقدير الاحتمال الأعظمي	(Maximum-likelihood estimation)
الإحصائية R^2_N	(Nagelkerke's R^2_N)
الأرجحية	(Odds)
إحصائية العلامة الفعّالة	(Rao's efficient score statistic)
إحصائية Wald	(Wald statistic)

12.6 مهمات يجب تنفيذها

يحوي الملف Answers(Chapter 6).pdf على القرص المضغوط المرفق الإجابات على هذه المهمات.

- أظهرت الدراسات الحديثة أن المحاضرين هم من بين العاملين الأكثر تعرضاً للإجهاد والإرهاق. وقد أراد باحث معرفة الأسباب وراء هذا الإجهاد وتبعاته. ولذلك قام بدراسة 467 حالة وطلب منهم الإجابة على استبيان يقيس: الإنهاك (Burnout) (المتحول burnout: نعم أو لا)، والتحكم بالفهم عن طريق الحواس (Perceived Control) (المتحول loc: العلامة المرتفعة = تحكم منخفض بالفهم عن طريق الحواس)، ونمط التعامل الناجح (Coping Style) (المتحول cope: العلامة المرتفعة = قدرة عالية على التعامل بنجاح مع الإجهاد)، والإجهاد بسبب التدريس (Stress from Teaching) (المتحول teaching: العلامة المرتفعة = يسبب التدريس الكثير من الإجهاد للشخص)، والإجهاد بسبب البحث (Stress from Research) (المتحول research: العلامة المرتفعة = يؤدي إلى إجهاد الشخص بشكل كبير البحث الكثير من الإجهاد للشخص)، والإجهاد من توفير الرعاية (Stress form Providing Pastoral Care) (المتحول pastoral: العلامة المرتفعة = يسبب توفير الرعاية للطلاب الكثير من الإجهاد للشخص). النتيجة التي اهتم بها الباحث هي الإنهاك (burnout)، ويدل نموذج Cooper, Sloan & Williams (1988) للإجهاد على أن التحكم

بالفهم عن طريق الحواس (loc) ونمط التعامل الناجح (cope) هما متحولان تنبؤيان هامان للحصول على النتيجة. أما المتحولات التنبؤية الأخرى فقد تم قياسها لمعرفة المساهمة الفردية لسمات عمل المحاضر في إرهاقه وإنهاكه. هل يمكنك مساعدة هذا الباحث بتنفيذ تراجع منطقي لمعرفة العامل الذي ينبأ بالإنهاك؟ يحوي الملف Burnout.sav البيانات لهذه المهمة.

- أراد أحد علماء النفس المهتمين بدراسة الفيروس HIV (المسبب لمرض الإيدز) معرفة العوامل التي تؤثر على استخدام الواقي في علاقة مع شريك جديد. النتيجة المقاسة هي هل تم استخدام الواقي أم لا (Use ويأخذ القيم: 1=تم استخدامه، 0= لم يتم استخدامه). وقد تم استخدام المتحولات التنبؤية المعتمدة في دراسة (CAS: Candom Attitude Scale) ظهرت في مجلة التقييم النفسي. المتحول Gender (جنس الشخص)، المتحول Safety (سلامة العلاقة، ويقاس على مقياس مكون من 5 نقاط ويدل على الدرجة التي يرى بها الشخص سلامة هذه العلاقة من ناحية نقل الأمراض الجنسية)، المتحول Sexexp (الخبرة الجنسية، ويقاس على مقياس مكون من 10 نقاط ويدل على الدرجة التي تؤثر بها العلاقات الجنسية السابقة على نظرته لاستخدام الواقي)، المتحول Previous (مقياس غير متضمن في CAS، ويقيس فيما إذا استخدم الشخصان الواقي في لقاءاتهما السابقة أم لا، ويأخذ القيم 0= لم يستخدما الواقي، 1=استخدما الواقي، 2= لم تكن هناك لقاءات سابقة بينهما)، selfcon (التحكم الذاتي، ويقاس على مقياس مكون من 9 نقاط ويدل على درجة التحكم الذاتي للشخص عند الإقدام على استخدام الواقي)، المتحول Perceive (إدراك الخطر، ويقاس على مقياس مكون من 6 نقاط ويدل على الدرجة التي يشعر بها الشخص بالخطر من ممارسة الجنس بشكل غير محمي). لقد أظهر بحث سابق قام به كل من Sacco, Rickman, Thompson, Levine & Reed في مجلة Aids Education and Prevention (1993) أن المتحولات gender وsafety وperceive تتنبأ باستخدام الواقي (متحول النتيجة use). ومهمتك هي تنفيذ تحليل مناسب للتحقق من نتائج تلك الدراسة، واختبار فيما إذا كانت المتحولات selfcon وprevious وsexexp قادرة على التنبؤ بالتباين المتبقي لاستخدام الواقي. (1) تفسير جميع الأجزاء الهامة من خرج البرنامج SPSS، (2) مدى وثوقية النموذج النهائي، (3) ما هي احتمالات أن يستخدم المشتركون 12 و53 و75 الواقي؟ (4) استخدمت أنثى الواقي في لقاءاتها السابقة مع شريكها الجديد، وحصلت على العلامة 2 في جميع المتحولات باستثناء perceive حيث حصلت على 6. استخدم النموذج لتقدير احتمال أن تستخدم الواقي في لقائها القادم. يحوي الملف condom.sav البيانات لهذا المثال.

يحوي الملف Answeas(chapter6).pdf على القرص المضغوط الإجابات لهذه المهمات.

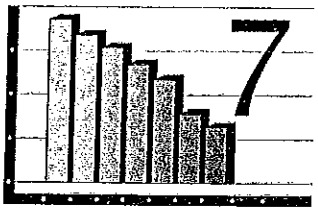

مقارنة متوسطين

1.7 بماذا يخبرنا هذا الفصل

يهتم بعض الباحثين أحياناً بالنظر إلى الفروق بين المجموعات بين البشر، بدلاً من النظر إلى العلاقات بين المتحولات، وبشكل خاص في الأبحاث التجريبية حيث نريد التلاعب بما يحدث للناس بحيث نحصل على التداخلات السببية. فعلى سبيل المثال، إذا أخذنا مجموعتين من الناس وطلبنا من إحداهما تناول أقراص للحمية، وطلبنا من المجموعة الأخرى إتباع نظام لأقراص السكر (وهم يعتقدون أنه سيساعدهم في تخفيف وزنهم)، فإذا فقد أفراد المجموعة الأولى وزناً أكثر مما يفقده أفراد المجموعة الثانية فإننا نستنتج أن أقراص الحمية قد سببت فقدان الوزن. وهذه أداة بحثية هامة لأنها تتقدم خطوة إضافية بعد مراقبة المتحولات والبحث عن العلاقات (كما في الارتباط والتراجع)[1]. وهذا الفصل هو الأول من مجموعة تهتم بهذا النوع من سيناريو الأبحاث، وسنبدأ بالسيناريو الأبسط حيث يكون لدينا مجموعتان، أو بشكل أدق، عندما نرغب بمقارنة متوسطين. وكما سترى، فإن هناك طريقتان مختلفتان لجمع البيانات، فإما أن نعرّض أشخاصاً مختلفين لتلاعبات تجريبية مختلفة (التصميم بين المجموعات أو التصميم المستقل) أو أن نأخذ مجموعة منفردة ونعرّضها لتلاعبات تجريبية مختلفة في أوقات مختلفة (تصميم القياسات المكررة). ولكن علينا أولاً أن ننظر إلى كيفية رسم الأنواع المختلفة من البيانات ثم ننظر إلى الإجرائيات الإحصائية لتحليل التصميم المستقل (اختبار t المستقل) ثم ننتقل إلى تصميم القياسات المكررة (اختبار t المرتبط).

---

1 يعتقد الناس في بعض الأحيان أن بعض الإجرائيات الإحصائية تسمح بالتداخلات السببية وبعضها الآخر لا يسمح. إن ذلك غير صحيح، إذ أننا نقوم عملياً بالتلاعب بأحد المتحولات بشكل منهجي لمعرفة أثره على المتحول الآخر الذي يسمح بالتداخل السببي. وفي أشكال أخرى من البحث، نراقب التغيرات في المتحولات دون أي تدخل من قبل القائم بالاختبار ولذلك لا يمكننا معرفة المتحول الذي يسبب التغير في المتحول الآخر ولكن يمكننا أن نقول أنهما يتغيران بطريقة معينة. وكما ستكتشف، فإن الإجرائيات الإحصائية لتحليل هذه الأنواع المختلفة من البيانات هي ذاتها رياضياً.

2.7 مراجعة البحث التجريبي

لا نكتفي في العلوم الاجتماعية بالاهتمام بتغير المتحولات أو توقع نتيجة ما، ولكننا قد نرغب بمعرفة أثر متحول ما على متحول آخر بإجراء تغيير منهجي لبعض مزايا ذلك المتحول. لذلك نقوم بالتلاعب بأحد المتحولات لمراقبة أثره على متحول آخر بدلاً من جمع البيانات التي تحدث بشكل طبيعي كما في حالتي الارتباط والتراجع. ففي حالة بسيطة قد نرغب بمعرفة أثر التشجيع الإيجابي على تعلم مادة الإحصاء. ولذلك نقسم بشكل عشوائي بعض الطلاب إلى مجموعتين مختلفتين:

- **المجموعة الأولى (الدعم الإيجابي):** نقوم بتشجيع جميع الطلاب خلال المحاضرات على عملهم ونجاحهم، وحتى عندما يرتكب الطلاب بعض الأخطاء، نواصل الدعم والتشجيع بقول عبارات مثل "كان الجواب تقريباً هو الجواب الصحيح"، ثم نعطي الطالب قطعة من الشوكولا.
- **المجموعة الثانية (الدعم السلبي):** تتلقى هذه المجموعة محاضرات من النمط الجامعي العادي، لذلك يتم خلال المحاضرات توجيه شتائم لفظية مستمرة لجميع الطلاب حتى عندما تكون إجاباتهم صحيحة، مع السخرية والاستهزاء من كل ما يقولونه. ويتم وصف الطلاب بالأغبياء والتافهين وأنهم لا يستحقون حضور المحاضرة.

إن ما تم التلاعب به هنا هو طريقة التعليم (الدعم الإيجابي مقابل الدعم السلبي). يُعرف هذا المتحول بالمتحول المستقل IV (Independent Variable) ويتمتع في هذه الحالة بمستويين، لأن التلاعب قد تم بطريقتين (تم تقسيم الدعم إلى نوعين إيجابي وسلبي). بعد تنفيذ هذا التلاعب يجب أن يكون لدينا نتيجة من نوعٍ ما نهتم بقياسها. في هذه الحالة، إنها المقدرة في علم الإحصاء، ويمكننا قياس هذا المتحول عن طريق علاقات الامتحان لمادة الإحصاء في نهاية العام الدراسي. يعرف متحول النتيجة بالمتحول التابع DV (Dependent Variable) لأننا نفترض أن هذه العلامات ستعتمد على نوع طريقة التعليم المستخدمة (المتحول المستقل).

1.2.7 طريقتان لجمع البيانات

عندما نقوم بجمع البيانات فإننا نختار بين طريقتين لجمع البيانات. يتم في الطريقة الأولى التلاعب بالمتحول المستقل باستخدام المشتركين المختلفين، وتشارك المجموعات المختلفة من الناس في كل حالة تجريبية (التصميم بين المجموعات، أو بين المواضيع، أو المستقل). أما في الطريقة الثانية فيتم التلاعب بالمتحول المستقل باستخدام نفس المشتركين. وتعني هذه الطريقة ببساطة أننا نعطي مجموعة من الطلاب دعماً إيجابياً لعدة أسابيع ونختبر مقدرتهم في علم الإحصاء، ثم نعطي لنفس المجموعة دعماً سلبياً لعدة أسابيع قبل اختبارهم مرة أخرى (التصميم ضمن المجموعة أو القياسات المكررة). وتحدد الطريقة التي يتم بها جمع البيانات نوع الاختبار المستخدم لتحليل البيانات.

2.2.7 نوعان من التغاير

قبل أن نبدأ، تخيل أنك استخدمت تصميم القياسات المكررة في تجربة ذات حالتين فقط. لذلك فقد شارك نفس المشتركون في كلتا الحالتين من التجربة، أو بطريقة أبسط، لقد قسنا سلوك المشتركين في الحالة الأولى وفي الحالة الثانية. تخيل على سبيل المثال أننا نحاول معرفة فيما إذا كان ممكناً تدريب الشمبانزي على إدارة الاقتصاد. في المرحلة الأولى من التدريب، يجلس الشمبانزي أمام الحاسب ويضغط الأزرار التي تغير البارامترات المختلفة للاقتصاد ثم يظهر مخطط على الشاشة ليشير إلى نتائج النمو الاقتصادي تبعاً لهذه البارامترات. وبما أن الشمبانزي لا يستطيع القراءة فإن هذا الانطباع عن النمو الاقتصادي لا معنى له بالنسبة إليه. أما في المرحلة الثانية من التدريب وعندما تكون نتائج النمو الاقتصادي جيدة فإن الشمبانزي يحصل على موزة (أما إذا كانت النتائج سيئة فلا يحصل على شيء)، وهذا الانطباع جيد بالنسبة للشمبانزي.

لننتقل خطوة إلى الوراء ونفكر: ماذا سيحدث لو أننا لم نتلاعب بالتجربة (أي أننا لم نقدم موزة في المرحلة الثانية من التدريب، وبقيت الحالة الثانية مماثلة للحالة الأولى). إذا لم يكن هناك تلاعب تجريبي فإننا نتوقع أن سلوك الشمبانزي سيكون ذاته في الحالتين. ونتوقع ذلك لأن العوامل الخارجية كالعمر والجنس ومستوى الذكاء والحماسة والإثارة ستكون ذاتها في الحالتين. وإذا كان مقياس الأداء موثوقاً (اختبارنا لكيفية إدارة الاقتصاد) وبقي المتحول الذي نقيسه (قابلية إدارة الاقتصاد) ثابتاً أو مستقراً عبر الزمن فإن أداء المشترك في الحالة الأولى سيكون مرتبطاً بشكل وثيق بأدائه في الحالة الثانية. ولذلك فإن الشمبانزي الذي حصل على علامات مرتفعة في الحالة الأولى سيحصل على علامات مرتفعة في الحالة الثانية، والشمبانزي الذي حصل على علامات منخفضة في الحالة الأولى سيحصل على علامات منخفضة في الحالة الثانية. وعلى كل حال ، لن يكون الأداء متطابقاً تماماً، إذ ستكون هناك بعض الاختلافات البسيطة التي تنشأ عن عوامل مجهولة. يدعى هذا التغاير في الأداء بالتغاير اللامنهجي (Unsystematic variation).

إذا أدخلنا تلاعباً تجريبياً (إعطاء موزة كمكافأة في إحدى جلستي التدريب) فإننا نقوم بشيء مختلف مع المشترك في الحالة الثانية عما نقوم به في الحالة الأولى. ولذلك فإن الفارق الوحيد بين الحالة الأولى والحالة الثانية هو التلاعب الذي قمنا به (ينال الشمبانزي موزة كمكافأة إيجابية في الحالة الثانية بينما لا ينال شيئاً في الحالة الأولى). ولذلك فإن أي اختلاف في المتوسط بين الحالتين ربما يكون عائداً للتلاعب التجريبي. فإذا كان أداء الشمبانزي في الحالة الثانية أفضل منه في الحالة الأولى فإن ذلك يعود لحقيقة أن الموزة قد استخدمت لتوفير انطباع في مرحلة التدريب الثانية وليس في المرحلة الأولى. تدعى الفروق في الأداء الناشئة عن تلاعب تجريبي معين بالتغاير المنهجي (Systematic Variation).

لنفكر الآن بما يحدث عندما نستخدم مشتركين مختلفين (التصميم المستقل). في هذا التصميم، سيكون لدينا حالتان أيضاً ولكن في هذه المرة لا يشارك نفس المشتركين في كلتا الحالتين. لنعد إلى

مثالنا، تتلقى مجموعة من الشمبانزي تدريباً دون مكافأة، بينما تتلقى مجموعة ثانية مكافأة على أدائها (موز). تخيل مرة ثانية أننا لا نقوم بتلاعب تجريبي. إذا لم نقدم أي شيء للمجموعتين فإن هناك بعض التغاير في الأداء بين المجموعتين وذلك لأنهما تحويان قروداً مختلفة من ناحية قدراتها وحماستها ومستوى ذكائها وغيرها من العوامل. وباختصار فإن نوع العوامل التي بقيت ثابتة في تصميم القياسات المكررة هي حرة التغير في التصميم المستقل. لذلك فإن التغاير اللامنهجي سيكون أكبر في حالة التصميم المستقل منه في تصميم القياسات المكررة. وإذا أدخلنا التلاعب التجريبي (الموز) فإننا نضيف تغايراً جديداً ناتجاً عن هذا التلاعب. ولذلك فإنه في كلا التصميمين هناك دائماً مصدران للتغاير:

- **التغاير المنهجي (Systematic Variation):** ينتج هذا التغاير لأن القائم بالاختبار يقوم بعمل شيء ما لجميع المشتركين في حالة ما ولا يفعل شيئاً في الحالة الأخرى.
- **التغاير اللامنهجي (Unsystematic Variation):** ينتج هذا التغاير عن العوامل العشوائية الموجودة بين الحالات التجريبية (كالفروقات الطبيعية في القدرات).

ودور الإحصاء هو اكتشاف مقدار التغاير في الأداء ثم العمل على تحديد المقدار المنهجي واللامنهجي في هذا التغاير. في تصميم القياسات المكررة، يمكن أن تنتج الفروق بين الحالات بسبب العاملين التاليين فقط: (1) التلاعب المنفّذ على المشتركين، (2) العوامل الأخرى التي يمكن أن تؤثر على طريقة أداء الشخص من وقت لآخر. ويبدو العامل الثاني صغيراً مقارنة بتأثير التلاعب التجريبي. أما في التصميم المستقل فإن الفروق بين الحالات يمكن أن تنتج عن أحد العاملين التاليين: (1) التلاعب المنفّذ على المشتركين، (2) الفروق بين مميزات الأشخاص الموزعين في كل مجموعة. ويبدو العامل الأخير محرضاً لتغاير عشوائي كبير ضمن كل حالة وبين الحالات أيضاً. ولذلك فإن أثر التلاعب التجريبي يبدو منتمياً إلى تصميم القياسات المكررة أكثر من التصميم المستقل (بين المجموعات) وذلك لأن التغاير اللامنهجي في تصميم القياسات المكررة يمكن أن ينتج بسبب الفروق في طريقة سلوك الشخص في الأوقات المختلفة. أما في التصميم بين المجموعات فلدينا فروق في القدرة الفطرية تساهم في التغاير اللامنهجي. ولذلك إذا استخدمنا نفس المشتركين فإن تغاير الخطأ سيكون دائماً أكبر. وعندما ننظر إلى أثر التلاعب التجريبي فإننا نجده دائماً مضاداً لخلفية الضجيج الناتج عن الفروق العشوائية وغير المتحكم بها بين الحالات التجريبية. في تصميم القياسات المكررة يبقى هذا الضجيج في حده الأدنى، ولذلك فإن أثر التجربة يبدو أوضح. وهذا يعني أن تصميم القياسات المكررة أكثر قدرة من التصميم المستقل على اكتشاف الآثار الحقيقية الموجودة.

3.2.7 العشوائية

في كلٍ من تصميم القياسات المكررة والتصميم المستقل، من المهم محاولة الحفاظ على التغاير اللامنهجي في حده الأدنى. وبالمحافظة على التغاير اللامنهجي صغيراً قدر الإمكان نحصل على قياس

أكثر حساسية للتلاعب التجريبي. وبشكل عام يستخدم العلماء عشوائية المشتركين لتحقيق هذا الهدف. وتعمل العديد من الاختبارات الإحصائية (مثل اختبار t) على تحديد المصادر المنهجية واللامنهجية للتغاير ومقارنتها. تسمح هذه المقارنة بمعرفة فيما إذا كانت التجربة قد ولّدت تغايراً أكبر بكثير مما قد نحصل عليه فيما لو اختبرنا المشاركين دون تلاعب تجريبي. والعشوائية (Randomization) هامة لأنها تلغي المصادر الأخرى للتغاير المنهجي مما يسمح لنا بالتأكد من أن أي تغاير منهجي بين الحالات التجريبية يعود للتلاعب بالمتحول المستقل.

لننظر أولاً إلى تصميم القياسات المكررة. عندما يشارك نفس الأشخاص في أكثر من حالة تجريبية فإن هذا يخالف بشكل بديهي مفهوم التوزيع العشوائي للأشخاص على المجموعات. فعلى الرغم من أن الأشخاص المشاركين في الحالة التجريبية الأولى كانوا سُذّجاً، فإنهم يشاركون في الحالة التجريبية الثانية بخبرة ناتجة عن مشاركتهم الأولى. أو على الأقل فإنهم يعرفون القياس الذي يخضعون له (أو المهمة التي يقومون بتأديتها). وأهم مصدرين للتغاير المنهجي في هذا النوع من التصميم هما:

- **آثار الممارسة (Practice effects):** إن المشاركين يؤدون بشكل مختلف في الحالة الثانية وذلك لمعرفتهم بالحالة التجريبية و/أو القياسات المستخدمة.
- **آثار الضجر (Boredom effects):** إن المشاركين يؤدون بشكل مختلف في الحالة الثانية وذلك لأنهم تعبوا أو سئموا عند انجازهم الحالة الأولى.

ومع أنه من المستحيل حذف هذه الآثار بشكل كامل، يمكننا أن نؤكد أنها لا تعطي تغايراً منهجياً بين الحالتين. ويمكننا أن ننجز ذلك بإجراء توازن في الترتيب الذي يشارك به شخص ما في حالة تجريبية. يمكننا أن نختار بشكل عشوائي الشخص الذي سيشارك في الحالة الأولى قبل الحالة الثانية، أو في الحالة الثانية قبل الحالة الأولى. إذا نظرنا إلى مثال طريقة التعليم في بداية هذا الفصل، فإذا شارك نفس الأشخاص في الحالتين فإننا قد نجد أن مقدرتهم في علم الإحصاء كانت أعلى بعد حالة الدعم السلبي. على كل حال، لقد خضع جميع الطلاب لحالة الدعم السلبي بعد حالة الدعم الإيجابي ولذلك فإنهم انتقلوا إلى حالة الدعم السلبي وقد حصلوا على معرفة أفضل في علم الإحصاء مما كانوا عليه عند دخولهم مرحلة الدعم الإيجابي. لذلك فإن التحسن الظاهري بعد الدعم السلبي لا يعود إلى التلاعب التجريبي (ليس بفضل الدعم السلبي)، إنه بفضل مشاركة الطلاب في محاضرات أكثر (أي بعد انتهاء مرحلة الدعم السلبي). يمكننا أن نؤكد أن عدد محاضرات الإحصاء لم يُدخل تأثيراً منهجياً بفضل عشوائية ترتيب الحالات، لذلك يمكننا أن نأخذ نصف عدد الطلاب بشكل عشوائي ونخضعهم لحالة الدعم السلبي أولاً بينما يخضع النصف الآخر لحالة الدعم الإيجابي أولاً.

إذا انتقلنا الآن إلى التصميم المستقل، فيمكننا تطبيق مناقشة مماثلة. نعلم أن مشتركين مختلفين يشاركون في الحالات التجريبية المختلفة وأن هؤلاء المشتركون يختلفون عن بعضهم بعدد من المزايا (مستوى الذكاء، والانتباه وغيره). ومع أننا نعلم أن هذه العوامل (المعروفة باسم المتحولات المحيّرة (Confounding Variables)) تساهم بالتغاير بين الحالات فإننا يجب أن نكون متأكدين بأن هذه

المتحولات تساهم في التغاير اللامنهجي وليس في التغاير المنهجي. والطريقة لتأكيد أن المتحولات المحيرة لن تساهم بشكل منهجي بالتغاير بين الحالات التجريبية هي تعيين المشتركين بشكل عشوائي إلى حالة تجريبية معينة. ويجب أن يؤكد ذلك أن هذه المتحولات المحيّرة موزعة بشكل منتظم بين الحالات.

ومثال جيد عن ذلك هو أثر الكحول على الشخصية.. فقد تعطي لمجموعة ما من الأشخاص 5 أقداح من البيرة وتترك على المجموعة الثانية دون إعطائها الكحول، ثم تحسب عدد المشاجرات التي يشترك فيها كل شخص. إن تأثير الكحول على الناس يمكن أن يكون متغيراً جداً وذلك بسبب مستويات التسامح المختلفة: فالأشخاص الذين لا يتناولون المسكرات أبداً قد يصبحون ثملين بعد تناول كمية قليلة من الكحول، أما المدمنين فيحتاجون لكميات كبيرة من الكحول قبل أن يؤثر الكحول عليهم. والآن إذا وضعت مجموعة من الأشخاص الذين لا يتناولون المسكرات في الحالة التي تستهلك الكحول فإنك قد لا تجد فرقاً بينهم وبين المجموعة التي لم تتناول الكحول (المجموعة الثانية) وذلك لأن جميع المشتركين أصبحوا غير واعين بعد الكأس الأولى لذلك لن يتورطوا في أية مشاجرات. وهكذا فإن خبرات الشخص السابقة مع الكحول ستؤدي لحدوث تغاير منهجي لا يمكن فك ارتباطه عن أثر التلاعب التجريبي. وإن أفضل طريقة لتخفيض هذه الإمكانية هي تعيين المشتركين بشكل عشوائي في الحالات التجريبية.

3.7 إدخال البيانات وإظهار المتوسطات على مخطط أعمدة الخطأ

لقد حاولنا في الفصل 3 التشديد على أهمية النظر إلى مخطط البيانات قبل البدء بعملية التحليل. وتساعد المخططات على فهم ما يجري ضمن البيانات ومعرفة أنواع النتائج التي نتوقع الحصول عليها. وقد رأينا في الفقرة 7.3 كيفية رسم مخططات الأعمدة (Bar charts) للمتوسطات. وغالباً ما تُقدم مخططات الأعمدة في الأبحاث الأكاديمية وهي طريقة رائعة لتلخيص البيانات ولكنها تعطي نظرة ضعيفة جداً للبيانات (حيث لا يعطي مخطط الأعمدة أي إشارة عن عدد العلامات التي تساهم بكل قيمة للمتوسط، أو عن التغاير الموجود في العلامات). وقد ذكرنا في الفقرة 7.3 عمود الخطأ وذكرنا أنه أفضل طريقة لفحص البيانات. يعرض مخطط عمود الخطأ (error bar chart) قيمة المتوسط ومجال الثقة 95% (أنظر الفقرة 2.6.1) لقيمة المتوسط لكل من الحالات التجريبية.

ولحسن الحظ أنك أصبحت ملمّاً بمجالات الثقة لأننا قد تعاملنا معها في الفصول 1 و5 و6. لنعد الآن إلى المثال في الفقرة 2.6.1 حيث حاولنا قياس الكمية المتوسطة للحيوانات المنوية (بالملايين) التي يعطيها طير السماني الياباني. وقد شرحنا حينها أنه إذا أخذنا 100 عينة من مجتمع ما وحسبنا قيمة المتوسط لكل منها وأنشأنا مجال الثقة 95% لكل منها فإن ذلك يعني أن 95 من مجالات الثقة التي يبلغ عددها 100 سيحوي القيمة الصحيحة للمتوسط (القيمة في المجتمع). لذلك إذا كان الحد الأدنى لمجال الثقة هو 2 والحد الأعلى 16 فإن ذلك يعني أننا واثقون بنسبة 95% بأن هذا المجال

يحوي قيمة المتوسط للمجتمع (الكمية الفعلية للسائل المنوي التي يعطيها طائر السماني). ولذلك فإن مخطط عمود الخطأ يبين الحدود التي نعتقد أن القيمة الفعلية للمتوسط تقع بينها.

ستكتشف بعد قليل أن الاختبار t يعمل على مبدأ أنه إذا أخذنا عينتين من نفس المجتمع فيجب أن يكون لهما نفس المتوسط تقريباً. ونعلم من الفصل 1 أنه من الممكن أن تختلف قيم المتوسط لعينتين بشكل طفيف (ويدلنا الخطأ المعياري القليل عن مقدار الاختلاف بين قيم المتوسط للعينات). يخبرنا مجال الثقة عن الحدود التي من المحتمل أن يقع متوسط المجتمع بينها (وتعتمد أبعاد مجال الثقة على حجم الخطأ المعياري) وفي المثال السابق نعلم أن متوسط المجتمع ربما يقع بين القيمتين 2 و16. ولكن إذا أخذنا عينة ثانية من طيور السماني ووجدنا أن مجال الثقة يتراوح بين القيمتين 4 و15، فإننا نجد أن مجال الثقة للعينة الثانية يتطابق بشكل كبير مع مجال الثقة للعينة الأولى:

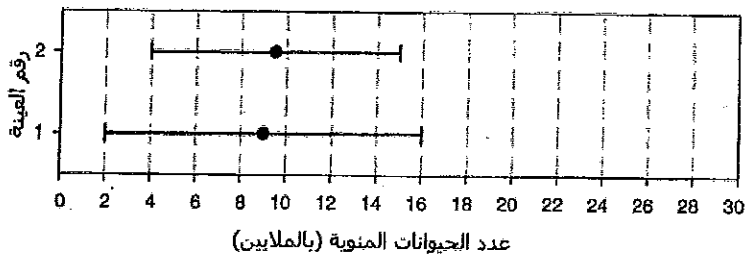

إن تطابق مجالي الثقة بهذه الطريقة يخبرنا بأن قيم المتوسط يمكن أن تأتي من نفس المجتمع، ففي كلتا الحالتين نحن واثقون بنسبة 95% بأن المجالات تحوي القيمة الصحيحة للمتوسط، ومجالي الثقة متطابقان، ولذلك فهما يحويان قيماً متشابهة كثيرة. ولكن ماذا لو كان مجال الثقة للعينة الثانية يتراوح بين القيمتين 18 و 28؟ إذا قارنّا هذا المجال مع مجال الثقة للعينة الأولى فإننا نحصل على ما يلي:

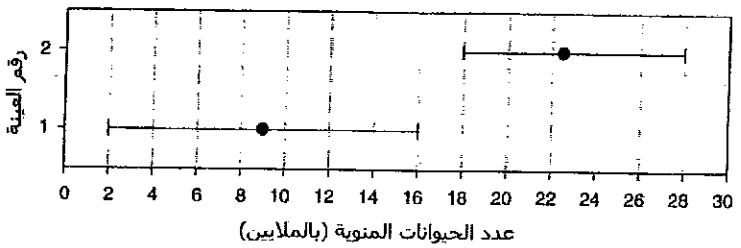

لا يتطابق مجالا الثقة أبداً. يخبرنا مجال الثقة للعينة الأولى (ونحن واثقون بنسبة 95% من أنه يحوي القيمة الصحيحة للمتوسط) أن متوسط المجتمع سيقع بين القيمتين 2 و 16، بينما يخبرنا مجال الثقة للعينة الثانية (ونحن واثقون بنسبة 95% أيضاً من أنه يحوي القيمة الصحيحة للمتوسط) أن متوسط المجتمع سيقع بين القيمتين 18 و 28. وهذا يعني أن العينات تأتي من مجتمعين مختلفين، أو أن العينات تأتي من نفس المجتمع ولكن أحد مجالي الثقة لا يحوي قيمة المتوسط للمجتمع. إذا كنا نستخدم مجال

الثقة 95% فإننا نعلم أن الاحتمال الثاني غير مرجح (لأن ذلك يحدث 5 مرات فقط من أصل 100) لذلك فإن التفسير الأول هو الأرجح.

ربما تتساءل الآن "إذاً ما العمل إذا كانت العينات من مجتمعين مختلفين؟". إذا أخذنا عينتين عشوائيتين من الناس واختبرناهما بإجراء بعض القياسات، فإننا نتوقع أن ينتمي هؤلاء الأشخاص إلى نفس المجتمع. إذا كانت قيم المتوسط للعينات مختلفة جداً فإننا نقول أنها من مجتمعات مختلفة. لماذا يمكن أن يحدث ذلك؟ الجواب هو أن التلاعب التجريبي قد حرّض فرقاً بين العينات.

عندما يكون التلاعب التجريبي ناجحاً فإننا نتوقع أن تنتمي العينات لمجتمعات مختلفة. أما إذا كان التلاعب التجريبي غير ناجح فإننا نتوقع أن تنتمي العينات لنفس المجتمع (قيم المتوسط للعينات متشابهة تقريباً). يخبرنا مجال الثقة 95% شيئاً ما عن القيمة المحتملة لمتوسط المجتمع. إذا أخذنا العينات من مجتمعين فإننا نتوقع أن تكون مجالات الثقة مختلفة (ولكي نتأكد من أن العينات تنتمي لمجتمعين مختلفين فإننا لا نتوقع أن يتطابق مجالا الثقة لهما). إذا أخذنا عينتين من نفس المجتمع فإننا نتوقع، إذا كانت قياساتنا موثوقة، أن تكون مجالات الثقة متماثلة جداً (يجب أن يتطابق مجالا الثقة بشكل كامل). قد تتساءل إلى أين يقودنا تحويل الانتباه إلى نظرية اختبار الفرضية، حسناً إنه يتبع ما قلناه حول التلاعب التجريبي الناجح الذي يدل على أن مجالات الثقة للمجموعات التجريبية يجب أن لا تكون متطابقة. إذا كان التلاعب غير ناجح فإن مجالات الثقة ستكون متطابقة. وفيما يتعلق بمخطط عمود الخطأ فإننا نجد أنه إذا كانت الأعمدة في مخطط عمود الخطأ غير متطابقة فهذا دليل على فرق كبير بين المجموعات. ونذكر هنا أن أعمدة الخطأ في SPSS مناسبة فقط للبيانات الموزعة طبيعياً.

1.3.7 مخطط عمود الخطأ للتصميم بين المجموعات

عندما يتم جمع البيانات باستخدام مشتركين مختلفين في كل مجموعة، فإننا بحاجة لإدخال البيانات باستخدام متحول ترميز (أنظر الفقرة 4.4.2). لذلك فإن محرر البيانات سيحوي عمودين من البيانات، العمود الأول هو متحول ترميز (يمكنك تسميته group) يحوي رمزين فقط عندما يكون لدينا مجموعتين فقط (ونقترح أن تكون القيم هي: 0=المجموعة الأولى، 1=المجموعة الثانية)، أما العمود الثاني فيحوي قيم المتحول التابع.

لقد استخدمنا في هذا الفصل نفس مجموعة البيانات لأنها تسمح بإظهار أشياء مختلفة. ويتعلق المثال المدروس بما يسمى الخوف من العناكب وفيما إذا كان مرتبطاً بالعناكب الحقيقية أو أن صور العناكب قد تثير نفس المستوى من الخوف والاضطراب. تم استخدام 24 شخصاً ممن يعانون من الخوف من العناكب. وقد طلبنا من 12 منهم أن يلعبوا مع عناكب حقيقة كبيرة، وقد تم قياس الخوف لديهم. أما المجموعة الباقية والمؤلفة من 12 شخصاً فقد عرضنا عليهم صورة لنفس العناكب التي تلعب معها المجموعة الأولى وقسنا مستوى الخوف أيضاً. يحوي الملف SpiderBG.sav هذه

البيانات، ولكن يمكن للأشخاص الراغبين في ممارسة إدخال البيانات أن يقوموا بذلك حيث يحوي (الجدول 1.7) نفس البيانات. تذكّر أن كل سطر من محرر البيانات يمثل بيانات مشترك مختلف. لذلك فأنت بحاجة لعمود يمثل المجموعة التي ينتمي إليها المشترك، وعمود آخر ليمثل مستوى خوفه. تبين البيانات في الجدول 1.7 رموز المجموعات وليس التسمية الموافقة للرمز. عند إدخال البيانات في برنامج SPSS تذكر أن تخبر البرنامج بأن الرمز 0 يمثل المجموعة التي شاهدت الصورة. وأن الرمز 1 يمثل المجموعة التي شاهدت العناكب الحقيقية (أنظر الفقرة 4.4.2).

المشترك	المجموعة	مستوى الخوف
1	0	30
2	0	35
3	0	45
4	0	40
5	0	50
6	0	35
7	0	55
8	0	25
9	0	30
10	0	45
11	0	40
12	0	50
13	1	40
14	1	35
15	1	50
16	1	55
17	1	65
18	1	55
19	1	50
20	1	35
21	1	30
22	1	50
23	1	60
24	1	39

الجدول 1.7 البيانات من الملف SpiderBG.sav

بعد إدخال البيانات (أو فتح الملف SpiderBG.sav) يمكنك الوصول إلى مربع الحوار error bar باستخدام أمر القائمة Graphs ⇒ Error Bar... حيث تحصل على مربع الحوار المبين في الشكل 1.7. هناك خياران لمخطط عمود الخطأ. الخيار الأول هو مخطط عمود الخطأ البسيط (لرسم مستويات من متحول مستقل وحيد) أما الخيار الثاني فهو مخطط عمود الخطأ الكتلي. يمكن استخدام النوع

الثاني من مخطط عمود الخطأ عند قياس متحول مستقل ثاني بين المجموعات (كالجنس مثلاً). إن المخطط المناسب لهذا المثال هو المخطط البسيط. الخيار التالي هو فيما إذا كانت البيانات في المخطط تلخص مجموعات من الحالات أو المتحولات المنفصلة. ويمكنك هنا إتباع القاعدة البسيطة التالية: اختر Summaries for groups of cases عندما تكون البيانات مجمّعة باستخدام مشتركين مختلفين (كما هي الحال هنا) واختر Summaries of separate variables عندما تكون البيانات مجمّعة باستخدام نفس المشتركين. بعد الانتهاء من تحديد الخيارات المناسبة انقر الزر Define.

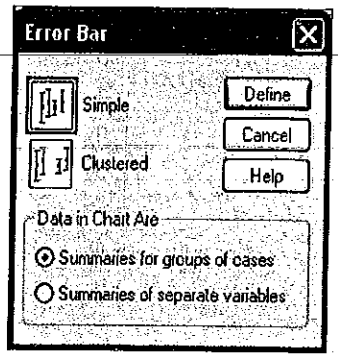

الشكل 1.7 مربع الحوار الأولى لمخطط عمود الخطأ

يظهر مربع الحوار المبين في (الشكل 2.7) الذي يسمح بتحديد المتحولات التي تريد رسمها. في هذا المثال لدينا متحولان فقط هما group وanxiety. انقر المتحول anxiety من القسم الأيسر لمربع الحوار وانقله إلى الحيز المسمى Variable بنقر زر السهم الموجود بين القسمين. ثم حدد المتحول group في القسم الأيسر لمربع الحوار وانقله إلى الحيز المسمى Category Axis بنقر زر السهم الموجود بين القسمين. يمكنك رسم عدة أشياء باستخدام هذا النوع من المخططات، ويسمح الخيار الافتراضي برسم مجال الثقة 95%. وهذا النوع من المخططات هو الأكثر فائدة ويمكن ترك خياراته الافتراضية دون تغيير.

يبين (الشكل 3.7) مخطط عمود الخطأ الناتج، وكما ترى فإنه يبدو كحرفي I. وفي منتصف كل من العمودين هناك مربع يمثل قيمة المتوسط للمجموعة. وتبين الخطوط الشاقولية امتداد مجال الثقة حول قيمة المتوسط. لذلك يمكنك أن ترى من هذا المخطط للبيانات أنه عند عرض صورة العنكبوت كان المستوى الوسطي للخوف هو 40 ومن المحتمل أن تقع قيمة المتوسط للمجتمع في المجال بين 34 و46. وعلى كل حال، عند استخدام العنكبوت الحقيقي فإن متوسط الخوف كان 47 ومن المحتمل أن تقع قيمة المتوسط للمجتمع بين 40 و54. والأهم من ذلك أن أعمدة الخطأ تتطابق بشكل كبير مما يدل على عدم احتمال انتماء هذه العينات إلى مجتمعين مختلفين (أي أن التلاعب التجريبي لم يكن ناجحاً). ولمعرفة فيما إذا كان الاستنتاج الأخير صحيحاً، عليك أن تنتظر الفقرة 3.6.7.

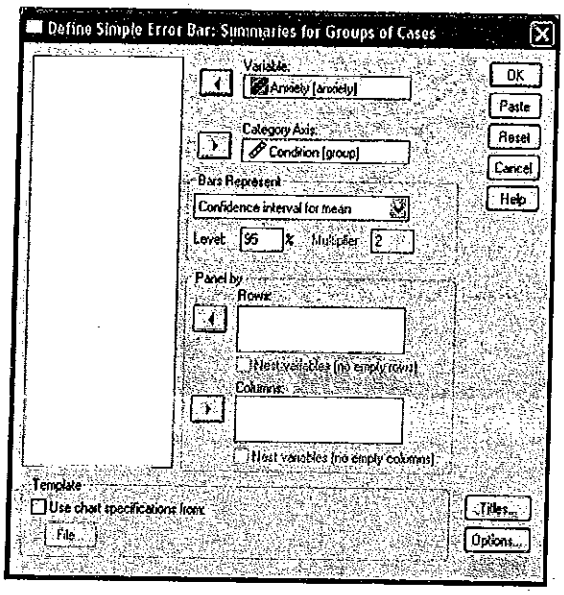

الشكل 2.7 مربع الحوار الرئيسي لعمود الخطأ من أجل الخيار Summaries for groups of cases

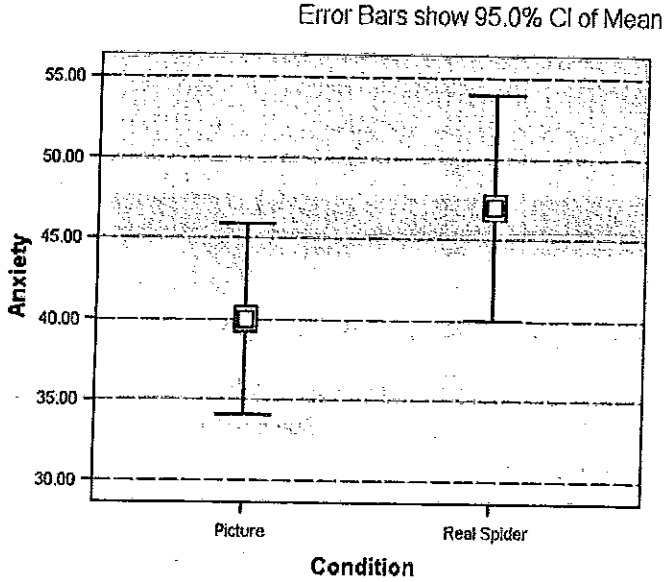

الشكل 3.7 مخطط عمود الخطأ للبيانات SpiderBG.sav

2.3.7 مخطط عمود الخطأ لتصميم القياسات المكررة

إذا كررنا الدراسة كما وصفناها سابقاً ولكن باستخدام نفس المشتركين في كلتا الحالتين، فإنه يمكننا رسم مخطط عمود الخطأ المشابه لما نراه في (الشكل 3.7). والمشكلة في إنشاء مخطط عمود

الخطأ لبيانات القياسات المكررة هي أن برنامج SPSS يعامل البيانات كما لو أنه تم استخدام مجموعات من المشتركين. ولتتأكد من صحة هذا الكلام فقد وضعنا بيانات هذه الدراسة في الملف SpiderRM.sav. إن قيم المتحول anxiety هي مماثلة لبيانات "التصميم بين المجموعات". على كل حال، تم ترتيب البيانات كما لو أن نفس المشتركين قد شاركوا في كل من الحالتين (تم عرض صورة العنكبوت على كل مشترك وتم قياس مستوى الخوف، ثم وفي وقت آخر تم تعريض المشترك للعنكبوت الحقيقي وقياس مستوى الخوف مرة أخرى). تم ترتيب البيانات بشكل مختلف لأن نفس المشتركين قد شاركوا في الحالتين. في برنامج SPSS يمثل كل صف في محرر البيانات مشتركاً وحيداً، ولذلك فإنه في هذا التصميم يتم ترتيب البيانات في عمودين (يمثل أحدهما حالة عرض الصورة ويمثله المتحول picture، بينما يمثل الآخر حالة العنكبوت الحقيقي ويمثله المتحول real). يبين (الجدول 2.7) هذه البيانات، ومن المفضل أن تقوم بإدخال البيانات بنفسك في محرر البيانات بدلاً من استخدام الملف الجاهز.

المشترك	picture	real
1	30	40
2	35	35
3	45	50
4	40	55
5	50	65
6	35	55
7	55	50
8	25	35
9	30	30
10	45	50
11	40	60
12	50	39

الجدول 2.7 بيانات الملف SpiderRM.sav

لرسم مخطط عمود الخطأ لهذه البيانات، افتح مربع الحوار error bar باستخدام أمر القائمة Graphs ⇒ Error Bar... (أنظر الشكل 1.7) ثم حدد الخيار Summaries of separate variables وانقر الزر Define حيث يتم فتح مربع الحوار الرئيسي. اختر المتحولين picture وreal ثم انقر الزر OK. يجب أن يكون المخطط الناتج مماثلاً لما حصلنا عليه في حالة البيانات بين المجموعات. لقد وقعنا في مشكلة الآن، إذ أننا هدرنا وقتاً ثميناً في الحديث عن أن تصميم القياسات المكررة يلغي كثيراً من التباين اللامنهجي، ولكن رسم بيانات القياسات المكررة بهذه الطريقة جعلنا نهمل مكون القياسات المكررة من البيانات. اقترح Loftus & Masson (1994) طريقة للتغلب على هذه المشكلة وهي حذف التغايرية "بين المجموعات" وذلك بمعايرة المتوسطات للمشترك (وهذا يعني التأكد من

أن جميع المشتركين لهم نفس المتوسط عبر الحالات المختلفة). ولمعايرة المتوسطات نحتاج لاستخدام الوظيفة compute في برنامج SPSS وتنفيذ عدة خطوات إضافية (لقد استخدمنا هذه الوظيفة في الفقرة 4.3.3).

لقد اكتشفنا في الفقرة 4.3.3 أن التعليمة compute تسمح بتنفيذ الوظائف على أعمدة البيانات (كالجمع أو الضرب بين الأعمدة). وقبل المضي في ذلك، عليك العودة إلى تلك الفقرة لتنشيط ذاكرتك بما يخص روائع تلك الوظيفة.

1.2.3.7 الخطوة الأولى: حساب المتوسط لكل مشترك

بفرض أنك قمت بمراجعة الوظيفة compute، يمكنك إذاً استخدامها لرسم مخطط أعمدة الخطأ للتصميم بين المجموعات بدقة أكبر. ولكي تبدأ فإنك بحاجة لحساب القيمة الوسطى للخوف لكل مشترك ولذلك نستخدم الوظيفة mean. للوصول إلى مربع الحوار الرئيسي للوظيفة compute، استخدم أمر القائمة Transform ⇒ Compute... اكتب اسم المتحول mean في الحيز المسمى Target Variable ثم ابحث في القائمة المنسدلة للوظائف عن الوظيفة MEAN(numexpr, numexpr,...). حدد هذه الوظيفة وانقلها إلى حيز الأوامر بنقر زر السهم المشير للأعلى. بعد نقل هذه الوظيفة إلى حيز الأوامر فإنها تظهر بالشكل "MEAN(?,?)" ويجب استبدال علامتي الاستفهام بأسماء المتحولات (حيث يمكنك كتابة الأسماء يدوياً أو نقلها من لائحة المتحولات). استبدل علامة الاستفهام الأولى بالمتحول picture والعلامة الثانية بالمتحول real. بعد الانتهاء يبدو مربع الحوار كما في الشكل 4.7.

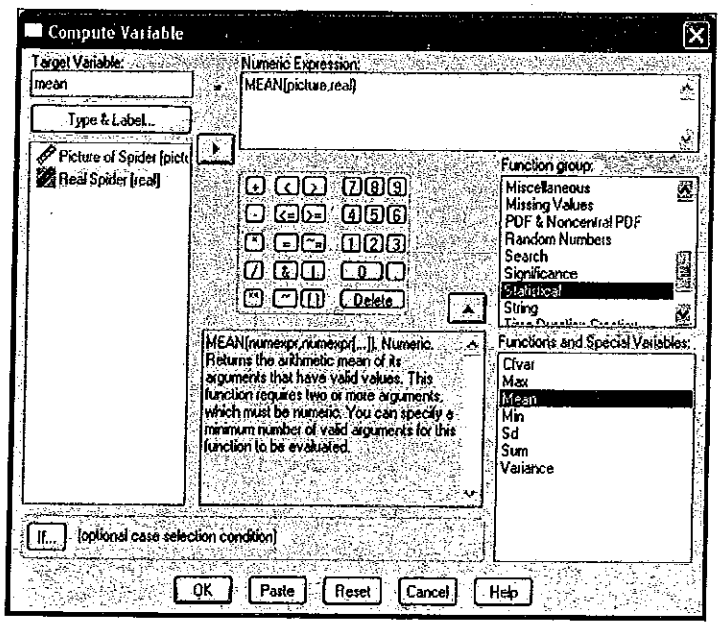

الشكل 4.7 استخدم الوظيفة Compute لحساب المتوسط لعمودين

2.2.3.7 الخطوة الثانية: حساب المتوسط الكلي

المتوسط الكلي (Grand mean) هو المتوسط لجميع العلامات بغض النظر عن الحالة التي تنتمي إليها، ومن أجل البيانات الحالية فإن قيمة المتوسط الكلي هي المتوسط لجميع العلامات والتي يبلغ عددها 24. يمكن حساب هذه القيمة يدوياً (نجمع جميع العلامات ثم نقسم الناتج على 24)، ولكن هناك طريقة أسهل وهي استخدام المتوسطات التي قمنا بحسابها في الخطوة الأولى. تمثل هذه المتوسطات العلامة الوسطية لكل مشترك ولذلك إذا أخذنا المتوسط لهذه القيم المتوسطة فإننا نحصل على المتوسط لجميع المشتركين (أي المتوسط الكلي). ولكي نقوم بذلك نستخدم الوظيفة descriptives (كما يمكنك أن تستخدم الوظائف Explore أو Frequencies التي صادفتها في الفصل 3، ولكن بما أنك اكتشفت تلك الوظائف فإننا سنجرب وظيفة جديدة). ويمكنك الوصول إلى هذه الوظيفة عبر أمر القائمة Analyze⇒ Descriptive Statistics ⇒ Descriptives... حيث يظهر مربع الحوار المبين في (الشكل 5.7). تُستخدم الوظيفة descriptives للحصول على الإحصائيات الوصفية الأساسية للمتحولات، ونصل إليها بنقر الزر Options... حيث يظهر مربع حوار آخر. اختر المتحول mean من القسم الأيسر لمربع الحوار الرئيسي وانقله إلى الحيز المسمى Variable(s) استخدم مربع الحوار Options لتحديد خيار المتوسط Mean فقط (يمكنك المحافظة على الإعدادات الافتراضية إذا كانت قيمة المتوسط هي التي تهمك فقط). إذا نفذت هذا التحليل فإن الخرج يعطيك الإحصائيات الوصفية لكل من المتحولات الثلاثة (بفرض أنك حددت جميع المتحولات). يجب أن تدرك أننا حصلنا على قيمة المتوسط لحالة عرض الصورة والمتوسط لحالة العنكبوت الحقيقي، ولكن ما يهمنا فعلياً هو المتحول الأخير: المتوسط لحالتي عرض الصورة والعنكبوت الحقيقي. وقيمة المتوسط لهذا المتحول هي قيمة المتوسط الكلي، وكما ترى فإن قيمته تبلغ 43.50. سنستخدم قيمة المتوسط الكلي في الحسابات اللاحقة.

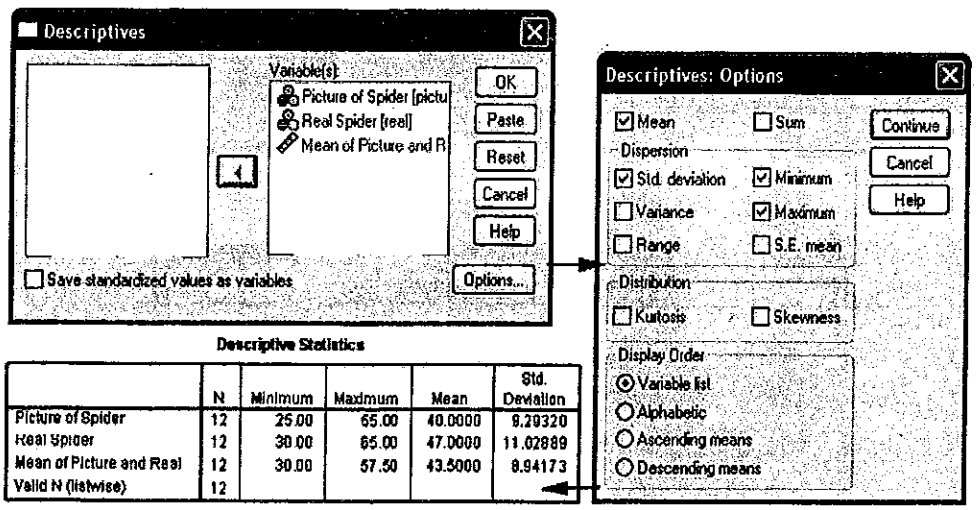

الشكل 5.7 مربعات الحوار والخرج للإحصائية Descriptives

3.2.3.7 الخطوة الثالثة: حساب عامل التعديل

إذا نظرت إلى المتحول المسمى mean فإنك تلاحظ أن القيم لكل مشترك مختلفة عن بقية المشتركين، وهذا يدل على أن بعض الأشخاص يخافون أكثر من بقية الأشخاص في الحالات المختلفة. إن حقيقة اختلاف قيم المتوسط لخوف المشتركين تمثل الفروق الشخصية بين الأشخاص المختلفين (لذلك فهي تمثل حقيقة أن بعض الأشخاص يخافون من العنكبوت أكثر من الأشخاص الآخرين). وهذه الفروق في الخوف الطبيعي من العناكب تلوث مخطط عمود الخطأ، ولذلك فإنه إذا لم نعدّل القيم التي نرسمها فإننا نحصل على نفس المخطط للتصميم بين المجموعات. ولحذف هذا التلوث يقترح Loftus & Masson (1994) أن نساوي بين قيم المتوسط للمشتركين (أي تعديل العلامات في كل حالة بحيث أنه إذا أخذنا المتوسط بين الحالات فإنها تكون نفس القيمة لجميع المشتركين). ولإنجاز ذلك يجب أن نحسب عامل التعديل بطرح علامة المتوسط لكل مشترك من قيمة المتوسط الكلي. يمكننا استخدام الوظيفة Compute للقيام بهذه الحسابات. نفتح مربع الحوار Compute ونعطي اسماً للمتحول الهدف (وليكن adjust) ثم نستخدم التعليمة "43.5 - mean". حيث تقوم هذه التعليمة بطرح قيمة المتحول mean لكل مشترك من قيمة المتوسط الكلي البالغة 43.5 (أنظر الشكل 6.7).

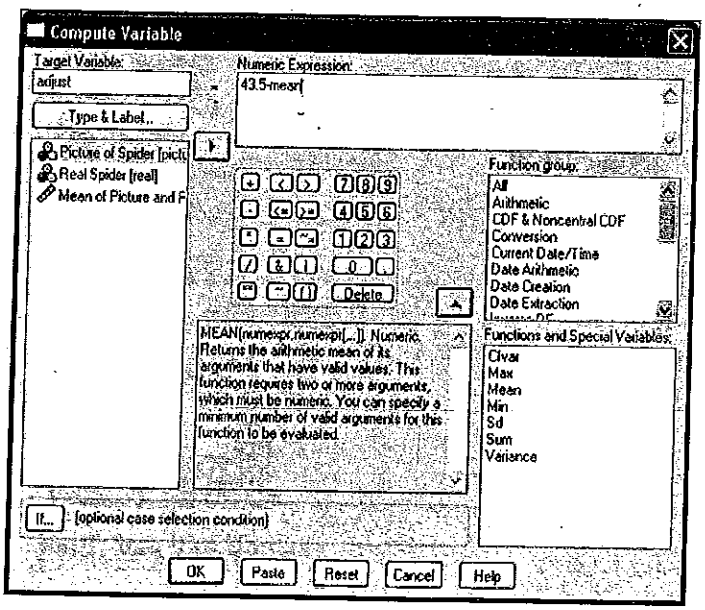

الشكل 6.7 حساب عامل التعديل

تقوم هذه التعليمة بإنشاء متحول جديد في محرر البيانات يدعى adjust، يمثل الفرق بين متوسط الخوف لكل مشترك ومتوسط الخوف لجميع المشتركين. تلاحظ أن بعض القيم موجبة، وهذا يعني أن المشترك هو أحد الذين يخافون بمستوى أقل من المتوسط. أما المشتركين الذين يخافون بمستوى

أعلى من المتوسط فإن علاماتهم تكون سالبة. يمكننا استخدام قيم عامل التعديل لحذف الفروق في التصميم بين المجموعات.

4.2.3.7 الخطوة الرابعة: إنشاء القيم المعدّلة لكل متحول

لقد حسبنا الفرق بين قيمة المتوسط لكل مشترك والمتوسط الكلي لجميع المشتركين. ويمكننا استخدام هذا الفرق لتعديل العلامات الموجودة لكل مشترك. سنقوم أولاً بتعديل العلامات في حالة عرض الصورة (picture). نستخدم مرة أخرى الوظيفة Compute لتنفيذ عملية التعديل. نفتح مربع الحوار Compute ونسمي المتحول الجديد picture2. (يمكنك نقر الزر Type & Label... لإعطاء تسمية لهذا المتحول مثل "Adjusted values for picture condition"). وكل ما سنفعله هو إضافة علامة كل مشترك في الحالة picture إلى قيمة التعديل الخاصة به. اختر المتحول picture وانقله إلى منطقة الأوامر، واكتب علامة الجمع (+) ثم اختر المتحول adjust وانقله إلى منطقة الأوامر. يجب أن يكون الشكل النهائي لمربع الحوار كما في (الشكل 7.7). يمكنك الآن تنفيذ نفس الخطوات من أجل المتحول real، أنشئ متحولاً جديداً باسم real2 يحوي مجموع القيمتين real وadjust.

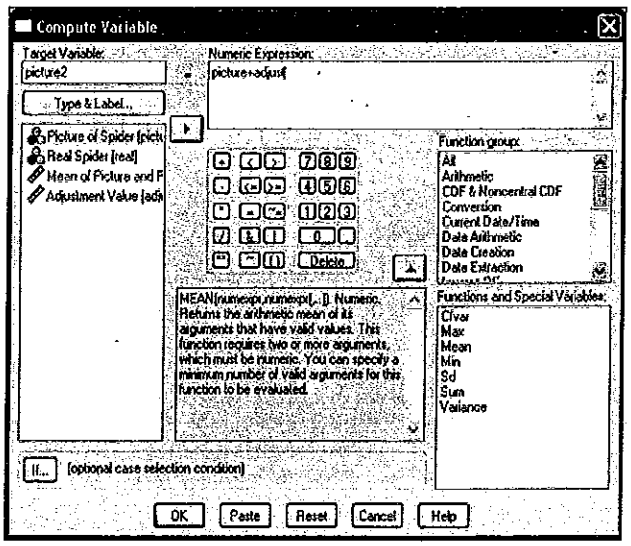

الشكل 7.7 تعديل القيم للمتحول picture

يمثل المتحولان picture2 وreal2 الخوف في كل من الحالتين التجريبيتين بعد تعديلهما لحذف الفروق في التصميم بين المجموعات. يمكنك التحقق من هذا الكلام باستخدام الوظيفة Compute لإنشاء المتحول mean2 التي يمثل القيمة المتوسطة للمتحولين picture2 وreal2 (كما فعلنا في الفقرة 1.2.3.7). يجب أن تكون القيمة في هذا العمود ذاتها لجميع المشتركين، وهذا يثبت اختفاء التغايرية بين المجموعات. وهذه القيمة هي "المتوسط الكلي - 43.50".

5.2.3.7 رسم مخطط عمود الخطأ

إن رسم المخطط مشابه لسيناريو التصميم بين المجموعات. نفتح أولاً مربع الحوار الرئيسي عبر أمر القائمة Graphs ⇒ Error Bar... حيث يظهر مربع الحوار (كالمبين في الشكل 1.7). حدد الخيار Summaries of Separate Variables ثم انقر الزر Define حيث يظهر مربع الحوار الرئيسي المبين في الشكل 8.7. اختر المتحولين picture2 و real2 ثم انقر الزر OK.

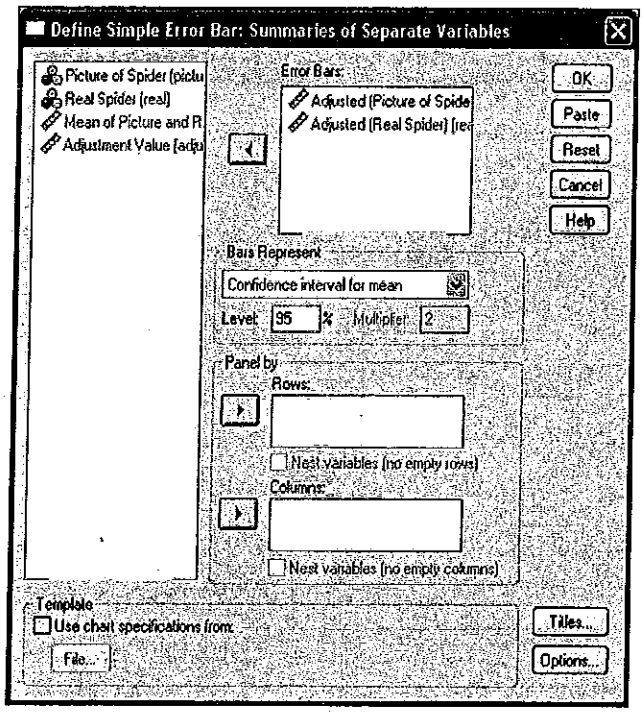

الشكل 8.7 مربع الحوار الرئيسي لرسم مخطط عمود الخطأ لمتحولات تصميم القياسات المكررة

يبين (الشكل 9.7) مخطط عمود الخطأ. تلاحظ أن مخطط عمود الخطأ للقيم المعدّلة مختلف نوعاً ما عن المخطط للقيم غير المعدّلة والمبين في الشكل 3.7. إن أول ما يجب ملاحظته هو عدم تطابق عمودي الخطأ. لقد قلنا سابقاً أنه عندما لا تتطابق أعمدة الخطأ فإنه يمكننا أن نكون على ثقة بأن العينات لا تنتمي لنفس المجتمع (أي أن التلاعب التجريبي كان ناجحاً). لذلك فإن المخطط لنسخة القياسات المكررة من هذه البيانات يدل على أن العناكب الحقيقية أثارت خوفاً أكبر (لأن قيمة المتوسط أعلى) من عرض الصورة. يوضح هذا المثال مدى اختلاف الاستنتاجات التي يمكن التوصل إليها بناءً على طريقة جمع البيانات (هل هي لنفس المشتركين أو لمشتركين مختلفين)، وسنشرح هذه النقطة بتفصيل أكبر في الفقرة 7.7.

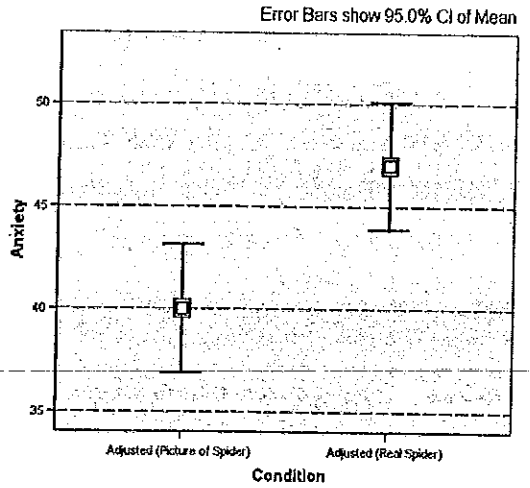

الشكل 9.7 مخطط عمود الخطأ للقيم المضبوطة للبيانات spiderRM.sav

4.7 اختبار الفروق بين المتوسطات: الاختبار t

إن أبسط شكل للتجارب التي يمكن تنفيذها هي التي تحوي متحولاً مستقلاً وحيداً ويمكن التلاعب به بطريقتين فقط وهناك نتيجة واحدة يتم قياسها. وغالباً ما يتضمن التلاعب بالمتحول المستقل حالة تجريبية ومجموعة مراقبة. ومن الأمثلة على هذا النوع من التصميم يمكن أن نذكر:

- هل فيلم scream2 مخيف أكثر من الفيلم الأول scream ؟ يمكننا قياس معدل ضربات القلب (الذي يدل على الخوف) خلال كلا الفيلمين ومقارنتهما.
- هل الاستماع للموسيقى أثناء العمل يحسّن جودة العمل؟ يمكنك أن تطلب من بعض الأشخاص كتابة مقالة (أو كتاب) مع الاستماع لموسيقاهم المفضلة، ثم كتابة مقالة أخرى بدون موسيقى (هذه هي مجموعة المراقبة). يمكنك بعد ذلك مقارنة درجات المقالتين.
- هل استماعك إلى موسيقاي المفضلة يحسّن عملك؟ يمكنك تكرار التجربة السابقة ولكن بدلاً من استماع الأشخاص إلى موسيقاهم المفضلة يمكنك أن تُسمِعهم موسيقاك المفضلة ومراقبة جودة أعمالهم.

إن الاختبار t (t-test) مصمم لتحليل هذه الأنواع من السيناريوهات. هناك طبعاً تجارب أكثر تعقيداً وسننظر إليها في الفصول اللاحقة. هناك في الواقع نوعان مختلفان من الاختبار t، ويعتمد النوع الذي تستخدمه على التلاعب الذي تم على المتحول المستقل، هل استخدم نفس المشتركين أم مشتركين مختلفين:

- **اختبار t للمتوسطات المستقلة:** يُستخدم هذا الاختبار عندما تكون هناك حالتان تجريبيتان ومشتركون مختلفون لكل حالة تجريبية (يدعى هذا الاختبار أحياناً باختبار t للقياسات المستقلة أو للعينات المستقلة).

- **اختبار t للمتوسطات التابعة:** يُستخدم هذا الاختبار عندما تكون هناك حالتان تجريبيتان ونفس المشتركين في كلتا الحالتين التجريبيتين (يدعى هذا الاختبار أحياناً باختبار t للأزواج المتطابقة أو العينات المزدوجة).

1.4.7 المنطق في الاختبار t

يخضع كلا الاختبارين t للمنطق ذاته.

- تم تجميع عينتين من البيانات وحساب متوسط العينة لكل منهما. قد تختلف هذه المتوسطات قليلاً أو كثيراً.
- إذا كانت العينات تنتمي لنفس المجتمع، فإننا نتوقع أن تكون قيم المتوسط متساوية تقريباً (أنظر الفقرة 6.1). ومع أن اختلاف المتوسطات قد يكون ناتجاً بمحض الصدفة فإننا نتوقع أن لا تحدث فروق كبيرة بين قيم المتوسط للعينات بشكل متكرر. وتحت ما يسمى فرضية العدم يمكننا أن نفترض أنه ليس للتلاعب التجريبي أثر على المشتركين، ولذلك فإننا نتوقع أن تكون المتوسطات متشابهة جداً.
- نقارن الفرق بين قيم المتوسط للعينات التي جمعناها مع الفرق بين قيم المتوسط للعينات التي نتوقع الحصول عليه بالصدفة. نستخدم الخطأ المعياري (أنظر الفقرة 6.1) كمقياس للتغايرية بين قيم المتوسط للعينات. إذا كان الخطأ المعياري صغيراً فإننا نتوقع أن تملك معظم العينات قيماً متشابهة جداً للمتوسط. عندما يكون الخطأ المعياري كبيراً فإننا نتوقع الحصول على فروق كبيرة في قيم المتوسط للعينات بمحض الصدفة. إذا كان الفرق بين العينات التي جمعناها أكبر مما توقعناه اعتماداً على الخطأ المعياري فإننا نفترض أحد التفسيرين:
  1. تتراوح قيم المتوسط للعينات كثيراً بسبب الصدفة وحدها، وقد جمعنا (بطريق الصدفة) عينتين شاذتين من المجتمع الذي تنتميان إليه.
  2. تنتمي العينات إلى مجتمعات مختلفة ولكن كل منهما نموذجية للمجتمع الذي تنتمي إليه. وفي هذا السيناريو يمثل الفرق بين العينات فرقاً حقيقياً بين العينات (ولذلك فإن فرضية العدم غير صحيحة).
- عندما يزداد الفرق المراقب بين قيم المتوسط للعينات، تزداد ثقتنا بأن التفسير الثاني (فرضية العدم غير صحيحة ويجب التخلص منها). إذا كانت فرضية العدم غير صحيحة فإننا نقبل ما يسمى بالفرضية التجريبية the experimental hypothesis (وتدعى أحياناً الفرضية البديلة the alternative hypothesis)، وهذا يعني أن قيم المتوسط للعينات تختلف لأن تلاعباً تجريبياً مختلفاً مطبقٌ على كل منهما.

لقد حسبنا الاختبار t باستخدام المعادلة (1.7)، ولكن الشكل الدقيق الذي تأخذه هذه المعادلة سيعتمد على كيفية جمع البيانات (استخدام نفس المشتركين أم مشتركين مختلفين في كل من الحالات التجريبية).

$$t = \frac{\text{الفرق المراقب بين قيم المتوسط للعينات} - \text{الفرق المتوقع بين قيم المتوسط للمجتمع (إذا كانت فرضية العدم صحيحة)}}{\text{تقدير الخطأ المعياري للفرق بين قيمة المتوسط للعينتين}}$$

2.4.7 فرضيات الاختبار t

يعتبر اختبارا t (المستقل والتابع) اختبارات بارامترية بناءً على التوزيع الطبيعي (أنظر الفصل 3). ولذلك فهي تفترض:

- البيانات هي من مجتمعات موزعة طبيعياً.
- البيانات مقاسة على مستوى المجال على الأقل.

ونظراً لاستخدام الاختبار t المستقل لاختبار المجموعات المختلفة من الناس فهو يفترض أيضاً أن:

- التباينات في هذه المجتمعات متساوية بشكل خشن (تجانس التباينات).
- العلامات مستقلة (لأنها تأتي من أناس مختلفين).

تم شرح هذه الفرضيات بالتفصيل في الفصل 3، حيث ركزنا على ضرورة التحقق من هذه الفرضيات قبل الوصول إلى مرحلة تنفيذ الاختبار الإحصائي. ولذلك لن نعيد شرحها هنا، ولكن هذا يعني أنه إذا تجاهلت النصيحة و لم تتحقق من هذه الفرضيات فإنك بحاجة لتنفيذ ذلك الآن. ويشمل برنامج SPSS بعض الإجرائيات المتعلقة بالاختبار t (مثل اختبار Levene الذي يتم تنفيذه بنفس الوقت مع اختبار t، أنظر الفقرة 6.3). سنبحث الآن في نوعَي الاختبار t بشكل مفصل.

5.7 اختبار t التابع

بعد أن تعلمنا كيفية رسم المتوسطات، ننتقل إلى تحليل فيما إذا كانت الفروق بين قيم المتوسط للمجموعات ذات معنى إحصائياً. إذا أخذنا حالة بيانات القياسات المكررة فإنه يمكننا النظر إلى اختبار t التابع أو اختبار t للعينات المزدوجة والذي يمكن حسابه بسهولة، حيث نستخدم الصيغة العددية التالية للمعادلة (1.7):

$$t = \frac{\overline{D} - \mu_D}{S_D/\sqrt{N}} \qquad (2.7)$$

تقارن المعادلة (2.7) فرق المتوسط بين العينات ($\overline{D}$) مع الفرق الذي نتوقع أن نجده بين متوسطات المجتمع (μ_D)، ثم تأخذ بعين الاعتبار الخطأ المعياري للفروق ($S_D/\sqrt{N}$). إذا كانت فرضية العدم صحيحة فإننا نتوقع أن لا يكون هناك فرق بين متوسطات المجتمع (أي $\mu_D=0$).

1.5.7 توزيعات أخذ العينات والخطأ المعياري

تم إدخال الخطأ المعياري في الفقرة 6.1 وهو ببساطة الانحراف المعياري لما يسمى توزيع أخذ العينات (Sampling distribution). يمكنك العودة إلى تلك الفقرة لتنشيط ذاكرتك بما يخص توزيع أخذ العينات والخطأ المعياري. ويتمتع توزيع أخذ العينات بعدة خصائص هامة. فإذا كان المجتمع موزعاً طبيعياً فإن توزيع أخذ العينات يكون أيضاً موزعاً طبيعياً، فإذا احتوت العينات على أكثر من 50 علامة فإن توزيع أخذ العينات سيكون دوماً موزعاً طبيعياً. والمتوسط لتوزيع أخذ العينات يساوي متوسط المجتمع، ولذلك إذا قمت بحساب المتوسط لجميع القيم المتوسطة للعينات فإن القيمة التي تحصل عليها يجب أن تكون مساوية لمتوسط المجتمع. ويكون لهذه الخاصية معنى لأنه إذا كانت العينة ممثلة للمجتمع فإنك تتوقع أن يكون متوسطها مساوياً لمتوسط المجتمع. على كل حال، تكون بعض العينات أحياناً غير ممثلة للمجتمع ويختلف متوسطها عن متوسط المجتمع. وبشكل وسطي فإن متوسط العينة يكون قريباً جداً من متوسط المجتمع ونادراً ما يكون مختلفاً عن متوسط المجتمع. أما الخاصية الأخيرة لتوزيع أخذ العينات فهي أن الانحراف المعياري لهذا التوزيع يساوي الانحراف المعياري للمجتمع مقسوماً على الجذر التربيعي لعدد المشاهدات في العينة. وكما ذكرنا سابقاً فإن هذا الانحراف المعياري يدعى بالخطأ المعياري.

يمكننا توسيع هذه الفكرة لتشمل الفروق بين متوسطات العينات. إذا كنت تريد أخذ عدة أزواج من العينات من مجتمع ما وحساب قيمها المتوسطة، فإنه يمكنك أيضاً حساب الفرق بين هذه المتوسطات. وقد ذكرنا سابقاً أن متوسطات العينات تكون في المعدل مشابهة جداً لمتوسط المجتمع، وهكذا فإن قيمة المتوسط لمعظم العينات ستكون متشابهة. ولذلك فإنه غالباً ما يكون الفرق بين متوسطات العينات القادمة من نفس المجتمع معدوماً أو قريباً من الصفر. على كل حال قد يكون لإحدى العينات أو لكلتيهما متوسط بعيد جداً عن متوسط المجتمع، وبذلك قد نحصل على فروق كبيرة بين متوسطات العينات ناتجة عن الصدفة وحدها. ولكن يحدث ذلك بشكل أقل تكراراً.

إذا رسمنا هذه الفروق بين متوسطات العينات كمخطط تكراري فإننا نحصل على توزيع أخذ العينات مع كل الخصائص المذكورة سابقاً. يدعى الانحراف المعياري لتوزيع أخذ العينات بالخطأ المعياري للفروق (Standard error of differences). ويدل الخطأ المعياري الصغير على أن معظم الأزواج من العينات القادمة من نفس المجتمع ستملك قيماً متوسطة متشابهة جداً (أي أن الفرق بين متوسطات العينات يجب أن يكون صغيراً جداً بشكل طبيعي). أما الخطأ المعياري الكبير فيدل على أن متوسطات العينات يمكن أن تنحرف بشكل كبير عن متوسط المجتمع ولذلك فإن الفروق بين أزواج العينات يمكن أن يكون كبيراً بمحض الصدفة.

2.5.7 شرح معادلة الاختبار t التابع

في تجربة ما، كانت علامة الشخص في الحالة التجريبية الأولى مختلفة عن علامته في الحالة الثانية، ويمكن أن يكون الفرق بين العلامتين صغيراً جداً أو كبيراً جداً. إذا أردنا حساب الفروق بين علامة كل شخص في كل حالة تجريبية ثم جمع هذه الفروق فإننا نحصل على المقدار الكلي للفروق. إذا قسمنا الناتج على عدد المشاركين فإننا نحصل على الفرق المتوسط (أي مقدار اختلاف علامة الشخص في المتوسط بين الحالتين التجريبيتين). هذا الفرق المتوسط هو ($\overline{D}$) في المعادلة (2.7) وهو مؤشر على التغاير المنهجي في البيانات (أي أنه يمثل الأثر التجريبي). نعلم أنه إذا أخذنا عينتين عشوائيتين من مجتمع ما فإن المتوسطات ستكون مختلفة نتيجة الصدفة فقط. وكما رأينا فإن الدرجة التي يحتمل أن تختلف بها متوسطات العينات تتحدد بحجم الخطأ المعياري للفروق. ويجب أن نتأكد من أن الفرق المراقب بين العينات يعود للتلاعب التجريبي (وليس نتيجة الصدفة). إن معرفة الفرق المتوسط فقط ليست مفيدة، لأن هذا الفرق يعتمد على سلم القياس ولذلك ينبغي علينا إجراء توحيد قياسي لهذه القيمة. وهناك طريقة للتوحيد القياسي لمجموع الفروق في المجموعة وهي التقسيم على الانحراف المعياري للعينة (أنظر الفقرة 1.4.1). وإذا كنا نعلم ماذا يمثل الانحراف المعياري (إنه مقياس للانحراف الوسطي عن قيمة المتوسط) فإن الانحراف المعياري لهذه الفروق بين الحالتين التجريبيتين يمثل الانحراف الوسطي عن الفرق الوسطي. بما أن الانحراف المعياري هو مقياس لمقدار التغاير الموجود بين علامات الفرق للمشتركين فإن الانحراف المعياري للفروق يمثل التغاير اللامنهجي في التجربة.

لتوضيح ذلك تخيل أن كائناً غريباً هبط من الفضاء وقام باستنساخ 12 نسخة من شخص ما يخاف من العناكب. إن جميع هذه النسخ ستكون مشابهة للشخص الأصلي وتتصرف بنفس الطريقة. لذلك فإنها ستخاف بنفس المستوى من صورة العنكبوت (ولنقل المستوى 40)، أما عند رؤية عنكبوت حقيقي فإن مستوى الخوف سيصل إلى 50. إذا حسبنا الفرق بين علامات الخوف من الصورة ومن العنكبوت الأصلي فإن قيمته ستكون 10 لجميع النسخ. إذا حسبنا الانحراف المعياري لهذه الفروق فإنه سيكون مساوياً 0 (لعدم وجود تغاير أبداً بين العلامات). لذلك إذا كان جميع المشتركين متماثلين فإن الانحراف المعياري يساوي 0 أي أنه لا يوجد تغاير لامنهجي. وبعبارة أخرى، إن جميع الفروق في مستوى الخوف نتجت عن رؤية العنكبوت الحقيقي بدلاً من صورة العنكبوت، ولا يمكن تفسير أي فروق نتيجة عوامل أخرى (كالفروق الشخصية مثلاً).

ومع أن التقسيم على الانحراف المعياري سيكون مفيداً كوسيلة للتوحيد القياسي للفرق المتوسط بين الحالتين التجريبيتين، فإن ما يهمنا هو معرفة مقدار الفرق بين متوسطات العينات مقارنة بما نتوقع أن نجده إذا لم نفرض تلاعباً تجريبياً. يمكننا استخدام خصائص توزيع أخذ العينات: بدلاً من تقسيم الفرق المتوسط بين الحالتين على الانحراف المعياري للفروق فإنه يمكننا التقسيم على الخطأ المعياري للفروق. إن التقسيم على الخطأ المعياري للفروق لا يعاير الفرق المتوسط بين الحالات فحسب،

ولكنه يدلنا على مقدار الفرق في المطال بين متوسطي العينتين مقارنة بما يمكن أن نتوقعه بمحض الصدفة. إذا كان الخطأ المعياري كبيراً، فإن الفروق الكبيرة بين متوسطات العينات ستكون شائعة (لأن توزيع الفروق منتشر بشكل أوسع). وبالعكس إذا كان الخطأ المعياري صغيراً فإن الفروق الكبيرة بين متوسطات العينات لن تكون شائعة (لأن التوزيع ضيق جداً ومتمركز حول القيمة 0). لذلك إذا كان الفرق المتوسط بين العينات كبيراً والخطأ المعياري للفروق صغيراً فيمكننا أن نكون على ثقة بأن الفرق الذي راقبناه في العينة ليس نتيجة الصدفة. إذا لم يكن الفرق ناتجاً عن الصدفة فإنه ناتج حتماً عن التلاعب التجريبي.

في عالم مثالي. يمكننا حساب الخطأ المعياري بأخذ جميع الأزواج الممكنة من العينات من مجتمع ما، وحساب الفروق بين متوسطاتها ثم إيجاد الانحراف المعياري لهذه الفروق. على كل حال، إن هذه العملية مستحيلة في الواقع. لذلك نقوم بتقدير الخطأ المعياري من الانحراف المعياري للفروق التي نحصل عليها ضمن العينة (S_D) ومن حجم العينة (N). بالعودة إلى الفقرة 6.1 حيث رأينا أن الخطأ المعياري هو ببساطة الانحراف المعياري مقسوماً على الجذر التربيعي لحجم العينة، فإنه يمكننا حساب الخطأ المعياري للفروق $\sigma_{\bar{D}}$ وذلك بتقسيم الانحراف المعياري للفروق على الجذر التربيعي لحجم العينة:

$$\sigma_{\bar{D}} = \frac{S_D}{\sqrt{N}}$$

إذا كان الخطأ المعياري للفروق مقياساً للتغاير اللامنهجي ضمن البيانات، وكان مجموع علامات الفروق يمثل التغاير المنهجي فيجب أن يكون واضحاً أن إحصائية t هي ببساطة نسبة التغاير المنهجي في التجربة إلى التغاير اللامنهجي. إذا أنشأ التلاعب التجريبي أي نوع من الآثار فإننا نتوقع أن يكون التغاير المنهجي أكبر بكثير من التغاير اللامنهجي (أي أن t ستكون على الأقل أكبر من 1). أما إذا كان التلاعب التجريبي غير ناجح فإننا نتوقع أن التغاير الناتج عن الفروق الشخصية أكبر بكثير من التغاير الناتج عن التجربة (وتكون t أصغر من 1). يمكننا مقارنة القيمة الناتجة للإحصائية t مع القيمة العظمى التي نتوقع الحصول عليها بمحض الصدفة في التوزيع t مع نفس عدد درجات الحرية (يمكن إيجاد هذه القيم في الملحق A2)، فإذا كانت القيمة أكبر من القيمة الحرجة فإننا نكون على ثقة أن ذلك يعكس أثراً ما على المتحول المستقل.

3.5.7 اختبار t التابع باستخدام SPSS

باستخدام البيانات الموجودة في الملف SpiderRM.sav، لدينا 12 شخصاً يخافون من العناكب وقد تم عرض صورة عنكبوت عليهم (المتحول picture)، وفي مرة أخرى تم عرض عنكبوت حقيقي عليهم (المتحول real). وقد قيس مستوى الخوف في كل حالة (تم عرض الصورة على نصف المشتركين ثم عرض عليهم العنكبوت الحقيقي، بينما عرض العنكبوت الحقيقي على النصف الآخر من المشتركين أولاً ثم تم عرض الصورة عليهم). لقد شرحنا سابقاً كيفية ترتيب البيانات ولذلك

سننتقل مباشرة إلى الاختبار ذاته. يجب فتح مربع الحوار الرئيسي للاختبار t وذلك بواسطة أمر القائمة ...Analyze ⇒ Compare Means ⇒ Paired-Sapmles T-Test (المبين في الشكل 10.7). نختار المتحول الأول ثم نختار المتحول الثاني (يظهر الترتيب في القسم السفلي الأيسر المسمى Current Selections) وننقلهما إلى الحيز المسمى Paired Variables (المتحولات المزدوجة) وذلك بنقر زر السهم الموجود بين القسمين. إذا أردت تنفيذ عدة اختبارات t فيمكنك اختيار زوج آخر من المتحولات ونقله إلى حيز المتحولات المزدوجة، واختيار زوج ثالث وهكذا. في هذه الحالة، نريد إجراء اختبار واحد فقط. إذا نقرت الزر ...Options يظهر مربع حوار آخر لضبط مجموعة من الخيارات كتغيير عرض مجال الثقة المحسوب وغيره. إن القيمة الافتراضية 95% مناسبة جداً، ولكن إذا أردت أن تكون صارماً أكثر فيمكنك اختيار القيمة 99% لمجال الثقة، ولكنك ستعمل عندئذ عند مستويات مخاطرة أعلى للفشل في اكتشاف أثر حقيقي (الخطأ من النوع الثاني). لتنفيذ التحليل انقر الزر OK.

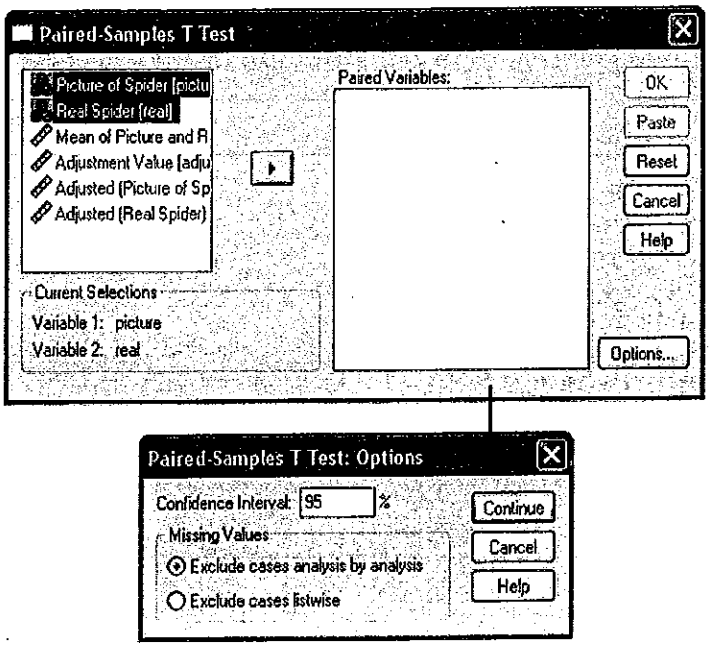

الشكل 10.7 مربعات الحوار لاختبار t في العينات المزدوجة

4.5.7 الخرج لاختبار t التابع

يعطي الخرج الناتج ثلاثة جداول. يبين (الخرج 1.7) جدولاً للإحصائيات الملخصة للحالتين التجريبيتين. ومن أجل كل حالة تم إظهار قيمة المتوسط وعدد المشاركين (N) والانحراف المعياري للعينة. ويحوي العمود الأخير قيمة الخطأ المعياري للعينة (SE=S/√N)، فمن أجل حالة عرض الصورة نجد SE=9.2932/√12=2.68.

يعرض الخرج 1.7 أيضاً معامل Pearson للارتباط بين الحالتين. عند استخدام القياسات المكررة، من الممكن أن تكون الحالات التجريبية مرتبطة (لأن البيانات في كل حالة تأتي من نفس الأشخاص ولذلك يمكن أن يكون هناك ثبات في استجاباتهم). يوفر برنامج SPSS قيمة معامل Pearson للارتباط r وقيمة الدلالة عند الطرفين (أنظر الفصل 4). من أجل هذه البيانات، تعطي الحالات التجريبية عامل ارتباط مرتفع نسبياً (r=0.545) ولكنها غير مرتبطة بشكل هام لأن p>0.05.

Paired Samples Statistics

		Mean	N	Std. Deviation	Std. Error Mean
Pair 1	Picture of Spider	40.0000	12	9.29320	2.68272
	Real Spider	47.0000	12	11.02889	3.18377

Paired Samples Correlations

		N	Correlation	Sig.
Pair 1	Picture of Spider & Real Spider	12	.545	.067

الخرج 1.7

يعرض (الخرج 2.7) الجدول الأكثر أهمية والذي يخبرنا فيما إذا كان الفرق بين المتوسطات للحالتين التجريبيتين كبيراً بشكل يجعله غير ناتج عن الصدفة. يعرض الجدول أولاً الفرق بين العلامات (قيمة $\overline{D}$ في المعادلة (2.7) وهو الفرق بين علامات المتوسط لكل حالة: 7-=40-47). يقدم الجدول أيضاً الانحراف المعياري للفروق بين المتوسطات، وأهم من ذلك الخطأ المعياري للفروق بين علامات المشتركين في كل حالة (أنظر الفقرة 1.5.7). يتم حساب إحصائية الاختبار t بتقسيم متوسط الفروق على الخطأ المعياري للفروق (أنظر المعادلة (2.7): t=-7/2.8311=-2.47). تتم مقارنة قيمة t مع القيم المعلومة اعتماداً على درجات الحرية. عند استخدام نفس العدد من المشتركين فإن عدد درجات الحرية هو ببساطة أقل بواحد من حجم العينة (df=N-1=11). يستخدم برنامج SPSS عدد درجات الحرية لحساب الاحتمال الدقيق لأن تكون قيمة t كبيرة بقدر القيمة التي يمكن الحصول عليها بالصدفة. وقيمة الاحتمال هذه موجودة في العمود المسمى .Sig. وبشكل افتراضي، يوفر برنامج SPSS الاحتمال ثنائي الطرف فقط، وهو الاحتمال المتوقع عندما لا يتم التنبؤ باتجاه فروق المجموعات. إذا تم تحديد اتجاه لهذه الفروق (يمكن أن نتوقع أن الخوف سيكون أعلى عند عرض العنكبوت الحقيقي) فيجب عندئذ تقديم الاحتمال وحيد الطرف، ويتم الحصول على هذه القيمة بتقسيم قيمة الاحتمال ثنائي الطرف على القيمة 2 (وسنتحدث بالتفصيل عن ذلك لاحقاً). إن الاحتمال ثنائي الطرف لهذا المثال منخفض جداً (p=0.031) ويدلنا على أن هناك احتمالاً قدره 3.1% لأن تكون قيمة t كبيرة بحيث تحدث بمحض الصدفة. وكعلماء اجتماع فإننا على استعداد

لقبول أي شيء يكون احتماله أقل من 5% ليحدث بالصدفة على أنه ذو معنى إحصائي. تدلنا قيمة t السالبة على أن للحالة الأولى (عرض الصورة picture) متوسطاً أصغر من الحالة الثانية (عرض العنكبوت الحقيقي real) ولذلك فإن العنكبوت الحقيقي يسبب مستويات أعلى للخوف من الصورة. وعند تقديم الاختبار t فإن نضمّنه دائماً عدد درجات الحرية (11 في هذه التجربة) وقيمة الإحصائية t ومستوى الدلالة لهذه القيمة. لذلك نستنتج أن التعرض لعنكبوت حقيقي يسبب خوفاً عند الأشخاص الذين يخافون من العناكب أكبر من الخوف الناتج عند عرض صورة العنكبوت ($t(11)=-2.47, p<0.05$). وقد تم التنبؤ بهذه النتيجة من مخطط عمود الخطأ في الشكل 9.7.

Paired Samples Test

	Paired Differences					t	df	Sig. (2-tailed)
	$\bar{D}$ Mean	Std. Deviation	Std. Error Mean	95% Confidence Interval of the Difference Lower	Upper			
Pair 1 Picture of Spider - Real Spider	-7.0000	9.80723	2.83110	-13.2312	-.7688	-2.473	11	.031

الخرج 2.7

الشيء الأخير الذي يوفره هذا الخرج هو مجال الثقة 95% للفرق المتوسط. تخيل أننا أخذنا 100 عينة من مجتمع له علامات مختلفة وحسبنا المتوسط $\bar{D}$ ومجال الثقة لهذا المتوسط. في 95 عينة من هذه العينات، تحوي مجالات الثقة التي تم إنشاؤها القيمة الصحيحة للفرق المتوسط. يدلنا مجال الثقة على الحدود التي يحتمل أن تقع قيمة الفرق المتوسط الحقيقية ضمنها. لذلك وبفرض أن مجال الثقة لهذه العينة هو واحد من المجالات 95 التي تحوي قيمة الفرق المتوسط للمجتمع فإنه يمكننا القول أن قيمة الفرق المتوسط الصحيحة للمجتمع تقع بين القيمتين 13.23- و 0.77-. وأهمية هذا المجال هي أنه لا يحوي القيمة 0 (القيمتين الحديتين من نفس الإشارة) وهذا يدل على أنه من غير المحتمل أن تكون قيمة الفرق المتوسط مساوية للصفر. إذا كان علينا مقارنة أزواج من العينات العشوائية من مجتمع ما، فإننا نتوقع أن تكون معظم الفروق بين متوسطات العينات مساوية للصفر. يدلنا هذا المجال واعتماداً على العينتين موضوع التحليل، على أنه من غير المحتمل أن تكون القيمة الحقيقية للفرق بين المتوسطين مساوية للصفر. ولذلك يمكن أن نكون على ثقة بأن العينتين لا تمثلان عينات عشوائية من نفس المجتمع، وإنما تمثلان عينات من مجتمعات مختلفة محرّضة بالتلاعب التجريبي.

5.5.7 حساب حجم الأثر

مع أن الإحصائية t ذات دلالة إحصائية، فهذا لا يعني أن الأثر هام بالمعنى العملي. ولاكتشاف فيما إذا كان الأثر فعلياً فإننا بحاجة لاستخدام ما يعرف بحجم الأثر (أنظر الفقرة 4.8.1). وسنستخدم حجم الأثر r لأنه مفهوم بشكل أوسع، وشائع الاستخدام. إن تحويل قيمة t إلى قيمة r بسيط

عملياً حيث يمكننا استخدام المعادلة التالية: (من Rosenthal, 1991 الصفحة 19 و osnow & Rosenthal, 2005 الصفحة 328):

$$r = \sqrt{\frac{t^2}{t^2 + df}}$$

وبما أننا نعلم قيمة t و df فيمكننا حساب r كما يلي:

$$r = \sqrt{\frac{(-2.473)^2}{(-2.473)^2 + 11}} = \sqrt{\frac{6.116}{17.116}} = 0.60$$

وإذا عدنا لمقياس حجم الأثر الذي يمثل أثراً كبيراً جداً (القيمة >0.5 هي العتبة لأثر كبير). لذلك وكما كان هذا الأثر ذا دلالة إحصائياً فإن حجمه كبير ويمثل نتيجة عملية.

6.5.7 تقديم الاختبار t التابع

هناك طريقة قياسية لتقديم أية إحصائية اختبار، حيث نذكر النتيجة التي يتعلق بها الاختبار ثم نقدم إحصائية الاختبار، وعدد درجات الحرية لها، وقيمة الاحتمال لتلك الإحصائية. وهناك توجه حديث لتقديم تقدير لحجم الأثر. وفي هذا المثال يقدم خرج البرنامج SPSS قيمة t=-2.473، وعدد درجات الحرية df=11 ومستوى الدلالة p=0.031. يمكننا أن نرى أيضاً المتوسطات لكل مجموعة، ولذلك يمكننا أن نكتب:

✓ بشكل وسطي، يُبدي المشتركون خوفاً عند رؤية العنكبوت الحقيقي(M=47.00, SE=3.18) أكبر من الخوف عند رؤية صورة العنكبوت (M=40.00, SE=2.68, t(11)=-2.473, p<0.05, r=0.60).

لاحظ أننا قدمنا قيمة المتوسط لكل مجموعة (والأخطاء المعيارية) بصيغة قياسية. ومن أجل إحصائية الاختبار t فقد قمنا بحسابها ووضعنا عدد درجات الحرية بين قوسين ثم ذكرنا قيمة إحصائية الاختبار. يمكن التعبير عن قيمة الاحتمال بعدة طرق، وغالباً ما يقدم الأشخاص هذه الأشياء عند مستوى قياسي للدلالة (مثل 0.05) كما فعلنا هنا، ولكن بعض الأشخاص يقدمون القيمة الفعلية للدلالة. وأخيراً لاحظ أننا قدمنا حجم الأثر. قد لا تجد هذه القيمة في بعض الأبحاث المنشورة ولكن هذا لا يعطيك عذراً لكي لا تقدمها في أعمالك.

تجنب كتابة عبارات فضفاضة غير عملية مثل:

✗ كان الناس أكثر خوفاً عند تعرضهم للعناكب الحقيقية (t=-2.47).

كانوا أكثر خوفاً من ماذا؟ أين عدد درجات الحرية؟ هل كانت النتيجة ذات دلالة إحصائية؟ هل كان الأثر هاماً (وما هو حجم الأثر)؟

أفكار مفيدة

- يقارن اختبار t التابع قيمتي المتوسط، عندما تأتي هاتان القيمتان من نفس المجموعة من الناس، كأن تكون لديك حالتان تجريبيتان واستخدمت نفس المشتركين في كل حالة.
- أنظر إلى العمود المسمى .Sig . إذا كانت القيمة أصغر من 0.05 فإن المتوسطات للمجموعتين مختلفة بشكل كبير.
- أنظر إلى قيم المتوسطات لمعرفة مدى اختلاف المجموعات.
- يوفر برنامج SPSS قيمة الدلالة ثنائية الطرف، وإذا أردت قيمة الدلالة وحيدة الطرف يكفي تقسيم القيمة المعطاة على العدد 2.
- عند تقديم الاختبار t، اذكر قيمة الإحصائية t وعدد درجات الحرية وقيمة الدلالة. اذكر أيضاً قيم المتوسطات والخطأ المعياري لكل منها (أو ارسم مخطط عمود الخطأ).
- إذا كنت شجاعاً، يمكنك حساب حجم الأثر وتقديمه مع الاختبار t.

6.7 اختبار t المستقل

1.6.7 شرح معادلة الاختبار t المستقل

يُستخدم اختبار t المستقل في الأوضاع التي توجد فيها حالتان تجريبيتان ومشتركون مختلفون في كل حالة تجريبية. وهناك نوعان مختلفان من المعادلات التي يمكن استخدامها لحساب الإحصائية t اعتماداً على فيما إذا كانت العينات تحوي عدداً متساوياً من المشتركين. وكما في حالة اختبار t التابع يمكننا حساب الإحصائية t باستخدام النسخة العددية من المعادلة (1.7). وفي حالة اختبار t التابع يمكننا النظر إلى الفروق بين أزواج من العلامات، لأن العلامات تأتي من نفس المشتركين ولذلك فقد تم حذف الفروق الشخصية بين الحالات. لذا فإن الفرق في العلامات يجب أن يعكس أثر التلاعب التجريبي فقط. أما في حالة اختبار t المستقل وعندما يشارك مشتركون مختلفون في الحالات المختلفة فإن أزواج العلامات ستختلف ليس فقط بسبب التلاعب التجريبي، ولكن بسبب مصادر التباين الأخرى (كالفروق الشخصية بين دوافع المشتركين ومستوى الذكاء وغيرها). إذا لم نستطع التحقق من الفروق بين الحالات على أساس كل مشترك (بمقارنة أزواج العلامات كما فعلنا من أجل اختبار t التابع) فإن علينا إجراء المقارنة على أساس الحالة (بالنظر إلى الأثر الكلي في حالة ما – أنظر المعادلة (3.7)):

$$t = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\text{تقدير الخطأ المعياري}} \qquad (3.7)$$

وبدلاً من النظر إلى الفروق بين أزواج العلامات فإننا ننظر الآن إلى الفروق بين المتوسطات الإجمالية للعينتين ونقارنها بالفروق التي نتوقع الحصول عليها بين المتوسطات للمجتمعين اللذين جاءت منهما العينتان. إذا كانت فرضية العدم صحيحة فقد تم إذاً سحب العينات من نفس المجتمع. ولذلك وتحت فرضية العدم يكون $\mu_1=\mu_2$ وتأخذ المعادلة (3.7) الشكل التالي:

$$t= \frac{\overline{X}_1 - \overline{X}_2}{\text{تقدير الخطأ المعياري}} \qquad (4.7)$$

في اختبار t التابع قسمنا الفرق المتوسط بين أزواج العلامات على الخطأ المعياري لهذه الفروق. أما في اختيار t المستقل فإننا نبحث عن الفروق بين المجموعات ولذلك فإننا نقسم على الانحراف المعياري للفروق بين المجموعات. ومازال بإمكاننا تطبيق المنطق الخاص بتوزيعات أخذ العينات على هذه الحالة. تخيل أننا نأخذ عدة أزواج من العينات، يحوي كل زوج عينة واحدة من المجتمعين المختلفين، ونقارن المتوسطات لهذه العينات. ومما تعلمناه عن توزيعات أخذ العينات، فإننا نعلم أن لغالبية العينات من مجتمع ما متوسطات متشابهة جداً. ولذلك إذا أخذنا عدة أزواج من العينات (من المجتمعات المختلفة) فإن الفروق بين متوسطات العينات ستكون متشابهة عبر الأزواج. على كل حال، غالباً ما ينحرف الفرق بين زوج من متوسطات العينات بمقدار صغير، ونادراً ما يكون الانحراف كبيراً. إذا استطعنا رسم مخطط توزيع أخذ العينات للفروق بين كل زوج من متوسطات العينات المأخوذة من مجتمعين مختلفين فإننا نجد أنه توزيع طبيعي مع متوسط يساوي الفرق بين متوسطات المجتمعين ($\mu_1-\mu_2$). يخبرنا توزيع أخذ العينات بمقدار الاختلاف الذي نتوقعه لمتوسطات العينتين. وكما قلنا سابقاً، فإن الانحراف المعياري لتوزيع أخذ العينات (الخطأ المعياري) يخبرنا بمقدار تغير الفروق بين متوسطات العينات الناتج عن الصدفة. إذا كان الانحراف المعياري كبيراً فإن الفروق الكبيرة بين متوسطات العينات يمكن أن تحدث بمحض الصدفة، أما إذا كان صغيراً فإن الفروق الصغيرة فقط بين متوسطات العينات هي المتوقعة. ولذلك يكون لاستخدامنا للخطأ المعياري لتوزيع أخذ العينات معنى في تقييم فيما إذا كان الفرق بين متوسطات العينات ذو معنى إحصائياً أم أنه نتيجة الصدفة فقط. وبشكل خاص فإننا نقسم الفرق بين متوسطات العينات على الانحراف المعياري لتوزيع أخذ العينات.

إذاً، كيف نحصل على الانحراف المعياري لتوزيع أخذ العينات للفروق بين متوسطات العينات؟ حسناً: نستخدم قانون مجموع التباينات Variance Sum Law والذي يدل على أن التباين للفرق بين المتحولات المستقلة يساوي مجموع تبايناتها. وتعني هذه العبارة أن التباين لتوزيع أخذ العينات يساوي مجموع التباينات للمجتمعين اللذين تم أخذ العينات منهما. وقد رأينا سابقاً أن الخطأ المعياري هو الانحراف المعياري لتوزيع أخذ العينات لمجتمع ما، يمكننا أن نستخدم الانحرافات المعيارية للعينات لحساب الخطأ المعياري لكل توزيع من توزيعات أخذ العينات للمجتمع:

الخطأ المعياري لتوزيع أخذ العينات في المجتمع 1 $= \frac{s_1}{\sqrt{N_1}}$

الخطأ المعياري لتوزيع أخذ العينات في المجتمع 2 $= \frac{s_2}{\sqrt{N_2}}$

وإذا تذكرنا أن التباين هو مربع الانحراف المعياري فإننا نستطيع أن نكتب:

التباين لتوزيع أخذ العينات في المجتمع 1 $= \left(\frac{s_1}{\sqrt{N_1}}\right)^2 = \frac{s_1^2}{N_1}$

التباين لتوزيع أخذ العينات في المجتمع 2 $= \left(\frac{s_2}{\sqrt{N_2}}\right)^2 = \frac{s_2^2}{N_2}$

ويعني قانون مجموع التباينات أنه لإيجاد التباين لتوزيع أخذ العينات للفروق فإننا نجمع التباينات لتوزيعي أخذ العينات للمجتمعين فنحصل على:

التباين لتوزيع أخذ العينات للفروق $= \frac{s_1^2}{N_1} + \frac{s_2^2}{N_2}$

ولإيجاد الخطأ المعياري لتوزيع أخذ العينات للفروق نأخذ الجذر التربيعي للتباين فنجد:

الخطأ المعياري لتوزيع أخذ العينات للفروق $= \sqrt{\frac{s_1^2}{N_1} + \frac{s_2^2}{N_2}}$

ولذلك فإن المعادلة (4.7) تصبح المعادلة (5.7) التالية:

$$t = \frac{\overline{X}_1 - \overline{X}_2}{\sqrt{\frac{s_1^2}{N_1} + \frac{s_2^2}{N_2}}} \qquad (5.7)$$

إن المعادلة (5.7) صحيحة عندما يكون حجم العينتين متساوياً فقط. وفي العلوم الاجتماعية ليس من الممكن جمع عينات متساوية الحجم (لأن بعض الأشخاص لا يكملون التجربة مثلاً). وعندما نرغب بمقارنة مجموعتين من الناس تحويان أعداداً مختلفة من المشتركين فإن المعادلة (5.7) تصبح غير مناسبة. وبدلاً من ذلك نستخدم اختبار t لتقدير التباين المشارك والذي يأخذ الفرق في حجم العينات بعين الاعتبار عن طريق تثقيل التباين لكل عينة. وبالحدس يمكن أن نلاحظ أن العينات الكبيرة أفضل من العينات الصغيرة لأنها تقريب أدق للمجتمع، ولذلك نقوم بتثقيل التباين بحجم العينة التي يعتمد عليها (نقوم عملياً بتثقيل عدد درجات الحرية الذي هو أقل بواحد من حجم العينة). لذلك فإن تقدير التباين المشارك هو:

$$s_p^2 = \frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}$$

وهذا ببساطة هو متوسطٌ مثقّل تم فيه ضرب كل تباين (أو تثقيله) بعدد درجات الحرية له، ثم التقسيم على مجموع التثقيل (أو مجموع درجات الحرية). ويتم بعد ذلك تعويض التباين المتوسط المثقّل في معادلة الاختبار t (المعادلة (5.7)):

$$t = \frac{\overline{X}_1 - \overline{X}_2}{\sqrt{\frac{s_p^2}{n_1} + \frac{s_p^2}{n_2}}}$$

وكما في حالة اختبار t التابع، يمكننا مقارنة القيمة التي نحصل عليها لاختبار t مع القيمة العظمى التي نتوقع الحصول عليها بالصدفة فقط في توزيع t له نفس عدد درجات الحرية (يمكن إيجاد تلك القيم في الملحق A2)، فإذا كانت القيمة التي حصلنا عليها تتجاوز القيمة الحرجة فإننا نكون على ثقة أن ذلك يعكس أثراً للمتحول المستقل.

إن الهدف من اشتقاق الإحصائية t توفير فكرة عما نفعله عند تنفيذ اختبار t في البرنامج SPSS.

2.6.7 الاختبار t المستقل باستخدام SPSS

إن التعامل مع المعادلات مملّ لذلك تم اختراع SPSS ليقلل احتكاكنا بها للحد الأدنى. باستخدام البيانات في الملف SpiderBG.sav، لدينا 12 شخصاً يخافون من العناكب وقد تم عرض صورة عنكبوت عليهم، و 12 شخصاً آخر يخافون أيضاً من العناكب وقد تم عرض عنكبوت حقيقي عليهم (وقد تم ترميز المجموعتين باستخدام المتحول group). تم قياس مستوى الخوف في كل حالة (المتحول anxiety). وقد شرحنا سابقاً كيف تم ترتيب البيانات (أنظر الفقرة 1.3.7)، ولذلك ننتقل مباشرة إلى تنفيذ الاختبار ذاته. نفتح مربع الحوار الرئيسي المبين في الشكل 11.7 باستخدام أمر القائمة Analyze ⇒ Compare Means ⇒ Independent-Sapmles T-Test... اختر المتحول التابع من اللائحة (anxiety) وانقله إلى الحيز المسمى Test Variable(s) (متحول أو متحولات الاختبار) وذلك بنقر زر السهم الموجود بين القسمين. إذا أردت تنفيذ عدة اختبارات t على عدة متحولات تابعة فيمكنك اختيار المتحولات الأخرى ونقلها إلى نفس الحيز. ولكن هناك أسباب معقولة لاعتبار هذه الفكرة غير جيدة (أنظر الفصل 8). بعد ذلك، علينا اختيار المتحول المستقل (متحول التجميع). في هذه الفكرة علينا اختيار المتحول group ونقله إلى الحيز المسمى Grouping Variable. بعد تحديد المتحول المستقل يصبح الزر Define Groups... فعّالاً، وعليك نقره لتفعيل مربع الحوار Define Groups لتعريف المجموعات. يحتاج SPSS الرموز العددية التي عينتها للمجموعتين، وهناك حيز خاص لكتابة هذه الرموز. في هذا المثال قمنا بترميز مجموعة عرض الصورة بالرمز 0، ومجموعة العنكبوت الحقيقي بالرمز 1، ولذلك فإن عليك كتابة هذه القيم في

ذلك الحيز. أو يمكنك تحديد نقطة قص (Cut point) حيث يقوم SPSS بتعيين جميع الحالات التي تساوي أو تكون أكبر من نقطة القص إلى إحدى المجموعتين، وجميع الحالات التي تكون أدنى من نقطة القص إلى المجموعة الأخرى. إن هذه الأداة مفيدة عند اختبار مجموعات مختلفة من المشاركين اعتماداً على شيء ما مثل منوال الفصل. لذلك، إذا أردت تصنيف الناس كمجموعة تخاف من العناكب، ومجموعة لا تخاف من العناكب، وقمت بقياس علامتهم في استبيان الخوف من العناكب وحسبت قيمة المنوال. فإنه يمكنك تصنيف أي شخص تكون علامته أعلى من المنوال على أنه يخاف من العناكب، وأي شخص تكون علامته أقل من المنوال على أنه لا يخاف من العناكب. وبدلاً من إعادة ترميز جميع المشتركين وإنشاء متحول ترميز، يمكنك كتابة قيمة المنوال في الحيز المسمى Cut point. بعد الانتهاء من تعريف المجموعات، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي. إذا نقرت الزر ...Options يظهر مربع حوار آخر ليسمح بضبط الخيارات كما في حالة اختبار t التابع. لتنفيذ التحليل انقر الزر OK.

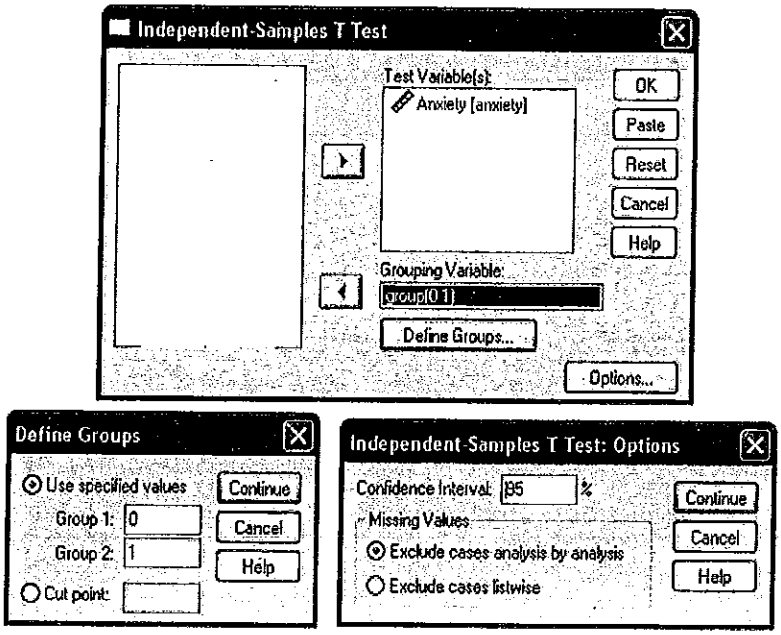

الشكل 11.7 مربعات الحوار لاختبار t المستقل

3.6.7 الخرج لاختبار t المستقل

يحوي الخرج لاختبار t المستقل جدولين فقط. يقدم الجدول الأول (الخرج 3.7) الإحصائيات التلخيصية للحالتين التجريبيتين. في هذا الجدول يمكننا أن نرى أن كلاً من المجموعتين تضم 12 مشتركاً (العمود المسمى N). للمجموعة التي شاهدت صورة العنكبوت متوسط خوف يبلغ 40 مع انحراف معياري 9.29، والخطأ المعياري لهذه المجموعة (الانحراف المعياري لتوزيع أخذ العينات) هو

2.68 (SE=9.2932/√12=2.68). ويقدم الجدول أيضاً مستوى الخوف الوسطي للمشتركين الذين شاهدوا العنكبوت الحقيقي ويبلغ 47 مع انحراف معياري 11.03 والخطأ المعياري لهذه المجموعة 3.18 (SE=11.03/√12=3.18).

Group Statistics

	Condition	N	Mean	Std. Deviation	Std. Error Mean
Anxiety	Picture	12	40.0000	9.29320	2.68272
	Real Spider	12	47.0000	11.02889	3.18377

الخرج 3.7

أما الجدول الثاني من الخرج (الخرج 4.7) فيحوي إحصائيات الاختبار الأساسية. إن أول ما يجب ملاحظته وجود صفين يحويان القيم لإحصائيات الاختبار: يسمى الصف الأول افتراض تساوي التباينات Equal variances assumed بينما يسمى الصف الثاني عدم افتراض تساوي التباينات Equal variances not assumed. وقد رأينا في الفصل 3 أن الاختبارات البارامترية تفترض أن التباينات في المجموعات التجريبية هي متساوية بشكل خشن. في الواقع هناك بعض عمليات التعديل التي ينبغي تنفيذها عندما لا تكون التباينات متساوية. يتعلق صفا الجدول بما إذا كانت هذه الفرضية محققة أم لا. ولكن كيف نعرف إذا كانت هذه الفرضية غير محققة؟

حسناً، يمكننا أن ننظر فقط إلى قيم التباينات لمعرفة فيما إذا متشابهة (نعلم أن الانحرافات المعيارية للمجموعتين هي 9.29 و11.03 وإذا قمنا بتربيع هذه القيم نحصل على التباينات 86.30 و121.66). ولكن هذا الحكم غير موضوعي. لحسن الحظ هناك اختبار يمكن تنفيذه لمعرفة فيما إذا كانت التباينات مختلفة لحد يدعو للقلق. إن اختبار Levene (أنظر الفقرة 6.3) مشابه لاختبار t من حيث أنه يختبر فرضية تساوي التباينات في المجموعتين (أي أن الفرق بين التباينات يساوي الصفر). لذلك إذا كان اختبار Levene ذا دلالة عند مستوى $p \leq 0.05$ فيمكننا أن نستنتج أن فرضية العدم غير صحيحة وأن التباينات مختلفة بشكل كبير، لذلك فإن فرضية تجانس التباينات غير محققة. وإذا كان اختبار Levene عديم الدلالة ($p > 0.05$ مثلاً) فإن علينا أن نقبل فرضية العدم بأن الفرق بين التباينات يساوي الصفر، أي أن التباينات متساوية بشكل خشن والفرضية محققة. من أجل البيانات التي لدينا فإن اختبار Levene عديم الدلالة ($p=0.386>0.05$) ولذلك علينا قراءة إحصائيات الاختبار الموجودة في الصف المسمى Equal variances assumed. لو كان اختبار Levene ذا دلالة لتوجب علينا قراءة إحصائيات الاختبار الموجودة في الصف المسمى Equal variances not assumed.

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means						
									95% Confidence Interval of the Difference	
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	Lower	Upper
Anxiety	Equal variances assumed	.782	.386	-1.681	22	.107	-7.0000	4.16333	-15.63422	1.63422
	Equal variances not assumed			-1.681	21.385	.107	-7.0000	4.16333	-15.64864	1.64864

الخرج 4.7

بعد أن تأكدنا من تحقق فرضية تجانس التباينات يمكننا الانتقال للنظر إلى اختبار t ذاته. نعرف أن قيمة الفرق المتوسط $\bar{X}_1 - \bar{X}_2$ هي (7-=40-47) والخطأ المعياري لتوزيع أخذ العينات للفروق الذي يتم حسابه من مقام المعادلة (5.7):

$$\sqrt{\frac{S_1^2}{N_1} + \frac{S_2^2}{N_2}} = \sqrt{\frac{9.29^2}{12} + \frac{11.03^2}{12}} = 4.16$$

يتم حساب الإحصائية t بتقسيم الفرق المتوسط على الخطأ المعياري لتوزيع أخذ العينات للفروق (t=-7/4.16=-1.68). ويتم تقييم قيمة t بمقارنتها مع قيمة t التي نتوقع أن نحصل عليها بالصدفة عند وجود عدد معين من درجات الحرية. من أجل اختبار t المستقل، يتم حساب عدد درجات الحرية بجمع أحجام العينتين وطرح عدد العينات من الناتج (df=N1+N2-2=12+12-2=22). يعطي برنامج SPSS قيمة الدلالة الفعلية للإحصائية t، ونهتم فيما إذا كانت هذه القيمة أقل من 0.05، ولذلك نستنتج عدم وجود فرق مهم بين متوسطات هاتين العينتين. وبما يتعلق بالتجربة يمكننا أن نستنتج أن الخوف من العناكب هو ذاته في حالة عرض صورة العنكبوت أو رؤية العنكبوت الحقيقي.

نستخدم الاحتمال ثنائي الطرف عندما لا نحدد توقعاً معيناً حول اتجاه الأثر (أنظر الفقرة 2.8.1). فعلى سبيل المثال، إذا لم نكن متأكدين فيما إذا كان العنكبوت الحقيقي يسبب خوفاً أكثر أو أقل من رؤية الصورة فإننا نستخدم الاختبار ثنائي الطرف. ولكننا غالباً ما نضع توقعاً معيناً حول المجموعة التي ستملك متوسطاً أعلى. وفي هذا المثال، فمن المحتمل أن نتوقع أن العنكبوت الحقيقي سيسبب خوفاً أعلى من رؤية صورة العنكبوت. وفي هذه الحالة يمكننا أن نستخدم الاختبار وحيد الطرف (لمزيد من التفاصيل حول هذه المسألة يمكنك العودة للفقرة 2.8.1) سيصاب بعض الطلاب بالإحباط لحقيقة أن برنامج SPSS يعطي الدلالة ثنائية الطرف فقط. والجواب بسيط، لا حاجة لوجود خيار لأن الدلالة وحيدة الطرف يمكن الحصول عليها بتقسيم الدلالة ثنائية الطرف على العدد 2. في هذا المثال، كانت قيمة الدلالة ثنائية الطرف 0.107. لذلك تكون قيمة الدلالة وحيدة

الطرف هي 0.054 (0.107/2). إن قيمة الدلالة وحيدة الطرف أكبر من 0.05 (بهامش صغير فقط) ولذلك يمكننا المحافظة على الاستنتاج بأن الخوف من العناكب هو ذاته في حالة عرض صورة العنكبوت أو رؤية العنكبوت الحقيقي. وقد توقعنا هذه النتيجة بواسطة مخطط عمود الخطأ في الشكل 3.7.

4.6.7 حساب حجم الأثر

لكي نكتشف فيما إذا كان الأثر فعلياً يمكننا أن نستخدم نفس المعادلة المستخدمة في الفقرة 5.5.7 لتحويل الإحصائية t إلى قيمة r. ونعرف قيم t و df من خرج SPSS لذلك نحسب r كما يلي:

$$r = \sqrt{\frac{-1.681^2}{-1.681^2 + 22}} = 0.34$$

إذا عدنا لقياس حجم الأثر فإن هذه القيمة تمثل أثراً متوسطاً (تمثل القيمة 0.3 العتبة للأثر المتوسط). لذلك حتى لو كان الأثر غير مهم فهو مازال يمثل أثراً فعلياً. قد تلاحظ أيضاً أن الأثر قد تقلص مما يبدو غريباً نوعاً ما مع أننا استخدمنا نفس البيانات (أنظر الفقرة 7.7).

5.6.7 تقديم اختبار t المستقل

يمكن أن نستخدم القواعد التي وضعناها لتقديم اختبار t التابع هنا لتقديم اختبار t المستقل. يخبرنا خرج البرنامج SPSS أن قيمة t=-1.68 بناءً على درجات الحرية 22، وأنها كانت بدون دلالة عند p<0.05. كما يمكننا رؤية قيمة المتوسط لكل من المجموعتين ولذلك يمكننا أن نكتب:

- ✓ بشكل وسطي، يُبدي المشتركون خوفاً عند العنكبوت الحقيقي (M=47.00, SE=3.18) أكبر من الخوف عند رؤية صورة العنكبوت (M=40.00, SE=2.68) . ولكن هذا الفرق عديم الدلالة t(22)=-1.68 عند p>0.05، ولكنه يمثل أثراً متوسط الحجم r=0.34.

لاحظ كيف قدمنا قيمة المتوسط لكل مجموعة (مع الخطأ المعياري) كما فعلنا سابقاً. وبالنسبة لإحصائية الاختبار فإن كل شيء مشابه لما سبق باستثناء أننا ذكرنا أن قيمة p أكبر من 0.05 بدلاً من أصغر من. وأخيراً لاحظ أننا وضعنا تعليقاً حول حجم الأثر.

أفكار مفيدة

- يقارن اختبار t المستقل قيمتي المتوسط لمجموعتين مختلفتين من الناس. فعلى سبيل المثال، عندما تكون لديك حالتان تجريبيتان وتستخدم مشتركين مختلفين في كل حالة.
- ننظر إلى العمود المسمى Levene's Test for Equality of Variance (اختبار Levene لتساوي التباين). وإذا كانت قيمة Sig. أصغر من 0.05 فإن فرضية تجانس التباين غير محققة ويجب النظر إلى الصف المسمى Equal variances not assumed. إذا كانت

قيمة Sig. لاختبار Levene أكبر من 0.05 فيجب عندئذٍ النظر إلى الصف المسمى Equal variances assumed.

- ننظر إلى العمود المسمى Sig. فإذا كانت القيمة أقل من 0.05 فإن قيم المتوسط للمجموعتين مختلفة بشكل كبير.
- ننظر إلى قيم المتوسط التي تدل على اختلاف أو عدم اختلاف المجموعتين.
- يقدم برنامج SPSS قيمة الدلالة ثنائية الطرف، فإذا أردت قيمة الدلالة وحيدة الطرف فعليك تقسيم القيمة المعطاة على العدد 2.
- يتم تقديم الإحصائية t، عدد درجات الحرية وقيمة الدلالة. وكذلك قيم المتوسط والخطأ المعياري المرتبط بها (أو رسم مخطط عمود الخطأ).
- وإذا كنت شجاعاً فيمكنك حساب حجم الأثر وتقديمه أيضاً.

7.7 التصميم بين المجموعات أم القياسات المكررة؟

كان المثالان المقدمان في هذا الفصل رائعين فعلاً لأنهما يوضحان الفرق بين البيانات المجمّعة باستخدام نفس المشتركين والبيانات المجمعة باستخدام مشتركين مختلفين، ويستخدم كلا المثالين نفس العلامات في كل حالة. وعند تحليلها كأنها قادمة من نفس المشتركين كانت النتيجة فرقاً مهماً بين القيم المتوسطة، ولكن عند تحليلها كأنها قادمة من مشتركين مختلفين لم يكن هناك فرق كبير بين قيم المتوسط للمجموعات. قد تبدو هذه النتيجة لغزاً مع أن الأرقام كانت ذاتها في كلا المثالين. إن هذا يوضح القدرة النسبية لتصميم القياسات المكررة. عند استخدام نفس المشتركين في الحالات التجريبية ينخفض التباين اللامنهجي (ويدعى غالباً تباين الخطأ (error variance)) مما يجعل اكتشاف أي تباين منهجي أكثر سهولة. ويُفترض غالباً أن الطريقة التي يتم بها جمع البيانات ليس لها علاقة بالموضوع، ولكن نأمل بأننا أوضحنا أنها المسؤولة عن اكتشاف أو عدم اكتشاف الفرق. وفي الحقيقة، نفذ الباحثون دراسات باستخدام نفس المشتركين في الحالات التجريبية، وكرروا الدراسة باستخدام مشتركين مختلفين في الحالات التجريبية، ثم استخدموا طريقة جمع البيانات كمتحول مستقل في التحليل. وقد وجدوا أن طريقة جمع البيانات تتفاعل بشكل كبير مع النتائج التي يتم الحصول عليها.

8.7 الاختبار t كنموذج خطي عام

يعتقد معظم القرّاء أنه من الغريب اختيار عامل الارتباط لتمثيل حجم الأثر لاختبارات t. وقد يفكرون بأن الارتباط يبين العلاقات وليس الفروق بين القيم المتوسطة. وقد اعتقدت ذلك أيضاً إلى أن قرأت بحثاً رائعاً من إعداد Cohen (1968). وما سأقوله قد يبدو بدون معنى أو أنه سيساعدك في تقدير أن جميع الإجرائيات الإحصائية هي ذاتها في الأساس، إنها نسخ مطورة بشكل ما عن معامل الارتباط.

ورأينا في الفصل 5 أن اختبار t قد استخدم لاختبار فيما إذا معامل التراجع لمتحول تنبؤي مساوياً للصفر. والتصميم التجريبي الذي يُستخدم من أجله اختبار t المستقل يمكن تمثيله كمعادلة تراجع (فهناك متحول مستقل واحد (متحول تنبؤي) ومتحول تابع واحد (النتيجة)). إذا أردنا التنبؤ بالنتيجة فإنه يمكننا استخدام المعادلة العامة التي ذكرناها في نقاط مختلفة:

$$Outcome_i = (Model_i) + error_i$$

إذا أردنا استخدام نموذج خطي فإننا نرى أن هذه المعادلة العامة تصبح المعادلة (2.5) التي يتم فيها تعريف النموذج بواسطة الميل والاعتراض لخط مستقيم. إن المعادلة (6.7) هي معادلة شبيهة جداً فيها A_i المتحول التابع (النتيجة)، و b_0 الاعتراض، و b_1 التثقيل للمتحول التنبؤي، و G_i المتحول المستقل (المتحول التنبؤي). وقد كتبنا المعادلة مرة أخرى باستبدال الأحرف بما تمثله في تجربة العنكبوت (لذلك A=Anxiety، G=Group). عند تنفيذ تجربة ما بحالتين فإن للمتحول المستقل قيمتين فقط (المجموعة الأولى أو المجموعة الثانية). وهناك عدة طرق يمكن فيها ترميز هذه المجموعات (في مثال العنكبوت استخدمنا الرمز 0 لتمثيل المجموعة الأولى، والرمز 1 لتمثيل المجموعة الثانية). يعرف متحول الترميز بالمتحول المزيف، وتمثل قيمه مجموعات الأشخاص:

$$\begin{aligned} A_i &= b_0 + b_1.G_i + \varepsilon_i \\ Anxiety_i &= b_0 + b_1.Group_i + \varepsilon_i \end{aligned} \qquad (6.7)$$

وباستخدام مثال العنكبوت فإننا نعلم أن متوسط anxiety للمجموعة التي شاهدت صورة العنكبوت كان 40 وأن المتحول group يساوي 0 من أجل هذه الحالة. لننظر ماذا يحدث إذا عوضنا هذه القيم في المعادلة (6.7) عند إهمال حد الباقي:

$$40 = b_0 + b_1 \times 0$$

$$b_0 = 40$$

لذلك فإن الاعتراض b_0 يساوي قيمة المتوسط للمجموعة التي شاهدت صورة العنكبوت (المجموعة ذات الرمز 0) أي $\bar{X}_{picture} = 40$. إذا أصبحت قيمة group تساوي 1 فإن الحالة هي التي تم فيها عرض العنكبوت الحقيقي على المجموعة، وتبلغ قيمة المتوسط للمتحول anxiety لهذه الحالة $\bar{X}_{real} = 47$. وتأخذ المعادلة (6.7) الشكل التالي:

$$47 = b_0 + b_1 \times 1 = 40 + b_1$$

$$b_1 = 47 - 40 = \bar{X}_{real} - \bar{X}_{picture}$$

وبذلك فإن b_0 يمثل الفرق بين متوسطات المجموعات. وهكذا يمكننا تمثيل تجربة ذات مجموعتين كمعادلة تراجع فيها المعامل للمتحول المستقل يساوي الفرق بين متوسطات المجموعات، والتقاطع هو قيمة المتوسط للمجموعة ذات الرمز 0. في التراجع، يستخدم الاختبار t للتأكد فيما إذا معامل التراجع (b_1) يساوي الصفر، وعند تنفيذ اختبار t على بيانات مجمّعة فإننا نختبر فيما إذا كان الفرق بين متوسطات المجموعات يساوي الصفر.

للتحقق من ذلك، استخدم البيانات في الملف SpiderBG.sav لإجراء تراجع خطي بسيط باستخدام المتحول group كمتحول تنبؤي والمتحول anxiety كنتيجة. لقد تم ترميز المتحول group باستخدام الرمزين 0 و 1 لتمثيل المتحول المزيف الذي تم وصفه سابقاً. يجب أن يحوي الخرج الناتج عن برنامج SPSS الجدول الملخص للتراجع المبين في الخرج 5.7. إن أول ما يجب ملاحظته هو قيمة الحد الثابت b_0 إنها 40 وهي نفس قيمة المتوسط للفئة المرجعية (المجموعة التي شاهدت صورة العنكبوت). والقيمة الثانية التي يجب ملاحظتها هي قيمة معامل التراجع b_1 والتي تساوي 7 وهو الفرق بين متوسطي المجموعتين (7=40-47). وأخيراً، الإحصائية t التي تختبر فيما إذا كان b_1 مختلفاً بشكل كبير عن القيمة 0، وهي نفس قيمة اختبار t المستقل (أنظر الخرج 4.7) وكذلك قيمة الدلالة[2].

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	40.000	2.944		13.587	.000
	Condition	7.000	4.163	.337	1.681	.107

a Dependent Variable: Anxiety

الخرج 5.7 تحليل التراجع لبيانات التصميم بين المجموعات (من الملف SpiderBG.sav)

لقد بينت هذه الفقرة أن التجارب يمكن تمثيلها وفق النماذج الخطية، وهذا المبدأ أساسي في فهم الفصول القادمة حول النموذج الخطي العام GLM.

9.7 ماذا لو كانت البيانات غير موزعة طبيعياً؟

لقد رأينا في هذا الفصل أن هناك عمليات ضبط يمكن تنفيذها على الاختبار t عندما تكون فرضية تجانس التباين غي محققة، ولكن ماذا نفعل إذا كانت البيانات غير موزعة طبيعياً؟ هناك إمكانية محاولة تصحيح التوزيع باستخدام التحويلات (أنظر الفصل 3)، ولكن ذلك لا ينجح دائماً. هناك حل مفيد آخر هو استخدام واحد من مجموعة اختبارات معروفة بالاختبارات اللابارامترية (non-parametric tests). ولهذا الأختبارات فرضيات أقل من مثيلاتها البارامترية ولذلك فهي مفيدة عندما لا تحقق البيانات فرضية البيانات البارامترية المبينة في الفقرة 1.2.3.

2 إن قيمة الإحصائية t هي ذاتها ولكن بإشارة موجبة. وتذكر من الفقرة 6.5.4 المناقشة حول الارتباط ثنائي التسلسل النقطي وأنه عند ارتباط متحول ثنائي فإن اتجاه معامل الارتباط يعتمد بشكل كامل على الحالات التي تم تعيينها لكل مجموعة. ولذلك فإن اتجاه الإحصائية t هنا متأثر بالمجموعة التي تم اختيارها لتكون الفئة المرجعية (الفئة ذات الرمز 0).

ويقدم الفصل 13 بعض هذه الاختبارات. يدعى نظير الاختبار t التابع في الاختبارات اللابارامترية باسم اختبار Wilcoxon للمرتبة ذات الإشارة (Wilcoxon signed rank-test) (الفقرة 3.13)، أما اختبار t المستقل فله نظيران في الاختبارات اللابارامترية هما اختبار Wilcoxon لمجموع المراتب (Wilcoxon rank-sum test) واختبار Mann-Whitney (Mann-Whitney test) (الفقرة 2.13). وننصح بقراءة تلك الفقرات قبل المتابعة.

10.7 ما الذي اكتشفناه عن الإحصاء؟

لقد غطينا الكثير من المبادئ في هذا الفصل، وما بدا كفصل سريع في مقارنة قيمتي المتوسط انتهى ككتاب كامل. بدأنا الفصل بالنظر إلى الطرق المختلفة لجمع البيانات والفائدة من مقارنة قيمتي المتوسط. وبحثنا في بعض النقاط الهامة مثل العشوائية. تحدثنا بعد ذلك عن مخطط عمود الخطأ، وذلك في الحالات التي يتم فيها جمع البيانات باستخدام مشتركين مختلفين ثم انتقلنا لبعض المسائل وعمليات الضبط الضرورية عند استخدام نفس المشتركين لجمع البيانات. تحدثنا بعد ذلك عن المزايا العامة المبدئية للاختبار t وهو الاختبار البارامتري المستخدم لاختبار الفروق بين قيمتي المتوسط. ثم انتقلنا لدراسة اختبار t التابع بشكل خاص (والذي نستخدمه عندما تحوي الحالات التجريبية نفس المشتركين). وقد شرحنا طريقة حسابه، وكيف يتم تنفيذه في برنامج SPSS وكيفية تفسير النتائج. اكتشفنا بعد ذلك اختبار t المستقل (والذي نستخدمه عند وجود أشخاص مختلفين في الحالات التجريبية المختلفة). بحثنا أيضاً في كيفية تمثيل وضعية ذات حالتين تجريبيتين كنموذج خطي عام. وأخيراً ذكرنا المكافئات اللابارامترية لاختبارات t والتي سيتم بحثها بالتفصيل في الفصل 13 .

11.7 المصطلحات الأساسية التي اكتشفناها

التصميم بين المجموعات	(Between-group design)
التصميم بين المواضيع	(Between-subjects design)
آثار الضجر	(Boredom effects)
المتحولات المحيّرة	(Confounding variables)
الموازنة	(Counterbalancing)
اختبار t التابع	(Dependent t-test)
المتحول التابع	(Dependent variable)
مخطط عمود الخطأ	(Error bar chart)
المتوسط الكلي	(Grand mean)

التصميم المستقل	(Independent design)
اختبار t المستقل	(Independent t-test)
المتحول المستقل	(Independent variable)
آثار الممارسة	(Practice effects)
العشوائية	(Randomization)
تصميم القياسات المكررة	(Repeated measures design)
الخطأ المعياري للفروق	(Standard error of differences)
قانون مجموع التباينات	(Variance sum law)
التصميم ضمن الموضوع	(Within-subject design)

12.7 مهمات يجب تنفيذها

يحوي الملف Answers (Chapter 7).pdf الموجود على القرص المضغوط المرفق الإجابات على هذه المهمات.

- **المهمة الأولى:** ضمن خطة المؤلف (Field) لتخليص العالم من علم النفس الشعبي فقد قام بتجربة صغيرة. أخذ مجموعتين من الأشخاص تربطهم علاقات معينة ووزعهم بشكل عشوائي على حالتين تجريبيتين. قرأت إحدى المجموعتين كتاب علم النفس الشعبي الشهير Women are from Bras and man are from Penis. أما المجموعة الثانية فقد قرأت Marie Claire. وقام باختبار 10 أشخاص من كل مجموعة، وكان المتحول التابع هو قياس موضوعي لمدى سعادتهم بعلاقاتهم بعد قراءة الكتاب. ولم تكن هناك توقعات معينة عن المواد المقروءة التي ستحسّن السعادة في العلاقات. يحوي الملف Penis.sav هذه البيانات، عليك تحليل هذه البيانات باستخدام اختبار t المناسب.
- **المهمة الثانية:** تخيل أن دار النشر التي تقوم بنشر Women are from Bras and man are from Penis كانت متزعجة من الإدعاء بأن الكتاب غير مفيد إطلاقاً. وقررت إجراء تجربة يقوم المشتركون فيها بقراءة كتابهم ثم قراءة أحد كتب المؤلف (Field & Hole) في أوقات مختلفة. وتم قياس سعادة العلاقة لهؤلاء المشتركين بعد قراءة كل كتاب. ولزيادة فرصتهم في العثور على فرق فقد استخدموا عينة من 500 مشترك. وطُلب من كل مشترك أن يشارك في الحالتين (قراءة الكتابين). وتمت الموازنة في ترتيب قراءة الكتابين وكانت الفترة الفاصلة بين قراءة الكتابين هي 6 أشهر. وقد توقعت دار النشر أن قراءة مساهمتهم الرائعة في علم النفس الشعبي ستؤدي لتحسين سعادة العلاقة أكثر من قراءة كتاب ممل حول تجاربهم. يحوي الملف Field&Hole.sav هذه البيانات، عليك تحليل هذه البيانات باستخدام اختبار t المناسب.

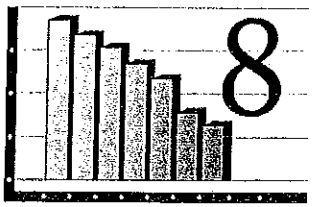

مقارنة عدة متوسطات ANOVA (GLM1)

1.8 ماذا يخبرنا هذا الفصل

لقد عرض الفصل السابق كيفية النظر إلى الفروق بين حالتين أو مجموعتين من الناس. وتعتبر الاختبارات التي اكتشفناها في ذلك الفصل أدوات مفيدة في أبحاث علم الاجتماع، ولكنها محدودة بالأوضاع التي فيها للمتحول المستقل مستويان فقط (كمجموعتي اختبار مثلاً). ومن الشائع تنفيذ تجارب يكون فيها ثلاثة أو أربعة أو أحياناً خمسة مستويات للمتحول المستقل، وفي هذه الحالة تكون الاختبارات المقدمة في الفصل 7 غير مناسبة. وبدلاً من ذلك تُستخدم التقنية المسماة تحليل التباين ANOVA (analysis of variance). وتتميز ANOVA بأنه يمكن استخدامها لتحليل الأوضاع التي يكون فيها عدد مستويات المتحولات المستقلة ثلاثة أو أكثر. وتخبرنا ANOVA في هذه الحالات عن كيفية تفاعل المتحولات المستقلة مع بعضها البعض وآثار هذه التفاعلات على المتحول التابع. لذلك يبدأ هذا الفصل بشرح الأسس النظرية لتحليل التباين عند استخدام مشتركين مختلفين (ANOVA المستقلة). ثم ننتقل لتنفيذ هذا التحليل في برنامج SPSS وتفسير النتائج.

2.8 الأسس النظرية لتحليل التباين ANOVA

1.2.8 معدلات الخطأ المتضخم

قبل شرح آلية عملية ANOVA سنتوقف عند الفكرة التالية: لماذا لا نقوم بتنفيذ عدة اختبارات t لمقارنة جميع التراكيب المحتملة للمجموعات التي يتم اختبارها؟. تخيل الوضع الذي توجد فيه ثلاث حالات تجريبية وأننا نهتم بالفروق بين هذه المجموعات الثلاث. إذا أردنا تنفيذ اختبارات t على كل زوج من المجموعات فإن علينا تنفيذ 3 اختبارات منفصلة: الأول لمقارنة المجموعتين 1 و2، والثاني لمقارنة المجموعتين 1 و3، والثالث لمقارنة المجموعتين 2 و3. إذا استخدم كل اختبار من هذه الاختبارات المستوى 0.05 للدلالة فإنه من أجل كل اختبار يكون احتمال رفض فرضية العدم عن طريق الخطأ (والمعروف بالخطأ من النوع الأول) هو 5% فقط. ولذلك فإن احتمال عدم وجود

خطأ من النوع الأول هو 95% لكل اختبار. إذا افترضنا أن كل اختبار هو مستقل (وبذلك يمكننا حساب جداء الاحتمالات) فإن الاحتمال الكلي لعدم وجود خطأ من النوع الأول هو $(0.95)^3=0.857$. وهكذا يمكننا حساب احتمال ارتكاب الخطأ من النوع الأول بطرح هذه القيمة من العدد 1 أي 1-0.857=0.143 أو 14.3%. كما نرى من خلال هذه المجموعة من الاختبارات فقد ازداد احتمال ارتكاب الخطأ من النوع الأول من 5% إلى 14.3% وهي قيمة أكبر من المعيار المقبول من قبل علماء الاجتماع. يُعرف معدل الخطأ عبر الاختبارات الإحصائية المنفذة على نفس البيانات التجريبية باسم معدل الخطأ حسب العائلة أو التجربة (Familywise or Experimentwise error rate). إن التجربة ذات الحالات الثلاث بسيطة نسبياً، وأثر تنفيذ عدة اختبارات ليس كبيراً. أما إذا رفعنا عدد الحالات التجريبية من 3 إلى 5 (أي حالتين إضافيتين فقط) فإن عدد اختبارات t المطلوب سيرتفع إلى 10، ويمكن حساب الخطأ حسب العائلة من المعادلة العامة (1.8)، حيث n عدد الاختبارات المنفذة على البيانات:

$$\text{Familywise error} = 1 - (0.95)^n \qquad (1.8)$$

ومن أجل 10 اختبارات فإن قيمة الخطأ تكون $1-(0.95)^{10}=0.40$ وهذا يعني أن احتمال ارتكاب خطأ من النوع الأول هو 40%. ولهذا السبب نستخدم تقنية ANOVA بدلاً من تنفيذ مجموعة من الاختبارات. عند تنفيذ اختبار t فإننا نختبر فرضية أن للعينتين نفس قيمة المتوسط. وبشكل مشابه تخبرنا ANOVA فيما إذا كانت ثلاثة متوسطات أو أكثر متساوية، ولذلك فهي تختبر فرضية أن جميع المتوسطات للمجموعات متساوية. وتعطي ANOVA إحصائية F أو نسبة F وهي شبيهة لإحصائية t من حيث مقارنتها مقدار التباين المنهجي في البيانات مع مقدار التباين اللامنهجي. على كل حال، تعتبر ANOVA اختباراً شاملاً وهذا يعني أنها تختبر الأثر التجريبي الكلي، ولذلك فإن هناك بعض الأمور التي لا تستطيع إخبارنا عنها. ومع أن ANOVA تدل على فيما إذا كان التلاعب التجريبي ناجحاً بشكل عام، فإنها لا توفر معلومات محددة عن المجموعات المتأثرة. لنفرض أنه تم تنفيذ تجربة على ثلاث مجموعات مختلفة، تخبرنا النسبة F ببساطة أن المتوسطات لهذه العينات الثلاث ليست متساوية (أي أن المساواة $\bar{X}_1 = \bar{X}_2 = \bar{X}_3$ ليست صحيحة). وعلى كل حال، هناك عدة إمكانيات يمكن أن تختلف بها المتوسطات. الإمكانية الأولى هي أن جميع المتوسطات مختلفة عن بعضها البعض $(\bar{X}_1 \neq \bar{X}_2 \neq \bar{X}_3)$. والإمكانية الثانية هي أن المتوسطات للمجموعتين 1 و2 متساوية ولكن المتوسط للمجموعة 3 مختلف بشكل كبير عنها $(\bar{X}_1 = \bar{X}_2 \neq \bar{X}_3)$. وإمكانية أخرى هي أن للمجموعتين 2 و3 نفس المتوسط ولكن المتوسط للمجموعة 1 مختلف $(\bar{X}_1 \neq \bar{X}_2 = \bar{X}_3)$. وأخيراً هناك إمكانية أن يكون للمجموعتين 1 و 3 نفس المتوسط ولكن المتوسط للمجموعة 2 مختلف $(\bar{X}_1 = \bar{X}_3 \neq \bar{X}_2)$. ولذلك فإن النسبة F تدلنا على أن للتلاعب التجريبي بعض الآثار ولكنها لا تدلنا على المجموعة المتأثرة بالتحديد.

2.2.8 ANOVA كتراجع

إن بعض علماء المجتمع غير مدرك لحقيقة أن ANOVA والتراجع هما من ناحية المبدأ نفس الإجرائية. والسبب وراء ذلك تاريخي، فقدً تطور في علم الاجتماع فرعان متمايزان في المنهجية: أبحاث الارتباط والأبحاث التجريبية. وقد اعتمد الباحثون المهتمون بالتجارب المراقبة ANOVA كإحصائية مميزة لهم بينما اعتمد الباحثون المهتمون في علاقات العالم الحقيقي التراجع المتعدد و لم يحاول أي فريق من الباحثين الإدعاء بأن اختياره للمنهجية هو الأفضل. ومع الانقسام في المنهجية حدثت هوّة بين الطرق الإحصائية المعتمدة لدى الفريقين. وقد استمر هذا الانقسام لعدة عقود إلى حد أن الطلاب يتعلمون التراجع وANOVA في سياقات مختلفة تماماً، ومعظم الكتب تعطي ANOVA بطريقة مختلفة تماماً عن التراجع. وقد حاول عدد من الباحثين تصحيح الوضع (Jacob Cohen,1968). وهناك عدة أسباب وجيهة تبرر الدعوة لتعليم ANOVA ضمن إطار التراجع. أولاً يوفر التراجع سياقاً معروفاً، فقد خصصنا فقرات مطوّلة لشرح التراجع فلماذا لا نستفيد من هذه القاعدة المعرفية لشرح مفهوم جديد. وثانياً، إن الطرق التقليدية لتعليم ANOVA المعروفة بطريقة نسبة التباين (Variance-ratio) مناسبة للتصاميم البسيطة، ولكنها تصبح مربكة لحد كبير في الحالات المعقدة (كما في تحليل التباين المشترك). يتوسع نموذج التراجع بشكل منطقي جداً في الحالات المعقدة دون الحاجة للغوص في الرياضيات. وأخيراً، تصبح طريقة نسبة التباين غير قابلة للإدارة في الظروف غير العادية كما في حالة أحجام العينات غير المتساوية. بينما تجعل طريقة التراجع هذه الأوضاع أبسط بكثير. ومع أن هذه الأسباب كافية لحد ما، فإنها أيضاً حالة البرنامج SPSS الذي ابتعد عن طريقة نسبة التباين للتقنية ANOVA وتطور باتجاه استخدام نموذج التراجع المعروف بالنموذج الخطي العام General Linear Model (GLM). والنتيجة النهائية لهاتين الطريقتين في تناول ANOVA هي ذاتها، وبما أن معظم الكتب تتناول طريقة نسبة التباين بالتفصيل (Howell, 2002) فهذا يبرر لنا عرض طريقة التراجع في هذا الكتاب.

تعتبر ANOVA طريقة لمقارنة نسبة التباين المنهجي إلى التباين اللامنهجي في دراسة تجريبية ما. تُعرف نسبة هذه التباينات بالنسبة F (F-ratio). ويستطيع من قرأ الفصل 5 أن يعرف النسبة F (انظر الفقرة 3.2.5) لأنها استُخدمت لتقييم مدى جودة نموذج التراجع في التنبؤ بالنتيجة مقارنة مع الخطأ ضمن النموذج. وإذا لم تقرأ الفصل 5 فأنصحك بقراءته قبل المتابعة. إن النسبة F في ANOVA هي ذاتها الموجودة في التراجع، باستثناء أن نموذج التراجع يحوي متحولات تنبؤية فئوية فقط (كمتحولات التجميع مثلاً). لذلك وكما مثّلنا الاختبار t بمعادلة تراجع خطي (انظر الفقرة 8.7)، فإنه يمكن تمثيل ANOVA بمعادلة تراجع متعدد يكون عدد المتحولات التنبؤية فيها أقل بواحد من عدد الفئات للمتحول المستقل.

لنأخذ مثالاً. يعتبر Viagra منشطاً جنسياً يستخدم لمعالجة العجز الجنسي، وقد تدفق إلى السوق السوداء مع الاعتقاد بأنه يجعل الإنسان أفضل من الناحية الجنسية. لنفترض أننا اختبرنا هذا الاعتقاد

بأخذ 3 مجموعات من المشتركين، وأعطينا المجموعة الأولى علاجاً تمويهياً (من مادة غير فعالة كالسكر مثلاً)، والمجموعة الثانية جرعة منخفضة من Viagra والمجموعة الثالثة جرعة مرتفعة من Viagra. والمتحول التابع هو قياس موضوعي للشهوة الجنسية (Libido). يحوي الملف Viagra.sav بيانات هذا المثال (سيتم شرحه بالتفصيل لاحقاً) والمبينة في الجدول 1.8.

	مجموعة الدواء التمويهي	مجموعة الجرعة المنخفضة	مجموعة الجرعة المرتفعة
	3	5	7
	2	2	4
	1	4	5
	1	2	3
	4	3	6
المتوسط $\bar{X}$	2.20	3.20	5.00
الانحراف المعياري (s)	1.30	1.30	1.58
التباين (s^2)	1.70	1.70	2.50
المتوسط الكلي= 3.467			
الانحراف المعياري الكلي= 1.767			
التباين الكلي= 3.124			

الجدول 1.8 بيانات الملف Viagra.sav

إذا أردنا أن نتوقع مستويات الشهوة انطلاقاً من المستويات المختلفة للدواء Viagra فإننا نستخدم المعادلة العامة:

$$Outcome_i = (Model_i) + error_i$$

إذا أردنا استخدام نموذج خطي فقد رأينا في الفقرة 8.7 أنه عند وجود مجموعتين فقط يمكننا استبدال الكلمة Model في المعادلة بمعادلة التراجع الخطي مع متحول مزيف واحد لوصف المجموعتين التجريبيتين. وقد كان هذا المتحول المزيف متحولاً فئوياً مع الترميز العددي (0 لمجموعة ما و1 للمجموعة الأخرى). وفي حالة 3 مجموعات يمكننا توسيع هذه الفكرة واستخدام نموذج التراجع المتعدد مع متحولَين مزيَفين. كقاعدة عامة يمكننا توسيع النموذج لأي عدد من المجموعات بحيث يكون عدد المتحولات المزيفة المطلوبة هو أقل بواحد من عدد الفئات أو المتحولات المستقلة. في حالة المجموعتين، جعلنا إحدى المجموعتين مجموعة مرجعية (تذكّر أننا في الفقرة 8.7 جعلنا حالة الصورة هي المجموعة المرجعية) وأعطيناها الرمز 0. وعند وجود 3 فئات فإننا بحاجة أيضاً إلى فئة مرجعية ويجب اختيار الحالة التي نريد مقارنة المجموعات الأخرى معها. وعادةً تكون هذه الفئة هي مجموعة المراقبة. وفي معظم تجارب علم الاجتماع المصممة بشكل جيد ستكون هناك مجموعة من المشتركين التي تعمل كمرجع لبقية الفئات.

وتعمل المجموعة المرجعية كمرجع أو فئة مرجعية مع أن المجموعة التي تختارها ستعتمد على الفرضيات الخاصة التي تريد اختبارها. في التصاميم غير المتوازنة (حيث أبعاد المجموعات غير متساوية) من الضروري أن تحوي الفئة المرجعية عدداً أكبر من الحالات لنضمن أن التقديرات لمعاملات التراجع موثوقة. في المثال الحالي، يمكننا أخذ مجموعة الدواء التمويهي كفئة مرجعية لأنها تعمل كمجموعة مراقبة. ونحن نهتم بمقارنة مجموعتي الجرعة المنخفضة والجرعة المرتفعة مع المجموعة التي لم تتناول Viagra أبداً. إذا كانت مجموعة الدواء التمويهي هي الفئة المرجعية فإن المتحولين المزيفين اللذين نريد إنشاؤهما سيمثلان الحالتين التجريبيتين الباقيتين، ولذلك نسمي المتحول المزيف الأول High (ليمثل مجموعة الجرعة المرتفعة) والمتحول المزيف الثاني Low (ليمثل مجموعة الجرعة المنخفضة). وتكون المعادلة الناتجة هي المعادلة (2.8):

$$Libido_i = b_0 + b_2\,High_i + b_1\,Low_i + \varepsilon_i \qquad (2.8)$$

يمكن التنبؤ بقيمة الشهوة لشخص ما بمعرفة رمز مجموعته (الرمز للمتحولات المزيفة High و Low) وقيمة الاعتراض b_0 للنموذج. يمكن ترميز المتحولات المزيفة في المعادلة (2.8) بعدة طرق، ولكن أسهل طريقة هي استخدام تقنية مشابهة للاختبار t. يتم ترميز الفئة المرجعية بالرمز 0 دائماً. إذا حصل المشترك على جرعة مرتفعة من Viagra فيتم ترميزه بالقيمة 1 للمتحول المزيف High، والقيمة 0 لبقية المتحولات. وإذا حصل المشترك على جرعة منخفضة من Viagra فيتم ترميزه بالقيمة 1 للمتحول المزيف Low، والقيمة 0 لبقية المتحولات، (وهو نفس مخطط الترميز الذي استخدمناه في الفقرة 10.5). وباستخدام هذا المخطط للترميز يمكننا التعبير عن كل مجموعة بتركيب من هذه الرموز للمتحولين المزيفين (انظر الجدول 2.8).

المجموعة	المتحول المزيف الأول High	المتحول المزيف الثاني Low
دواء تمويهي	0	0
جرعة منخفضة	0	1
جرعة مرتفعة	1	0

الجدول 2.8 الترميز المزيف للتجربة ذات المجموعات الثلاث

مجموعة الدواء التمويهي: لنتحقق من النموذج في حالة مجموعة الدواء التمويهي. تكون قيم المتحولين High و Low مساوية للصفر. فإذا أهملنا حد الباقي ε_i فإن معادلة التراجع تصبح:

$$Libido_i = b_0 + b_2 \times 0 + b_1 \times 0 = b_0$$

$$\overline{X}_{Placebo} = b_0$$

في هذا الوضع تم استثناء مجموعتي الجرعة المرتفعة والجرعة المنخفضة (لأنهما تحملان الرمز 0). ونبحث عن التنبؤ بمستوى الشهوة عند إهمال مجموعتي الجرعة المرتفعة والمنخفضة، ولذلك فإن القيمة المتوقعة هي متوسط المجموعة ذات الدواء التمويهي (لأنها الوحيدة التي تدخل في النموذج).

وهكذا فإن الاعتراض لنموذج التراجع (b_0) هو المتوسط للفئة المرجعية دائماً (وهي فئة الدواء التمويهي في هذا المثال).

مجموعة الجرعة المرتفعة: إذ أردنا التحقق من مجموعة الجرعة المرتفعة فإن قيمة المتحول المزيف High ستكون 1، وقيمة المتحول المزيف Low ستكون 0. إذا بدلنا هذه القيم في المعادلة (2.8) فإن معادلة النموذج تصبح:

$$Libido_i = b_0 + (b_2 \times 1) + (b_1 \times 0) = b_0 + b_2$$

ونعلم أن b_0 هو متوسط مجموعة الدواء التمويهي. إذا كنا نهتم بمجموعة الجرعة المرتفعة فإن على النموذج أن يتوقع أنّ قيمة الشهوة لمشترك معين تساوي متوسط المجموعة ذات الجرعة المرتفعة. وبالاستفادة من هذه المعلومة فإن المعادلة تصبح:

$$Libido_i = b_0 + b_2$$
$$\overline{X}_{High} = \overline{X}_{Placebo} + b_2$$
$$b_2 = \overline{X}_{High} - \overline{X}_{Placebo}$$

وهكذا فإن b_2 يمثل الفرق بين متوسطي المجموعة ذات الجرعة المرتفعة ومجموعة الدواء التمويهي.

مجموعة الجرعة المنخفضة: أخيراً، إذا نظرنا إلى النموذج عند أخذ مجموعة الجرعة المنخفضة فإن قيمة المتحول المزيف Low ستكون 1، وقيمة المتحول المزيف High ستكون 0. وبذلك تصبح معادلة التراجع:

$$Libido_i = b_0 + (b_2 \times 0) + (b_1 \times 1) = b_0 + b_1$$

وتعلم أن الاعتراض b_0 هو متوسط الفئة المرجعية، ومن أجل مجموعة الجرعة المنخفضة فإن القيمة المتوقعة يجب أن تساوي متوسط المجموعة ذات الجرعة المنخفضة، وهكذا يتحول النموذج إلى الشكل:

$$Libido_i = b_0 + b_1$$
$$\overline{X}_{Low} = \overline{X}_{Placebo} + b_1$$
$$b_1 = \overline{X}_{Low} - \overline{X}_{Placebo}$$

وهكذا فإن b_1 يمثل الفرق بين متوسطي المجموعة ذات الجرعة المنخفضة ومجموعة الدواء التمويهي.

إن هذا الشكل لترميز المتحول المزيف هو أبسط الأشكال ولكن كما سنرى لاحقاً هناك عدة طرق يمكن فيها ترميز المتحولات وفقاً لفرضيات محددة للاختبار. تُعرف مخططات الترميز البديلة بالمقارنات (Contrasts) (انظر الفقرة 2.10.2.8). والفكرة من المقارنات أنك تستطيع ترميز المتحولات المزيفة بطريقة تمثل فيها قيم b الفروق بين المجموعات التي تهتم باختبارها.

لتوضيح ما سنقوم به بالضبط فقد أنشأنا ملفاً باسم dummy.sav في المجلد Chapter 8 على القرص المضغوط المرفق. يحوي هذا الملف بيانات Viagra مع متحولين إضافيين (dummy1 وdummy2)

يحددان المجموعة التي تنتمي إليها نقطة البيانات (كما في الجدول 2.8). افتح هذا الملف ونفذ تحليل التراجع المتعدد باستخدام المتحول Libido كنتيجة والمتحولين dummy1 وdummy2 كمتحولين تنبؤيين. إذا لم تعرف كيفية القيام بالتراجع المتعدد فإن عليك قراءة الفصل 5 مرة أخرى (هناك سبب منطقي لترتيب الفصول بهذا الشكل!). يبين الخرج 1.8 التحليل الناتج. ولا بأس من العودة إلى الجدول 1.8 الذي يبين قيم المتوسط للمجموعات الثلاث. إن أول ما يجب ملاحظته هو أن الحد الثابت يساوي متوسط الفئة المرجعية (مجموعة الدواء التمويهي). أما معامل التراجع للمتحول المزيف الأول (b_2) فيساوي الفرق بين المتوسطين لمجموعة الجرعة المرتفعة ومجموعة الدواء التمويهي (5.0-2.2=2.8). وأخيراً فإن معامل التراجع للمتحول المزيف الثاني (b_1) يساوي الفرق بين المتوسطين لمجموعة الجرعة المنخفضة ومجموعة الدواء التمويهي (3.2-2.2=1.0). يوضح هذا التحليل كيف يمثل نموذج التراجع وضعاً بثلاث مجموعات. يمكننا أن نرى من خلال قيم الدلالة للاختبارات t أن الفرق بين مجموعة الجرعة المرتفعة ومجموعة الدواء التمويهي (b_2) ذو دلالة لأن $p<0.05$. أما الفرق بين مجموعة الجرعة المنخفضة ومجموعة الدواء التمويهي فهو بدون دلالة لأن $p=0.282$.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	2.200	.627		3.508	.004
	Dummy Variable1	2.800	.887	.773	3.157	.008
	Dummy Variable2	1.000	.887	.276	1.127	.282

a. Dependent Variable: Libido

الخرج 1.8

يمكن توسيع هذا السيناريو لدراسة تجربة ذات 4 مجموعات. وقد ذكرنا سابقاً أن عدد المتحولات المزيفة سيكون أقل بواحد من عدد المجموعات في التجربة، ولذلك فإن النموذج بحاجة إلى 3 متحولات مزيفة. وكما قلنا سابقاً فإن علينا تحديد إحدى الفئات كفئة مرجعية (مجموعة مراقبة). يجب أن يكون رمز هذه الفئة المرجعية هو 0 للمتحولات المزيفة الثلاثة. أما بقية الحالات فتأخذ الرمز 1 للمتحول المزيف الذي يمثلها و0 لبقية المتحولات المزيفة. يوضح الجدول 3.8 مخطط الترميز لهذا السيناريو.

3.2.8 المنطق وراء النسبة F

تعرفنا في الفصل 5 على النسبة F وطريقة حسابها. وتعلمنا أن النسبة F مستخدمة لاختبار التوافق الكلي لنموذج التراجع مع مجموعة من البيانات المشاهدة. وقد شرحنا كيف يمكن تمثيل ANOVA

كمعادلة تراجع، ويجب أن يساعدك ذلك في فهم ما يمكن أن تخبرنا به النسبة F عن البيانات. يعرض الشكل 1.8 بيانات Viagra بشكل بياني (يتضمن متوسطات المجموعات، والمتوسط الكلي، والفرق بين كل حالة ومتوسط المجموعة).

	المتحول المزيف 1	المتحول المزيف 2	المتحول المزيف 3
المجموعة 1	1	0	0
المجموعة 2	0	1	0
المجموعة 3	0	0	1
المجموعة 4 (المرجعية)	0	0	0

الجدول 3.8 الترميز المزيف لتجربة ذات 4 مجموعات

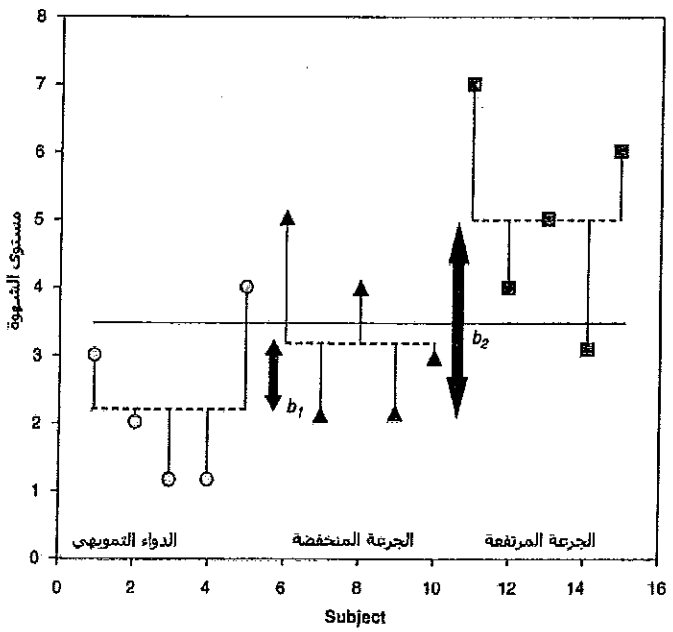

الشكل 1.8 الشكل البياني لبيانات الملف Viagra. تمثل الخطوط المتقطعة متوسط الشهوة لكل مجموعة. أما الأشكال فتمثل الشهوة للمشتركين المنفردين (تدل الأشكال المختلفة على المجموعات التجريبية المختلفة). ويمثل الخط الأفقي المستمر المتوسط الكلي لجميع المشتركين.

في هذا المثال، لدينا ثلاث مجموعات، ولذلك نريد اختبار فرضية أن القيم المتوسطة للمجموعات الثلاث مختلفة (أي أن فرضية العدم هي تَساوي المتوسطات للمجموعات الثلاث). إذا كانت جميع المتوسطات متساوية فلن نتوقع أن تختلف مجموعة الدواء التمويهي عن مجموعة الجرعة المنخفضة أو

مجموعة الجرعة المرتفعة، ولن نتوقع أن تختلف مجموعة الجرعة المنخفضة عن مجموعة الجرعة المرتفعة. لذلك تكون الخطوط المتقطعة على المخطط منطبقة على بعضها عند المستوى الشاقولي ذاته (والوضع الدقيق سيكون المتوسط الكلي). ولكننا وجدنا في نموذج التراجع أن b_2 تمثل الفرق بين متوسطي المجموعتين ذات الجرعة المرتفعة وذات الدواء التمويهي، وأن b_1 تمثل الفرق بين متوسطي المجموعتين ذات الجرعة المنخفضة وذات الدواء التمويهي. وقد تم تمثيل هذه الفروق بالأسهم الشاقولية في المخطط 1.8. إذا تحققت فرضية العدم وكان لجميع المجموعات نفس قيمة المتوسط فإن المعاملات b يجب أن تكون مساوية للصفر. وينتج منطق ANOVA مما فهمناه عن التراجع:

- إن النموذج الأبسط الذي يتوافق مع مجموعة من البيانات هو المتوسط الكلي (المتوسط لمتحول النتيجة). وعندما يتوافق هذا النموذج الأساسي فإننا نحصل على مقادير كبيرة للخطأ بين النموذج والبيانات المشاهدة.
- يمكن اختيار أحد الخطوط المستقيمة العديدة كنموذج للبيانات المجمعة. إذا توافق هذا النموذج مع البيانات بشكل جيد فإنه يجب أن يكون أفضل من استخدام المتوسط الكلي.
- يمكن وصف المستقيم المختار باستخدام الاعتراض وواحد من معاملات التراجع أو أكثر.
- تحدد معاملات التراجع ميل المستقيم، ولذلك كلما كانت قيم المعاملات أكبر كان الانحراف بين الخط والمتوسط الكلي أكبر.
- في ANOVA تتحدد معاملات التراجع بالفروق بين متوسطات المجموعات.
- كلما كانت الفروق بين متوسطات المجموعات أكبر كان الفرق بين مستقيم التراجع والمتوسط الكلي أكبر.
- إذا كانت الفروق بين متوسطات المجموعات كبيرة لحد كافٍ فإن المستقيم الناتج سيمثل توافقاً للبيانات أفضل من المتوسط الكلي.
- لذلك إذا كانت متوسطات المجموعات مختلفة بشكل كبير فإننا نتوقع أن يكون نموذج التراجع أفضل من المتوسط الكلي كتوافق للبيانات.

ونتحقق من صحة العبارة الأخيرة بمقارنة التحسن في التوافق والناتج عن استخدام النموذج (بدلاً من المتوسط الكلي) مع الخطأ المتبقي. ويمكن أن نعبر عن ذلك بطريقة أخرى وهي أنه عند استخدام المتوسط الكلي كنموذج فإن هناك مقداراً معيناً من التغاير بين البيانات والمتوسط الكلي. وعند ملاءمة نموذج ما فإنه يفسر قسماً من هذا التغاير ولكن يبقى قسم آخر دون تبرير. وتمثل النسبة F نسبة التغاير المبرر إلى غير المبرر. ينبغي عليك العودة الآن للفقرة 3.2.5 لتنشيط ذاكرتك حول هذه المبادئ قبل المتابعة. قد يبدو ذلك معقداً ولكن معظم التغايرات تخلص إلى معادلة بسيطة واحدة (انظر المربع 1.8).

المربع 1.8 ربما تتفاجأ من معرفة أن ANOVA تنتهي بمعادلة واحدة!

في كل مرحلة من تحليل التباين (ANOVA) نجري تقييماً للتغاير (أو الحيدان) عن نموذج معين (سواءً كان النموذج الأبسط أو الأكثر تقدماً). وقد رأينا في الفقرة 1.4.1 أنه يمكن التعبير عن الحد الذي يمكن أن ينحرف النموذج به عن البيانات المشاهدة بالمعادلة (3.8). لذلك فإننا نستخدم المعادلة (3.8) في تحليل التباين كتراجع لحساب توافق النموذج الأبسط، ثم توافق النموذج الأفضل (خط التوافق الأفضل). فإذا كان النموذج الأفضل جيداً بشكل ما فإن توافقه مع البيانات سيكون أفضل من النموذج الأساسي البسيط:

$$\text{deviation} = \sum(\text{Observed} - \text{Model})^2 \qquad (3.8)$$

النقطة المهمة هي أن جميع مجاميع المربعات في ANOVA هي أشكال مختلفة من هذه المعادلة الأساسية. فكل ما يتغير هو ما نستخدمه كنموذج، والقيم المشاهدة الموافقة. انظر في الفقرات المختلفة حول مجاميع المربعات وقارن المعادلات الناتجة مع المعادلة (3.8)، ستكون جميعها أشكال مختلفة من هذا الشكل العام للمعادلة (3.8).

4.2.8 المجموع الكلي للمربعات SS_T

لإيجاد المقدار الكلي للتغاير ضمن البيانات، نحسب الفرق بين كل نقطة من البيانات المشاهدة والمتوسط الكلي. ثم نقوم بتربيع هذه الفروق وجمعها معاً للحصول على المجموع الكلي للمربعات (SS_T):

$$SS_T = \sum(X_i - \overline{X}_{grand})^2 \qquad (4.8)$$

وقد رأينا في الفقرة 1.4.1 أن التباين ومجاميع المربعات مرتبطة بحيث يكون $s^2=SS/(N-1)$ حيث N هو عدد المشاهدات. لذلك يمكننا حساب المجموع الكلي للمربعات من التباين لجميع المشاهدات (التباين الكلي (The grand variance)) بإعادة ترتيب العلاقة بالشكل $SS=s^2.(N-1)$. والتباين الكلي هو التغاير بين جميع العلامات بغض النظر عن الحالات التجريبية التي تنتمي إليها تلك العلامات. وبالعودة للشكل (1.8) فإنه يكون مجموع مربعات المسافات بين كل نقطة والخط الأفقي المستمر. يعطى التباين الكلي لبيانات Viagra في الجدول 1.8، وإذا حسبنا عدد المشاهدات فإننا نجد أنه يساوي 15، ولذلك يتم حساب SS_T بالشكل التالي:

$$SS_T = s^2_{grand}(n-1) = 3.124(15-1) = 43.74$$

وقبل المتابعة، من الضروري أن نفهم درجات الحرية، لذلك عليك قراءة المربع 2.8.

المربع 2.8 درجات الحرية

من الصعب شرح مبدأ درجات الحرية (df)، وقد أشرنا عدة مرات لدرجات الحرية دون تعريف أو توضيح المبدأ. لنبدأ بحالة تشابه، لنتخيل أنك مدير فريق الركبي ولديك ورقة الفريق مع 15 شقاً فارغاً لتمثيل المواقع في الملعب. هناك تشكيل قياسي في الركبي ولذلك فإن لكل فريق 15 موقعاً محدداً يجب المحافظة عليها ثابتة في المباراة التي سيتم خوضها. عند وصول اللاعب الأول يمكنك اختيار موقع من بين 15 موقعاً متوفراً لوضع هذا اللاعب فيه. تضع اسم اللاعب الأول في الشق الذي يمثل الموقع الذي اخترته له. وعند وصول اللاعب الثاني يمكنك اختيار موقع من بين 14 موقعاً متبقياً ولكن ما زالت لديك الحرية لاختيار الموقع الذي ستضع فيه هذا اللاعب. ومع وصول مزيد من اللاعبين ستصل إلى النقطة التي يتم فيها ملء 14 موقعاً، وعندها يصل اللاعب الأخير، لم يبق سوى موقع فارغ واحد لهذا اللاعب وليس لديك حرية الاختيار. ولذلك فإن عدد درجات الحرية هو 14، لأنك تمتعت بنوع من الحرية في اختيار الموقع لعدد من اللاعبين يصل إلى 14، ومن أجل لاعب 1 لم تكن حرية اختيار الموقع. إذاً عدد درجات الحرية = عدد اللاعبين -1.

وفيما يتعلق بالإحصاء فإن عدد درجات الحرية مرتبط بعدد المشاهدات التي تتمتع بحرية التغير. إذا أخذنا عينة مؤلفة من 4 مشاهدات من مجتمع ما، فإن هذه العلامات الأربع حرة في التغير بالطريقة التي تريدها (يمكنها أن تأخذ أية قيمة). إذا استخدمنا هذه العينة لحساب الانحراف المعياري للمجتمع، فإن علينا أن نستخدم قيمة المتوسط للعينة كتقدير لمتوسط المجتمع. وبذلك نبقي أحد البارامترات ثابتاً. ليكن متوسط العينة 10، ولذلك نفترض أن متوسط المجتمع هو 10 أيضاً ونحافظ على هذه القيمة ثابتة. إذا كان هذا البارامتر ثابتاً فهل يمكن لجميع العلامات في العينة أن تتغير؟ الجواب هو لا، وذلك لأن المحافظة على قيمة المتوسط ثابتة تسمح لثلاث قيم فقط بحرية التغير. فعلى سبيل المثال إذا كانت القيم هي 8 و 9 و 11 و 12 (المتوسط=10) وقمنا بتغيير ثلاثة من هذه القيم إلى 7 و 15 و 8 فإن القيمة الرابعة ستكون حتماً 10 وذلك للمحافظة على قيمة المتوسط 10 ثابتة. لذلك إذا أبقينا أحد البارامترات ثابتاً فإن عدد درجات الحرية يجب أن يكون أقل من حجم العينة بمقدار 1. وتفسر هذه الحقيقة سبب استخدام العدد N-1 بدلاً من N عند حساب الانحراف المعياري لمجتمع (كما فعلنا في الفقرة 1.4.1). ومن أجل حساب المجموع الكلي للمربعات (SS_T) فإننا نستخدم العينة بكاملها لحساب مجموع المربعات ولذلك فإن عدد درجات الحرية الكلي (df_T) هو أقل بواحد من حجم العينة أي (N-1). ومن أجل المثال Viagra فإن هذه القيمة تكون 14=1-15.

5.2.8 مجموع المربعات للنموذج SS_M

نعلم أن المقدار الكلي للتغاير ضمن البيانات هو 43.74 وحدة، ولكننا نريد معرفة المقدار الذي يمكن أن يفسره نموذج التراجع من هذا التغاير. في سيناريو ANOVA يعتمد النموذج على الفروق بين متوسطات المجموعات ولذلك فإن مجموع المربعات للنموذج يدلنا على الجزء من التغاير الكلي الذي يمكن تفسيره بحقيقة أن نقاط البيانات المختلفة تأتي من المجموعات المختلفة. وباختصار فإن النموذج يمثل أثر التلاعب التجريبي.

وقد رأينا في الفقرة 3.2.5 أنه يتم حساب مجموع المربعات للنموذج بأخذ الفرق بين القيم المتوقعة من قبل النموذج والمتوسط الكلي (انظر الشكل 3.5). وفي ANOVA تكون القيم المتوقعة من قبل النموذج هي متوسطات المجموعات (ولذلك فإن الخطوط المتقطعة في الشكل 1.8 تمثل قيم الشهوة المتوقعة من قبل النموذج). ومن أجل كل مشترك فإن القيمة المتوقعة من قبل النموذج هي قيمة المتوسط للمجموعة التي ينتمي إليها المشترك. وفي المثال Viagra تكون القيمة المتوقعة للمشتركين من المجموعة ذات الدواء التمويهي هي 2.2، وللمشتركين من المجموعة ذات الجرعة المنخفضة هي 3.2، وللمشتركين من المجموعة ذات الجرعة المرتفعة هي 5.0 ويتطلب مجموع المربعات للنموذج حساب الفروق بين القيمة المتوقعة لكل مشترك وقيمة المتوسط الكلي. يتم تربيع هذه الفروق وجمعها معاً. نعلم أن القيمة المتوقعة للمشتركين في مجموعة معينة هي قيمة المتوسط لتلك المجموعة. ولذلك فإن أسهل طريقة لحساب مجموع المربعات للنموذج (SS_M) هي:

1. حساب الفرق بين المتوسط لكل مجموعة والمتوسط الكلي.
2. تربيع هذه الفروق .
3. ضرب كل قيمة ناتجة بعدد المشتركين في المجموعة المعينة (n_k) .
4. جمع القيم الناتجة معاً.

ونعبر بشكل رياضي عن هذه العملية بالمعادلة (5.8):

$$SS_M = \sum n_k.(\overline{X}_k - \overline{X}_{grand})^2 \qquad (5.8)$$

وباستخدام المتوسطات من بيانات Viagra يمكننا حساب (SS_M) كما يلي:

$$SS_M = 5(2.200-3.467)^2+5(3.200-3.467)^2+5(5.000-3.467)^2 = 20.135$$

من أجل (SS_M) فإن عدد درجات الحرية (df_M) سيبقى دائماً أقل بواحد من عدد البارامترات المقدرة. أي أن هذه القيمة ستكون عدد المجموعات -1 (والذي يتم التعبير عنه بالشكل k-1). لذلك فإنه في تجربة ذات ثلاث مجموعات يكون عدد درجات الحرية 2 دائماً (بما أن حساب مجموع المربعات يعتمد على متوسطات المجموعات، فإن 2 يتمتعان بحرية التغير في المجتمع بينما يبقى الثالث ثابتاً).

6.2.8 مجموع مربعات البواقي SS_R

نعلم أن هناك 43.74 وحدة من التغاير في البيانات التي يجب تفسيرها، وأن النموذج قد برر 20.135 من هذه الوحدات. إن مجموع المربعات الأخير هو مجموع مربعات البواقي (SS_R) والذي يدلنا على مقدار التغاير الذي لا يمكن للنموذج تفسيره. وهذه القيمة هي مقدار التغاير الناتج عن العوامل الخارجية كالفروق الشخصية في الوزن، التستترون وغيرها. بمعرفة SS_T و SS_M فإن الطريقة الأبسط لحساب SS_R هي طرح SS_M من SS_T أي: ($SS_R=SS_T-SS_M$) ولكن تنفيذ هذه العملية بهذا

الشكل يعتمد على صحة حساب تلك القيم، فإذا كانت قيمة SS_T أو SS_M (أوكلتاهما) غير صحيحة فإن SS_R ستكون غير صحيحة أيضاً. وقد رأينا في الفقرة 3.2.5 أن مجموع مربعات البواقي هو الفرق بين ما يتوقعه النموذج وما تتم مراقبته فعلياً. ونعلم أنه من أجل مشترك معين، فإن النموذج يتوقع قيمة المتوسط للمجموعة التي ينتمي إليها المشترك. ولذلك يتم حساب SS_R بالنظر إلى الفرق بين العلامة التي يحصل عليها الشخص والمتوسط للمجموعة التي ينتمي إليها. وبشكل بياني فإن الخطوط الشاقولية في المخطط 1.8 تمثل مجموع المربعات هذا. يتم تربيع المسافات بين كل نقطة بيانات ومتوسط المجموعة وجمعها معاً للحصول على مجموع مربعات البواقي SS_R (انظر المعادلة (6.8)):

$$SS_R = \sum(x_{ik} - \bar{x}_k)^2 \qquad (6.8)$$

إن مجموع المربعات لكل مجموعة يمثل مجموع الفروق المربعة بين علامة كل مشترك في المجموعة ومتوسط المجموعة. ولذلك يمكننا التعبير عن SS_R بالشكل:...+ $SS_R=SS_{group1}+SS_{group2}$ وبما أننا نعلم العلاقة بين التباين ومجموع المربعات، فإنه يمكننا استخدام التباينات لكل مجموعة في المثال Viagra لإنشاء معادلة شبيهة بما فعلناه من أجل المجموع الكلي للمربعات. وهكذا يتم التعبير عن SS_R بالمعادلة (7.8):

$$SS_R = \sum s_k^2(n_k - 1) \qquad (7.8)$$

وهذا يعني أننا نأخذ التباين لكل مجموعة s_k^2 ونضربه بحاصل طرح العدد 1 من عدد المشتركين في تلك المجموعة (n_k-1). وعند الانتهاء من تنفيذ ذلك لكل مجموعة، نقوم بجمع القيم الناتجة. ومن أجل المثال Viagra يكون لدينا:

$$SS_R = s^2_{group1}(n1-1)+ s^2_{group2}(n2-1)+ s^2_{group3}(n3-1)$$
$$= 1.70(5-1)+1.70(5-1)+1.70(5-1)$$
$$= 32.60$$

إن عدد درجات الحرية لمجموع مربعات البواقي (df_R) هو حاصل طرح عدد درجات الحرية للنموذج من العدد الكلي لدرجات الحرية ($df_R=df_T - df_M=14-2=12$). أو بطريقة أخرى (N-k) حيث N حجم العينة وk عدد المجموعات.

7.2.8 متوسط المربعات

يدل SS_M على مقدار التغاير الذي يبرره نموذج التراجع، ويدل SS_R على مقدار التغاير العائد لأسباب خارجية. ولكن بما أن هاتين القيمتين هي قيم ناتجة عن عمليات الجمع فإنها تتأثر بعدد العلامات التي يتم جمعها (يستخدم SS_M مجموع ثلاث قيم مختلفة هي متوسطات المجموعات، بينما يستخدم كل من SS_R وSS_T مجموع 14 قيمة مختلفة). ولإلغاء هذا التأثير نستطيع حساب المجموع

المتوسط للمربعات (والمعروف باسم متوسط المربعات MS (Mean Squares)) وهو ببساطة مجموع المربعات مقسوماً على عدد درجات الحرية. والسبب وراء التقسيم على عدد درجات الحرية بدلاً من عدد البارامترات المستخدمة لحساب مجموع المربعات هو أننا نحاول القيام بعملية استيفاء خارجي للمجتمع، ولذلك يجب المحافظة على بعض البارامترات ضمن ذلك المجتمع ثابتة. من أجل المثال Viagra نحصل على متوسطات المربعات التالية:

$$MS_M = \frac{SS_M}{df_M} = \frac{20.135}{2} = 10.067$$

$$MS_R = \frac{SS_R}{df_R} = \frac{23.60}{12} = 1.967$$

يمثل MS_M المقدار الوسطي للتغاير الذي يبرره النموذج (أي التغاير المنهجي) بينما يمثل MS_R المقدار الوسطي للتغاير الذي تبرره المتحولات الخارجية (أي التغاير اللامنهجي).

8.2.8 النسبة F

النسبة F هي مقياس لنسبة التغاير الذي يبرره النموذج إلى التغاير التي تبرره العوامل اللامنهجية. ويمكن حسابها بتقسيم متوسط المربعات للنموذج على متوسط المربعات للبواقي:

$$F = \frac{MS_M}{MS_R} \qquad (8.8)$$

وكما في حالة اختبار t المستقل، فإن النسبة F هي مقياس لنسبة التغاير المنهجي إلى التغاير اللامنهجي. وهي إذاً نسبة الأثر التجريبي إلى الفروق الشخصية في الأداء. وهناك نقطة مثيرة حول النسبة F هي أنه طالما أنها نسبة التغاير المنهجي إلى التغاير اللامنهجي، فإذا كانت قيمتها أقل من 1 فهذا يعني بالتعريف أنها تمثل أثراً غير مهم. والتعليل لصحة هذه العبارة هو أنه عندما تكون النسبة F أقل من 1 فهذا يعني أن MS_R أكبر من MS_M مما يدل عملياً على وجود تباين لامنهجي أكثر من التباين المنهجي. يمكنك التفكير بذلك من حيث أن أثر الفروق الطبيعية على المقدرة أكبر من الفروق الناتجة عن التجربة. وفي هذا السيناريو يمكنك أن تكون متأكداً من أن التلاعب التجريبي لم يكن ناجحاً (لأنه أعطى تغييراً أقل مما لو تركنا المشتركين دون تأثير). ومن أجل المثال Viagra فإن:

$$F = \frac{MS_M}{MS_R} = \frac{10.067}{1.967} = 5.12$$

إن هذه القيمة أكبر من 1 مما يدل على أنه كان للتلاعب التجريبي بعض الأثر الذي يتعدى الفروق الشخصية في الأداء. على كل حال، لا يدلنا ذلك على أن النسبة F كبيرة لحد لا يمكن اعتبارها نتيجة الصدفة. ولاكتشاف ذلك يمكننا مقارنة قيمة F التي حصلنا عليها مع القيمة العظمى التي نتوقع الحصول عليها بمحض الصدفة في توزيع F من أجل نفس عدد درجات الحرية (ويمكن إيجاد

هذه القيمة في الملحق A3)، إذا كانت القيمة التي حصلنا عليها أكبر من هذه القيمة الحرجة فإننا نكون على ثقة بأن ذلك يعكس أثراً للمتحول المستقل. في هذه الحالة، من أجل قيم درجات الحرية $df_M=2$ و $df_R=12$ فإن القيم الحرجة هي 3.89(p=0.05) و 6.93(p=0.01). إن القيمة المشاهدة F=5.12 هي ذات دلالة عند المستوى 0.05 ولكنها ليست كذلك عند المستوى 0.01 من الدلالة. إن القيمة الدقيقة للدلالة التي يعطيها برنامج SPSS ستقع إذاً بين 0.01 و 0.05 (وهذا ما يحدث فعلاً).

9.2.8 فرضيات ANOVA

إن الفرضيات التي تكون معها تقنية ANOVA موثوقة هي نفس الفرضيات لجميع الاختبارات البارامترية المستندة إلى التوزيع الطبيعي (انظر الفقرة 2.3). يجب أن تكون البيانات قادمة من مجتمع ذي توزيع طبيعي، وأن تكون التباينات في كل حالة تجريبية متشابهة تقريباً، وأن تكون المشاهدات مستقلة، كما يمكن قياس المتحول التابع على مستوى المجال على الأقل. ومع أننا نركّز دوماً على أهمية الفرضيات، فهي ليست غير مرنة تماماً. فعلى سبيل المثال تحقق Lunney (1970) من استخدام ANOVA عندما يكون المتحول التابع ثنائياً (يأخذ القيم 0 و 1 فقط). وقد أظهرت النتائج أنه عندما تكون أحجام المجموعات متساوية فإن ANOVA تكون دقيقة عند وجود 20 درجة حرية على الأقل. وإذا كانت فئة الاستجابة الأصغر تحوي أقل من 20% من جميع الإجابات فإن أداء ANOVA يكون دقيقاً فقط عند وجود 40 درجة حرية أو أكثر. وأظهرت هذه الدراسة أن ANOVA يمكن أن تكون إجرائية قوية متماسكة.

عند عدم تحقق فرضية تجانس التباين، فإن ANOVA تكون متماسكة عندما تكون أحجام العينات متساوية. أما عندما تكون أحجام العينات غير متساوية فإن ANOVA ليست مقاومة لخرق فرضية تجانس التباين (ولهذا السبب قلنا سابقاً أنه يجب أن نحاول جمع عينات متساوية الحجم للبيانات في الحالات التجريبية المختلفة). عندما تكون المجموعات كبيرة الحجم ذات تباينات أكبر من المجموعات صغيرة الحجم فإن نسبة F الناتجة تميل للصرامة. أي أنها تحاول إعطاء نتائج غير ذات دلالة عند وجود فرق حقيقي في المجتمع. وبالعكس عندما تملك المجموعات كبيرة الحجم تباينات أصغر من المجموعات صغيرة الحجم فإن النسبة F تميل للتسامح. أي أنها تحاول إعطاء نتائج ذات دلالة عندما لا يكون هناك فرق بين المجموعات في المجتمع (أي أنه لا يمكن التحكم بمعدل الخطأ من النوع الأول).

يمكن تصحيح المشاكل التي تنتج عن عدم احترام فرضية تجانس التباين (انظر المربع 3.8) ولذلك فإن المشكلة الأكثر جدية هي خرق فرضية الاستقلال. وقد أظهر Scariano & Davenport أنه عند خرق هذه الفرضية (هناك ارتباط بين المشاهدات عبر المجموعات) فإن معدل الخطأ من النوع الأول يكون متضخماً جداً. فعلى سبيل المثال، باستخدام معدل الخطأ من النوع الأول 0.05، وعندما

تكون المشاهدات مستقلة، إذا ارتبطت هذه المشاهدات بشكل معتدل (مع قيمة معامل Pearson 0.5 مثلاً)، وعند مقارنة 3 مجموعات تحوي كل منها 10 مشاهدات، فإن معدل الخطأ من النوع الأول الفعلي هو 0.74 (تضخم كبير). ولذلك إذا كانت المشاهدات مرتبطة فإنك قد تعتقد أنك تعمل بمعدل خطأ مقبول 0.05 بينما معدل الخطأ قريب من 0.74 عملياً.

10.2.8 أنواع المقارنات المنظمة

تخبرنا النسبة F عما إذا النموذج الموافق للبيانات يساهم بتغاير أكبر من العوامل الخارجية، ولكنها لا تدلنا على مواقع الفروق بين المجموعات. لذلك إذا كانت النسبة F كبيرة لتكون ذات دلالة إحصائية فإننا نعلم فقط أن واحداً من الفروق بين المتوسطات أو أكثر هو ذو دلالة إحصائية (إما b_2 أو b_1 هو ذو دلالة إحصائية). ولذلك فمن الضروري بعد تنفيذ تحليل التباين ANOVA القيام بمزيد من عمليات التحليل لإيجاد المجموعات المختلفة. في التراجع المتعدد، يتم اختبار كل معامل b بشكل منفصل باستخدام اختبار t ANOVA. على كل حال، فإننا نحتاج لتنفيذ اختبارَي t مما يضخم معدل الخطأ حسب العائلة (انظر الفقرة 1.2.8). ولذلك فإننا بحاجة لطريقة لمقارنة المجموعات المختلفة دون تضخيم معدل الخطأ من النوع الأول. وهناك طريقتان لتحقيق هذا الهدف. تتمثل الأولى بفصل التباين الناتج عن النموذج إلى أجزائه المكونة، أما الطريقة الثانية فتتمثل بمقارنة كل المجموعات (كما لو كنا نقوم بعدة اختبارات t) ولكن باستخدام معيار قبول أكثر صرامة كأن لا يتجاوز معدل الخطأ حسب العائلة القيمة 0.05. يمكن تنفيذ الخيار الأول باستخدام المقارنات المنظمة (Planned Contrasts) بينما يتم تنفيذ الخيار الثاني باستخدام المقارنات post hoc (انظر الفقرة التالية). ويمكن تشبيه الفرق بين المقارنات المنظمة واختبارات post hoc بالفرق بين الاختبار وحيد الطرف والاختبار ثنائي الطرف حيث يتم تنفيذ المقارنات المنظمة عند وجود فرضيات معينة نرغب باختبارها، أما الاختبارات post hoc فيتم تنفيذها عند عدم وجود فرضيات معينة. لنلق في البداية نظرة على أنواع المقارنة المنظمة.

1.10.2.8 اختيار المقارنة التي نريد تنفيذها

في المثال Viagra كانت لدينا فرضيات محددة جداً. فقد توقعنا أن تناول أي جرعة من Viagra سيغير الشهوة مقارنة بمجموعة الدواء التمويهي. وكفرضية ثانية يمكن أن نعتقد أن الجرعة المرتفعة من Viagra ستزيد الشهوة أكثر من الجرعة المنخفضة. ولإجراء المقارنات المنظمة، يجب اشتقاق هذه الفرضيات قبل البدء بجمع البيانات. ومن الشائع قياسياً في العلوم الاجتماعية أننا نريد مقارنة الحالات التجريبية مع حالات المراقبة كمقارنة أولى، ثم البحث عن موقع الفرق بين المجموعات التجريبية. وتعتمد ANOVA على تقسيم التغاير الكلي إلى مكونين اثنين: التغاير الناتج عن التلاعب التجريبي (SS_M) والتلاعب الناتج عن العوامل اللامنهجية (SS_R) (انظر الشكل 2.8). وتقود

المقارنات المنظمة هذا المنطق خطوة أخرى إلى الأمام وذلك بتقسيم التغاير الناتج عن التجربة إلى أجزائه المكونة (انظر الشكل 3.8). وتعتمد عمليات المقارنة الدقيقة التي يتم تنفيذها على الفرضيات التي نريد اختبارها.

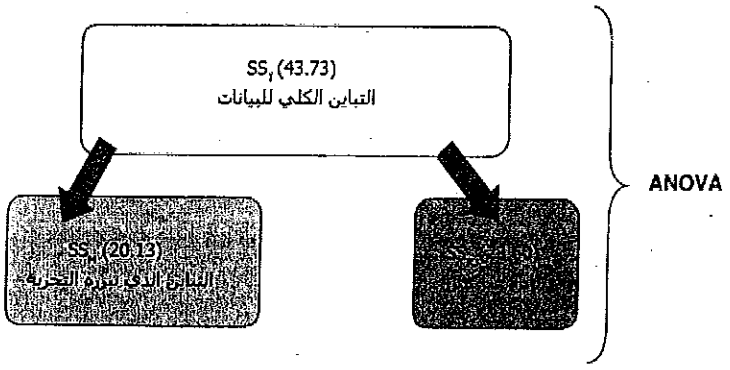

الشكل 2.8 تقسيم التباين من أجل ANOVA

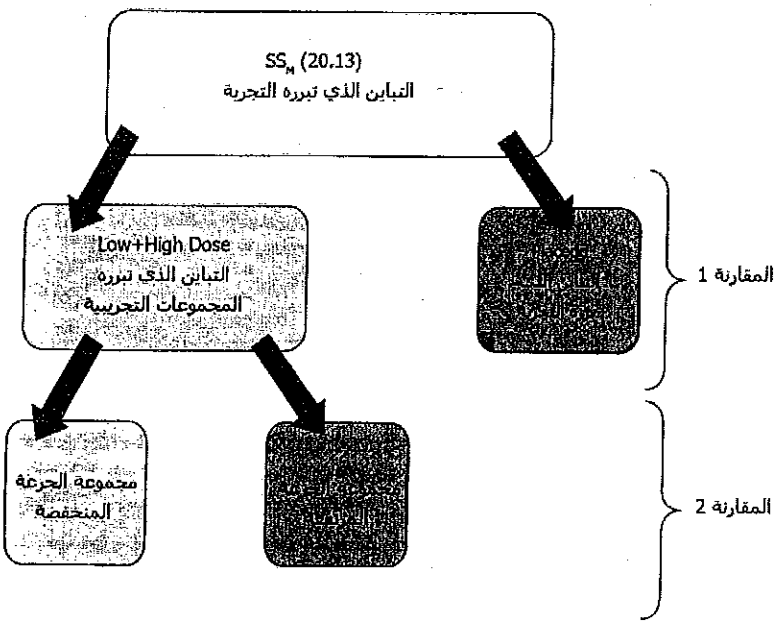

الشكل 3.8 تقسيم التباين الناتج عن التجربة إلى مقارناته المكونة

يبين الشكل 3.8 الوضعية التي تم فيها تقسيم التباين الناتج عن التجربة لمعرفة مقدار التغاير الناتج عن حالتي جرعة Viagra مقارنة بحالة الدواء التمويهي (المقارنة 1). ثم تقسيم التباين الذي يبرره تناول جرعة Viagra لمعرفة المقدار الذي تبرره الجرعة المرتفعة بالنسبة للجرعة المنخفضة (المقارنة 2).

وهناك عدة قواعد للتعرف على مفهوم المقارنات المنظمة والتعامل معه. إن أهم شيء يجب أن نتذكره أننا نقسم مقداراً كبيراً من التغاير إلى مقادير مستقلة أصغر. وهذا يعني عدة أمور، أولاً: إذا ظهرت مجموعة ما في مقارنة معينة فيجب ألا تظهر في أية مقارنة أخرى. لذلك نرى في الشكل 3.8 أن المقارنة الأولى تتضمن مقارنة مجموعة الدواء التمويهي مع المجموعات التجريبية وبما أن مجموعة الدواء التمويهي قد ظهرت هنا فيجب ألا تظهر في أية مقارنة لاحقة. يمكن تشبيه عملية تقسيم التباين بتقسيم قالب الكاتو. تبدأ مع قالب الكاتو (المجموع الكلي للمربعات SS_T) ثم تقسمه إلى قطعتين (SS_M و SS_R). تم تأخذ القطعة التي تمثل SS_M وتقسمها إلى قطع أصغر. عندما تقسم قطعة الكاتو لا يمكنك إعادة لصقها بالقطعة الأصلية، كما لا يمكنك لصقها بالقطع الأخرى، وكل ما يمكنك عمله هو تقسيمها إلى قطع أصغر. وبشكل مشابه، عند فصل جزء من التباين من جزء أكبر فإنه لا يمكنك وصله بأي جزء آخر من التباين، وكل ما يمكنك عمله هو تقسيمه إلى أجزاء أصغر فقط. والأمر الثاني الذي يجب اعتباره عند اختيار المقارنات هو أن قاعدة استقلال التباينات (تقسيم قالب الكاتو) تعني أن عدد المقارنات أقل بعدد واحد من عدد المجموعات، فإذا كان عدد المجموعات التي نقوم بمقارنتها هو k فإن عدد المقارنات يكون k-1. وأخيراً فإن كل مقارنة يجب أن تقارن قسمين فقط من التباين. أما القاعدة الأخيرة فتنص على ضرورة الوصول إلى استنتاجات حازمة من كل مقارنة نقوم بها. تدلنا النسبة F على أن بعض القيم المتوسطة مختلفة ولكنها لا تقوم بتحديدها. وإذا قمنا بمقارنة أكثر من قسمين من التباين فإننا سنقع في نفس المشكلة. أما عند مقارنة قسمين فقط من التباين فإننا نكون متأكدين أن نتيجة مهمة تمثل فرقاً بين هذين القسمين من التغاير الناتج عن التجربة.

في معظم أبحاث العلوم الاجتماعية، يتم استخدام حالة مراقبة واحدة على الأقل، وفي غالبية التجارب فإننا نتوقع أن تختلف الحالات التجريبية عن حالة (أو حالات) المراقبة. ولذلك تكون النصيحة الهامة التالية مفيدة جداً: عند استخدام المقارنات المنظمة يجب أن تتم أولاً مقارنة جميع المجموعات التجريبية مع مجموعة (أو مجموعات) المراقبة. بعد الانتهاء من هذه المقارنة الأولى، فإن بقية المقارنات ستعتمد على تحديد المجموعة التجريبية المختلفة عن المجموعات الأخرى.

لتوضيح هذه المبادئ، تبين الأشكال 4.8 و 5.8 المقارنات التي يمكن تنفيذها في تجربة تضم 4 مجموعات. وأول ما يجب ملاحظته في كلا السيناريوهين وجود 3 مقارنات ممكنة (3=1-4). كما أن كل مقارنة تقارن قسمين فقط من التباين. وأكثر من ذلك، المقارنة الأولى في كلا السيناريوهين هي ذاتها وتشمل مقارنة المجموعات التجريبية مع مجموعة المراقبة. في الشكل 4.8 هناك مجموعة مراقبة واحدة فقط ولذلك فإن هذا القسم من التباين قد تم استخدامه في المقارنة الأولى فقط (لأنه لا يمكن تقسيمه مرة أخرى). أما في الشكل 5.8 فهناك مجموعتي مراقبة، ولذلك فإن الجزء من التباين الناتج عن حالات المراقبة (المقارنة 1) يمكن تقسيمه مرة أخرى لمعرفة فيما إذا كانت العلامات في مجموعات المراقبة ستختلف عن بعضها أم لا (المقارنة 3).

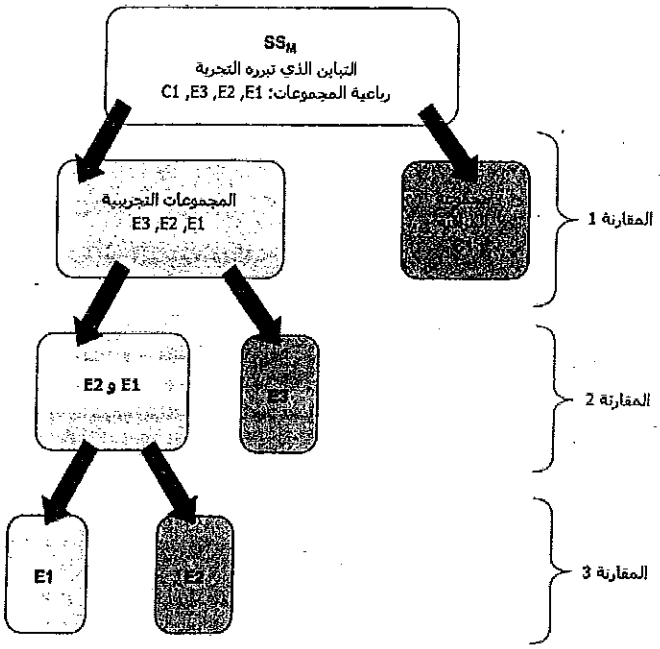

الشكل 4.8 تقسيم التباين في المقارنات المنظمة في تجربة ذات 4 مجموعات وباستخدام مجموعة مراقبة واحدة فقط

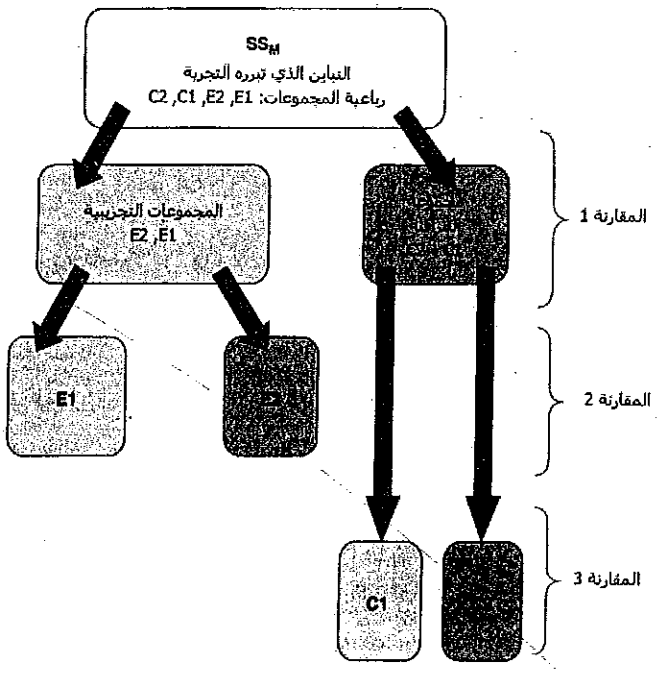

الشكل 5.8 تقسيم التباين في المقارنات المنظمة في تجربة ذات 4 مجموعات وباستخدام مجموعتي مراقبة

في الشكل 4.8، تحوي المقارنة الأولى قسماً من التباين يعود للمجموعات التجريبية الثلاث، وقد تم تقسيم هذا القسم بناء على اختلاف المجموعتين E1 وE2 عن المجموعة E3 (المقارنة 2). يمكنك أيضاً استخدام المقارنة الثانية لمقارنة المجموعتين E1 وE3 مع المجموعة E2، أو لمقارنة المجموعتين E2 وE3 مع المجموعةE1 وتعتمد المقارنة الدقيقة التي تختارها على الفرضيات المستخدمة. ولكي تكون المقارنة الثانية في الشكل 4.8 صحيحة يجب أن يكون لدينا سبب وجيه للاعتقاد بأن المجموعة E3 مختلفة عن المجموعتين E1 و E2. أما المقارنة الثالثة في الشكل 4.8 فتعتمد على المقارنة التي تم اختيارها من أجل المقارنة الثانية. تتضمن المقارنة الثانية بشكل إجباري مقارنة مجموعتين تجريبيتين مع مجموعة ثالثة، ويتم في المقارنة الأخيرة فصل هاتين المجموعتين ومقارنتهما مع بعضهما البعض. النقطة الأخيرة التي يجب ملاحظتها في الأشكال 4.8 و5.8 هي أنه عند الانتهاء من مقارنة مجموعة ما فإنها لا تظهر مرة أخرى في أية مقارنة لاحقة.

عند تنفيذ المقارنات المنظمة فإننا نقوم بمقارنة أجزاء من التباين، وغالباً ما تتألف هذه الأجزاء من عدة مجموعات. وقد نرتبك في فهم النتائج التي تعطيها هذه المقارنات. حسناً، عند تصميم مقارنة ما لمقارنة عدة مجموعات مع مجموعة أخرى فإننا نقارن المتوسط لهذه المجموعات من جهة مع قيمة المتوسط للمجموعة الوحيدة من الجهة الأخرى. ففي المثال Viagra وجدنا أنه من المناسب إجراء المقارنة الأولى بين مجموعتي جرعة Viagra من جهة مع مجموعة الدواء التمويهي من الجهة الأخرى. وتبلغ قيمة المتوسط لكل من المجموعات الثلاث كالتالي: 2.20 لمجموعة الدواء التمويهي و3.20 لمجموعة الجرعة المنخفضة و5.00 لمجموعة الجرعة المرتفعة، ولذلك فإن المقارنة الأولى كانت بين 2.20 (مجموعة الدواء التمويهي) والقيمة (4.10=2/(3.2+5.0)) (المتوسط لمجموعتي جرعة Viagra). إذا كانت نتيجة المقارنة ذات دلالة فإنه يمكننا أن نستنتج أن القيمة 4.10 هي أكبر من 2.20. وهذا يعني بالمفهوم التجريبي أن المتوسط للمجموعات التجريبية مختلف بشكل كبير عن المتوسط لمجموعة المراقبة. وربما علمت أن ذلك يعني منطقياً أنه إذا كانت الأخطاء المعيارية هي ذاتها فإن المجموعة التجريبية ذات المتوسط الأعلى (مجموعة الجرعة المرتفعة) ستكون مختلفة بشكل كبير عن مجموعة الدواء التمويهي. على كل حال، قد لا تكون المجموعة التجريبية ذات المتوسط الأدنى (مجموعة الجرعة المنخفضة) مختلفة بالضرورة عن مجموعة الدواء التمويهي، ولذلك علينا استخدام المقارنة الأخيرة لإعطاء معنى للحالات التجريبية. ففي المثال Viagra تبحث المقارنة الأخيرة عن وجود فرق بين الحالتين التجريبيتين (هل قيمة المتوسط لمجموعة الجرعة المرتفعة مختلف بشكل كبير عن قيمة المتوسط لمجموعة الجرعة المنخفضة؟). إذا كانت نتيجة هذه المقارنة ذات دلالة فإنه يمكننا أن نستنتج أن تناول جرعة أكبر من Viagra سيؤثر بشكل كبير على الشهوة مقارنة بتناول جرعة منخفضة. أما إذا كانت المقارنة بدون دلالة فإننا نستنتج أن مقدار جرعة Viagra لا يعطي فرقاً في تأثيره على الشهوة. وفي السيناريو الأخير فإن جرعتي Viagra تؤثران على الشهوة أكثر من الدواء التمويهي، بينما تقتضي الحالة السابقة أن تناول جرعة منخفضة قد لا يكون مختلفاً عن تناول الدواء التمويهي. وكلمة "تقتضي" هامة هنا، فمن المحتمل أن لا تكون مجموعة الجرعة المنخفضة مختلفة عن مجموعة الدواء التمويهي. وللتأكد بشكل كامل من هذه النتيجة علينا تنفيذ الاختبارات post hoc.

2.10.2.8 تحديد المقارنة باستخدام التثقيل

نأمل أن تكون قد تشكلت لديك فكرة عن التخطيط للمقارنات التي تريد تنفيذها. ومع أنني أحب أن أخبرك بأن العمل الصعب قد انتهى أو أن برنامج SPSS سيتولى تنفيذ المقارنات التي اخترتها فإن ذلك لن يحصل. إذ يجب عليك تحديد المجموعات التي تريد مقارنتها، وتنفيذ ذلك قد يكون معقداً جداً. عند تنفيذ المقارنات فإننا نعين قيماً لبعض المتحولات في نموذج التراجع كما فعلنا عند استخدام الترميز المزيف من أجل تحليل التباين الأساسي. لتنفيذ المقارنات نقوم ببساطة بتعيين بعض القيم للمتحولات المزيفة في نموذج التراجع. قمنا سابقاً بتعريف المجموعات التجريبية بإعطاء المتحولات المزيفة القيم 1 أو 0، وعندما نقوم بتنفيذ المقارنات فإننا نستخدم قيماً مختلفة لتحديد المجموعات التي نريد مقارنتها. وتمثل المعاملات الناتجة في نموذج التراجع (b_1 وb_2) المقارنات التي نهتم بها. وتُعرف القيم المعينة للمتحولات المزيفة بالأثقال (Weights).

وهذه الإجرائية مربكة بشكل كبير، ولكن هناك عدد من القواعد الأساسية لتعيين القيم للمتحولات المزيفة للحصول على المقارنات المطلوبة. وسنشرح هذه القواعد البسيطة قبل عرض آلية عمل هذه العملية. تذكّر الفقرة السابقة وذكّر نفسك بما قلناه عن أجزاء التباين.

- **القاعدة 1:** اختر مقارنات حساسة. تذكر أنك تريد مقارنة قسمين فقط من التباين وأنه إذا ذكرت مجموعة ما في مقارنة معينة فيجب عليك استثناء تلك المجموعة من المقارنات اللاحقة.
- **القاعدة 2:** ستتم مقارنة المجموعات المرمّزة بأثقال موجبة مع المجموعات المرمّزة بأثقال سالبة. لذلك ينبغي عليك تعيين أثقال موجبة لجزء من التغاير، وأثقال سالبة للأجزاء المقابلة.
- **القاعدة 3:** إن مجموع الأثقال في مقارنة ما يساوي الصفر.
- **القاعدة 4:** إذا لم تكن مجموعة ما متضمنة في مقارنة معينة فحدد قيمة الثقل 0 لهذه المجموعة. إذا أعطينا الثقل 0 لمجموعة ما فإن ذلك يحذفها من جميع الحسابات.
- **القاعدة 5:** من أجل مقارنة معينة فإن الأثقال الممنوحة للمجموعة (أو المجموعات) في قسم من التباين يجب أن تكون مساوية لعدد المجموعات في القسم المقابل من التباين.

لنتبع بعض هذه القواعد من أجل اشتقاق قيم الأثقال في المثال Viagra. لقد اخترنا المقارنة الأولى لمقارنة المجموعتين التجريبيتين من جهة مع مجموعة المراقبة من الجهة الأخرى:

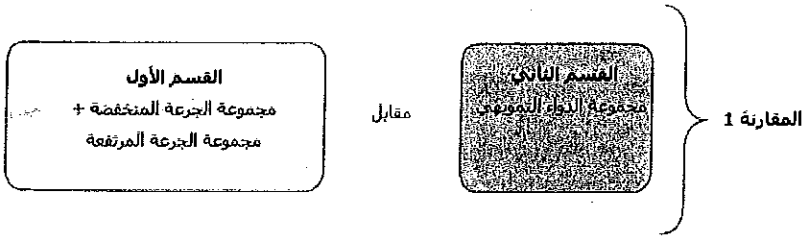

لذلك فإن القسم الأول يحوي المجموعتين التجريبيتين بينما يحوي القسم الثاني مجموعة الدواء التمويهي فقط. تنص القاعدة 2 على تعيين أثقال موجبة لقسم معين وأثقال سالبة للقسم الآخر. ولا تهم الطريقة المتبعة لتنفيذ ذلك، ولكننا نفضل أن نعطي القسم الأول أثقالاً موجبة، والقسم الثاني أثقالاً سالبة:

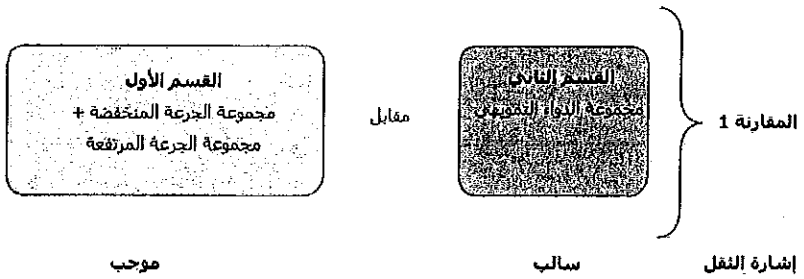

وباستخدام القاعدة 5، فإن الثقل الذي علينا تعيينه للمجموعات في القسم الأول يجب أن يكون مكافئاً لعدد المجموعات في القسم الثاني. هناك مجموعة واحدة فقط في القسم الثاني ولذلك نمنح كل مجموعة في القسم الأول الثقل 1. وبشكل مشابه نمنح المجموعة الموجودة في القسم الثاني ثقلاً يساوي عدد المجموعات في القسم الأول. وبما أن القسم الأول يحوي مجموعتين فإننا نمنح المجموعة في القسم الثاني الثقل 2. نعطي بعد ذلك إشارة الثقل للقيمة الممنوحة فنحصل على الثقل 2- لمجموعة الدواء التمويهي، و1 لمجموعة الجرعة المنخفضة و1 لمجموعة الجرعة المرتفعة.

تنص القاعدة 3 على أنه من أجل مقارنة معينة فإن مجموع الأثقال يجب أن يساوي 0، وبإتباع القاعدتين 2 و5 فإن القاعدة 3 تكون محققة دائماً (إذا لم تتبع القواعد 2 و5 بشكل صحيح فإن ذلك يصبح واضحاً عند تطبيق القاعدة 3). وللتحقق من القاعدة 3 نقوم بجمع الأثقال فنجد :1+1-2=0

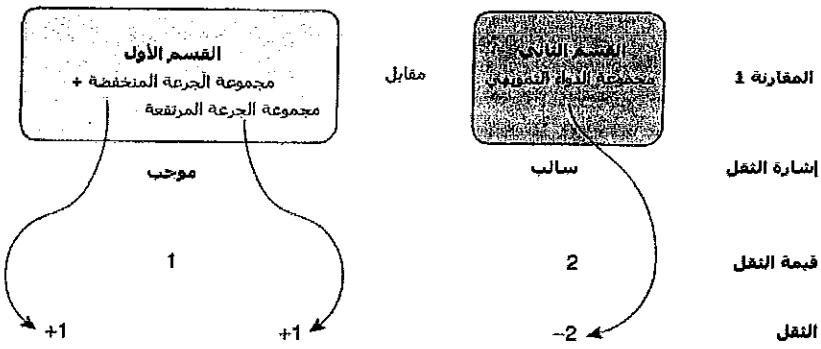

في المقارنة الثانية قمنا بمقارنة المجموعتين التجريبيتين ولذلك علينا إهمال مجموعة الدواء التمويهي. تنص القاعدة 4 على تعيين القيمة 0 للثقل الممنوح لهذه المجموعة (ولذلك يتم حذف هذه المجموعة من

الحسابات). لدينا الآن قسمان من التغاير: القسم الأول الذي يحوي مجموعة الجرعة المرتفعة، والقسم الثاني الذي يحوي مجموعة الجرعة المنخفضة. بإتباع القاعدتين 2 و5 يجب أن يكون بديهياً أن تأخذ إحدى المجموعتان الثقل 1+ بينما تأخذ المجموعة الأخرى الثقل 1- ولإهمال مجموعة المراقبة يتم منحها الثقل 0. إذا جمعنا الأثقال للمقارنة فإننا نحصل على 0=0+1-1:

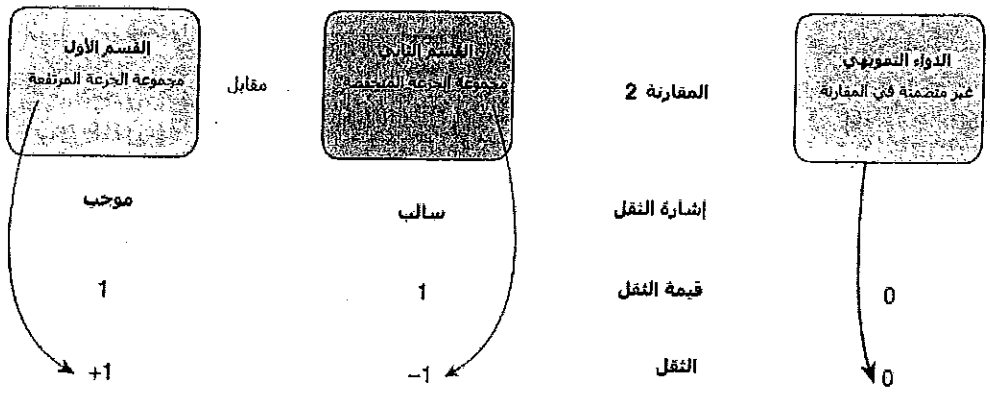

يتم ترميز الأثقال لكل مقارنة من أجل المتحولين المزيفين في المعادلة (2.8). ونظراً لإمكانية استخدام هذا الترميز في نموذج التراجع المتعدد حيث يمثل b_2 المقارنة الأولى (مقارنة المجموعتين التجريبيتين مع مجموعة المراقبة) ويمثل b_1 المقارنة الثانية (مقارنة مجموعة الجرعة المرتفعة مع مجموعة الجرعة المنخفضة) ويمثل b_0 المتوسط الكلي (انظر المعادلة 9.8):

$$Libido_i = b_0 + b_1Contrast_1 + b_2Contrast_2 \qquad (9.8)$$

لم تعد المجموعات محددة الآن بمخطط الترميز 0 و1 الذي استخدمناه في البداية، وإنما باستخدام مخطط الترميز للمقارنتين. يحدد الرمز 2- للمقارنة الأولى والرمز 0 للمقارنة الثانية المشاركين في مجموعة الدواء التمويهي. وبشكل مشابه، يتم التعرف على مجموعة الجرعة المرتفعة من الرمز 1 لكلا المتحولين، أما مجموعة الجرعة المنخفضة فتأخذ الرمز 1 للمقارنة الأولى والرمز 1- للمقارنة الثانية (انظر الجدول 4.8).

المجموعة	المتحول المزيف الأول (Contrast1)	المتحول المزيف الثاني (Contrast2)	الجداء (Contrast1×Contrast2)
الدواء التمويهي	-2	0	0
الجرعة المنخفضة	1	-1	-1
الجرعة المرتفعة	1	1	1
الكلي	0	0	0

الجدول 4.8 المقارنات المتعامدة لبيانات المثال Viagra

من المهم أن يكون مجموع الأثقال لمقارنة معينة مساوياً 0 لأنه يضمن مقارنة قسمين فقط من التغاير. ولذلك يمكن لبرنامج SPSS تنفيذ اختبار t. وهناك اعتبار مهم آخر وهو أن جداء الأثقال لمجموعة معينة وجمع هذه الجداءات معاً يعطي القيمة 0 أيضاً (العمود الأخير في الجدول 4.8). إذا كان مجموع الجداءات مساوياً للصفر فإننا نتأكد من أن المقارنات مستقلة أو متعامدة (Orthogonal). وهذا ضروري جداً عند إعطاء التفسير. عندما استخدمنا ترميز المتحولات المزيفة ونفذنا التراجع على بيانات Viagra، أعطينا تعليقاً بأنه لا يمكننا النظر إلى اختبارات t المنفصلة المنفذة على معاملات التراجع لأن معدل الخطأ حسب العائلة يكون مضخماً (انظر الفقرة 10.2.8 والخرج 1.8). إذا كانت المقارنات مستقلة فإن اختبارات t المنفذة على المعاملات b هي مستقلة أيضاً ولذلك فإن قيم p الناتجة هي غير مرتبطة. قد تعتقد بأنه من الصعب جداً التأكد من أن الأثقال المختارة للمقارنات تحقق متطلبات الاستقلال، ولكن إتباع القواعد التي ذكرناها سابقاً يسمح لك دائماً باشتقاق مجموعة من المقارنات المتعامدة. ويجب أن تتحقق من ذلك بشكل مضاعف وذلك بالنظر إلى مجموع جداءات الأثقال فإذا كان هذا المجموع غير مساوي للصفر فعليك العودة إلى القواعد واكتشاف الأخطاء المرتكبة (انظر العمود الأخير في الجدول 4.8).

لقد ذكرنا سابقاً أنه عندما نستخدم ترميز المقارنات في المتحولات المزيفة ضمن نموذج التراجع فإن قيم b تمثل الفروق بين المتوسطات التي تم تصميم المقارنات لاختبارها. وسنبين فيما يلي كيفية عمل نموذج التراجع. عند تنفيذ المقارنات المنظمة فإن الاعتراض b_0 يساوي المتوسط الكلي (أي القيمة التي يتوقعها النموذج عندما تكون عناصر المجموعة غير معروفة):

$$b_0 = \text{المتوسط الكلي} = \frac{\overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo}}{3}$$

مجموعة الدواء التمويهي: إذا استخدمنا ترميز المقارنات لمجموعة الدواء التمويهي (انظر الجدول 4.8) فإن القيمة المتوقعة للنتيجة Libido تساوي المتوسط لمجموعة الدواء التمويهي. ولذلك يمكن كتابة معادلة التراجع بالشكل التالي:

$$\text{Libido}_i = b_0 + b_1\,\text{Contrast}_1 + b_2\,\text{Contrast}_2$$

$$\overline{X}_{Placebo} = \left(\frac{\overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo}}{3}\right) + (-2b_1) + (b_2 \times 0)$$

إذا أعدنا الآن ترتيب هذه المعادلة وضربنا حدي المعادلة بالعدد 3 للتخلص من الكسور فإننا نجد:

$$2b_1 = \left(\frac{\overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo}}{3}\right) - \overline{X}_{Placebo}$$

$$6b_1 = \overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo} - 3\overline{X}_{Placebo}$$

$$6b_1 = \overline{X}_{High} + \overline{X}_{Low} - 2\overline{X}_{Placebo}$$

إذا قسمنا حدي المعادلة على العدد 2 فإننا نجد:

$$3b_1 = \left(\frac{\overline{X}_{High} + \overline{X}_{Low}}{2}\right) - \overline{X}_{Placebo}$$

تبين هذه المعادلة أن b_1 تمثل الفرق بين متوسط المجموعتين التجريبيتين من جهة ومجموعة المراقبة من جهة أخرى:

$$3b_1 = \frac{5 + 3.2}{2} - 2.2 = 1.9$$

لقد خططنا لأن تبحث المقارنة الأولى عن الفرق بين المتوسط للمجموعات التجريبية ومجموعة المراقبة ونجد الآن أن b_1 يمثل فعلاً ذلك الفرق. وربما لاحظت أنه بدلاً من الحصول على القيمة الحقيقية للفرق بين المجموعات التجريبية ومجموعة المراقبة فإن قيمة b_1 هي عملياً ثلث قيمة الفرق (b_1=1.9/3=0.633). وسبب هذه القسمة أنه يتم التحكم بالخطأ حسب العائلة عن طريق جعل معامل التراجع مساوياً للفرق الفعلي مقسوماً على عدد المجموعات المتضمنة في تلك المقارنة (وفي هذه الحالة 3).

مجموعة الجرعة المرتفعة: عند استخدام الترميز لمجموعة الجرعة المرتفعة (انظر الجدول 4.8) فإن القيمة المتوقعة للشهوة هي المتوسط لمجموعة الجرعة المرتفعة، وبذلك فإن معادلة التراجع تصبح:

$$Libido_i = b_0 + b_1\ Contrast_1 + b_2\ Contrast_2$$

$$\overline{X}_{High} = b_0 + (b_1 \times 1) + (b_2 \times 1)$$

$$b_2 = \overline{X}_{High} - b_1 - b_0$$

ونعلم ما تمثله قيم b_1 و b_0 لذلك نضع هذه القيم في المعادلة ونضرب حدي المعادلة بالعدد 3 للتخلص من الكسور فنجد:

$$b_2 = \overline{X}_{High} - \left\{\frac{1}{3}\left[\left(\frac{\overline{X}_{High} + \overline{X}_{Low}}{2}\right) - \overline{X}_{Placebo}\right]\right\} - \left(\frac{\overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo}}{3}\right)$$

$$3b_2 = 3\overline{X}_{High} - \left[\left(\frac{\overline{X}_{High} + \overline{X}_{Low}}{2}\right) - \overline{X}_{Placebo}\right] - \left(\overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo}\right)$$

إذا ضربنا طرفي المعادلة بالعدد 2 للتخلص من الكسر المتبقي ونشرنا حدود المعادلة وبسطناها فإننا نجد:

$$6b_2 = 6\overline{X}_{High} - (\overline{X}_{High} + \overline{X}_{Low} - 2\overline{X}_{Placebo}) - 2(\overline{X}_{High} + \overline{X}_{Low} + \overline{X}_{Placebo})$$

$$6b_2 = 3\overline{X}_{High} - 3\overline{X}_{Low}$$

إذا قسمنا طرفي المعادلة على العدد 6 فإننا نجد أن b_2 يمثل:

$$b_2 = \frac{1}{2}(\overline{X}_{High} - \overline{X}_{Low})$$

لقد خططنا لأن تبحث المقارنة الثانية عن الفرق بين المجموعات التجريبية:

$$\overline{X}_{High} - \overline{X}_{Low} = 5 - 3.2 = 1.8$$

وقد وجدنا أن b_2 يمثل هذا الفرق، وقيمته تساوي نصف هذا الفرق عملياً (b_2=1.8/2=0.9). ومرة أخرى تم التحكم بالخطأ حسب العائلة وذلك بجعل معامل التراجع مساوياً لحاصل قسمة الفرق على عدد المجموعات المتضمنة في المقارنة (وفي هذه الحالة 2).

لتوضيح هذه المبادئ، قمنا بإنشاء الملف Contrast.sav وتم فيه ترميز بيانات Viagra باستخدام مخطط الترميز للمقارنات المستخدم في هذه الفقرة. نقوم بتنفيذ تحليل التراجع المتعدد على هذه البيانات باستخدام المتحول Libido كنتيجة والمتحولين dummy1 وdummy2 كمتحولات تنبؤية (مع الإبقاء على جميع الخيارات الافتراضية). إن تحليل ANOVA الأساسي للنموذج هو ذاته عند استخدام الترميز المزيف ولكن معاملات التراجع قد تغيرت.

يعرض الخرج 2.8 نتيجة هذا التراجع. وأول ما يجب ملاحظته هو أن قيمة الاعتراض تساوي المتوسط الكلي 3.467. ثانياً، إن معامل التراجع للمقارنة الأولى يساوي ثلث الفرق بين المتوسط للمجموعات التجريبية من جهة ومجموعة المراقبة من جهة أخرى. وأخيراً، إن معامل التراجع للمقارنة الثانية يساوي نصف الفرق بين المجموعتين التجريبيتين. ولذلك فإنه عند تنفيذ المقارنة المنظمة في ANOVA يتم تنفيذ اختبار t لمقارنة المتوسط لقسم من التغاير مع المتوسط لقسم آخر. بالنظر لقيم الدلالة لاختبارات t يمكننا أن ندرك فيما إذا كانت المجموعات التجريبية مختلفة بشكل كبير عن مجموعة المراقبة ($p<0.05$)، أما المجموعات التجريبية فلم تكن مختلفة عن بعضها بشكل كبير ($p>0.05$).

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	2.200	.627		3.508	.004
	Dummy Variable1	2.800	.887	.773	3.157	.008
	Dummy Variable2	1.000	.887	.276	1.127	.282

a. Dependent Variable: Libido

الخرج 2.8

3.10.2.8 المقارنات غير المتعامدة

لقد تحدثنا بشكل مطوّل عن كيفية تصميم المقارنات المتعامدة المناسبة دون الإشارة للإمكانيات التي توفرها المقارنات غير المتعامدة. المقارنات غير المتعامدة (Non-orthogonal Contrasts) هي مقارنات مرتبطة بطريقة ما، وأفضل طريقة لاكتشافها هي عدم الخضوع للقاعدة 1 المذكورة في

الفقرة السابقة. باستخدام التشابه مع قالب الكاتو مرة أخرى، فإن المقارنات غير المتعامدة تحدث عندما تقطع قالب الكاتو ثم تحاول لصق القطع مع بعضها من جديد. فمن أجل المثال Viagra قد يكون لمجموعة من المقارنات غير المتعامدة نفس المقارنة البدائية (مقارنة المجموعات التجريبية من جهة مع مجموعة المراقبة من جهة أخرى)، ولكن تتم بعد ذلك مقارنة مجموعة الجرعة المنخفضة مع مجموعة الدواء التمويهي، وهذا يناقض القاعدة 1 لأن مجموعة الدواء التمويهي استخدمت في المقارنة الأولى ولكن تم استخدامها مرة أخرى في المقارنة الثانية. يبين الجدول 5.8 الترميز لهذه المجموعة من المقارنات، وبالنظر إلى العمود الأخير نجد أنه إذا قمنا بضرب الرمزين في المقارنتين وجمعهما ثم أوجدنا ناتج الجمع للمجموعات الثلاث فإنه لا يساوي الصفر. وهذا يدل على أن المقارنات ليست متعامدة.

المجموعة	المتحول المزيف الأول (Contrast1)	المتحول المزيف الثاني (Contrast2)	الجداء (Contrast1×Contrast2)
الدواء التمويهي	-2	-1	2
الجرعة المنخفضة	1	0	0
الجرعة المرتفعة	1	1	1
الكلي	0	0	3

الجدول 5.8 المقارنات غير المتعامدة لبيانات المثال Viagra

ليس هناك أي خطأ يمنع تنفيذ المقارنات غير المتعامدة. ولكن إذا أردت تنفيذ هذا النوع من المقارنات فيجب أن تكون حذراً في تفسير النتائج التي تحصل عليها. عند تنفيذ المقارنات غير المتعامدة فإن المقارنات المنفّذة هي مرتبطة ولذلك فإن إحصائيات الاختبار الناتجة وقيم p ستكون مرتبطة أيضاً لحد ما. ولهذا السبب يجب أن تستخدم مستوى احتمال أكثر صرامة لقبول الدلالة الإحصائية لمقارنة معينة (انظر الفقرة 11.2.8). ولهذا السبب أيضاً ننصحك بتنفيذ المقارنات المتعامدة إذا كان ذلك ممكناً.

4.10.2.8 المقارنات القياسية

قد تضطر أحياناً لتصميم المقارنات الخاصة بك. ولكن هناك مقارنات خاصة تم تصميمها لمقارنة بعض الأوضاع. وبعض هذه المقارنات متعامد وبعضها الآخر غير متعامد. وتسمح العديد من الإجرائيات في برنامج SPSS باختيار المقارنات التي تريد تنفيذها والتي سيتم ذكرها في هذه الفقرة.

يعرض الجدول 6.8 المقارنات المتوفرة في برنامج SPSS من أجل الإجرائيات مثل التراجع المنطقي (انظر الفقرة 3.4.6)، التحليل العاملي للتباين، وتحليل التباين للقياسات المكررة (انظر الفصلين 9 و10). ومع أن الترميز الدقيق غير متوفر في الجدول 6.8 فإن هذا الجدول يحوي أمثلة عن المقارنات

المنفذة من أجل حالات تحوي ثلاث أو أربع مجموعات (حيث تمت تسمية المجموعات 1,2,3 أو 1,2,3,4). عند ترميز المتحولات في محرر البيانات يقوم SPSS بمعالجة الرمز ذو القيمة الأدنى على أنه المجموعة 1، ويكون الرمز الأعلى منه مباشرة للمجموعة 2 وهكذا. لذلك، واعتماداً على المقارنات التي تريد تنفيذها يجب عليك ترميز متحول التجميع بشكل مناسب (ثم استخدم الجدول 6.8 كدليل للمقارنات التي سينفذها برنامج SPSS).

ربما لاحظت أن بعض المقارنات في (الجدول 6.8) متعامدة (مثل Helmert ومقارنات الفرق) وبعضها الآخر غير متعامد مثل (التباعد، البسيطة، المكررة). وربما لاحظت أيضاً أن المقارنات المحسوبة باستخدام المقارنات البسيطة هي نفسها المعطاة باستخدام ترميز المتحول المزيف المبين في الجدول 2.8.

الاسم	التعريف	المقارنة	ثلاث مجموعات	أربع مجموعات
التباعد (الأول) Deviation	تقارن أثر كل فئة (باستثناء الأولى) مع الأثر التجريبي الإجمالي	1	2 مقابل (1,2,3)	2 مقابل (1,2,3,4)
		2	3 مقابل (1,2,3)	3 مقابل (1,2,3,4)
		3	-	4 مقابل (1,2,3,4)
التباعد (الأخير) Deviation	تقارن أثر كل فئة (باستثناء الأخيرة) مع الأثر التجريبي الإجمالي	1	1 مقابل (1,2,3)	1 مقابل (1,2,3,4)
		2	2 مقابل (1,2,3)	2 مقابل (1,2,3,4)
		3	-	3 مقابل (1,2,3,4)
البسيطة (الأول) Simple	تقارن كل فئة مع الفئة الأولى	1	1 مقابل 2	1 مقابل 2
		2	1 مقابل 3	1 مقابل 3
		3	-	1 مقابل 4
البسيطة (الأخير) Simple	تقارن كل فئة مع الفئة الأخيرة	1	1 مقابل 3	1 مقابل 4
		2	2 مقابل 3	2 مقابل 4
		3	-	3 مقابل 4
المكررة Repeated	تقارن كل فئة (باستثناء الأولى) مع الفئة السابقة	1	1 مقابل 2	1 مقابل 2
		2	2 مقابل 3	2 مقابل 3
		3	-	3 مقابل 4
Helmert	تقارن كل فئة (باستثناء الأخيرة) مع الأثر الوسطي لجميع الفئات اللاحقة	1	1 مقابل (2,3)	1 مقابل (2,3,4)
		2	2 مقابل 3	2 مقابل (3,4)
		3	-	3 مقابل 4
الفرق Difference	تقارن كل فئة (باستثناء الأولى) مع الأثر الوسطي لجميع الفئات السابقة	1	3 مقابل (2,1)	4 مقابل (3,2,1)
		2	2 مقابل 1	3 مقابل (2,1)
		3	-	2 مقابل 1

الجدول 6.8 المقارنات القياسية المتوفرة في برنامج SPSS

5.10.2.8 المقارنات كثيرة الحدود: تحليل المنحى

من أنواع المقارنات التي أغفلنا ذكرها في (الجدول 6.8) المقارنة كثيرة الحدود. وتختبر هذه المقارنة المنحى في البيانات، وبشكلها الأولي جداً تبحث عن المنحى الخطي (أي أن متوسط المجموعة يزداد بشكل متناسب). وهناك مناحي أكثر تعقيداً يمكن اختبارها كالمنحى التربيعي والتكعيبي والرباعي. يعرض (الشكل 6.8) مخططات لأنواع المناحي التي يمكن أن تتواجد في مجموعات البيانات. ينبغي أن يكون المنحى الخطي (Linear trend) مألوفاً الآن، وهو يمثل تغيراً تناسبياً في قيمة المتحول التابع عبر الفئات المرتبة. ويحدث المنحى التربيعي (Quadratic trend) عندما يكون هناك تغير وحيد في اتجاه المنحني. وكمثال على ذلك يمكن أن نأخذ الحالة التي يكون فيها الدواء منشطاً في مهمة ما في البداية ولكن زيادة الجرعة تؤدي لانخفاض الأداء مرة أخرى. ويجب أن يكون بديهياً أنه للحصول على منحى تربيعي فإننا بحاجة لثلاث مجموعات على الأقل (لأنه في حالة مجموعتين فقط فإن عدد الفئات من المتحولات المستقلة غير كاف لكي تتغير متوسطات المتحول التابع باتجاه معين ثم باتجاه آخر). ويحدث المنحى التكعيبي (Cubic trend) عندما يكون هناك تغيران في اتجاه المنحى. لذلك وعلى سبيل المثال يرتفع المتوسط للمتحول التابع بين الزوج الأول من فئات المتحول المستقل ثم ينخفض عبر الفئات اللاحقة ثم يعود للارتفاع عبر الفئات الأخيرة. وللحصول على تغيرين في اتجاه المتوسط يجب أن تكون لدينا 4 فئات من المتحول المستقل على الأقل. أما المنحى الأخير الذي يحتمل أن تصادفه فهو المنحى الرباعي (Quartic trend)، ولهذا المنحى ثلاثة تغيرات في الاتجاه (ولذلك فنحن بحاجة إلى 5 فئات من المتحول المستقل على الأقل).

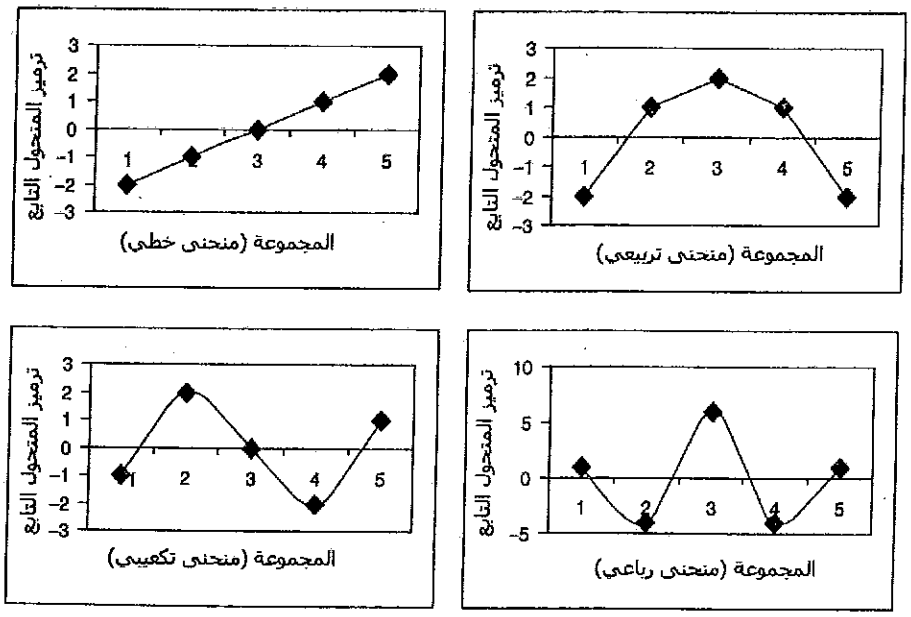

الشكل 6.8 المنحى الخطي، التربيعي، التكعيبي، الرباعي عبر 5 مجموعات

يجب اختبار المناحي كثيرة الحدود في مجموعات البيانات التي يكون فيها معنى لترتيب فئات المتحول المستقل (على سبيل المثال، عند إدارة 5 جرعات من دواء معين فمن المهم اختبار هذه الجرعات حسب ترتيب قيمها). من أجل بيانات Viagra هناك ثلاث مجموعات فقط ولذلك نتوقع أن نجد منحى خطياً أو تربيعياً فقط (وسيكون اختبار المناحي من الدرجة الأعلى بدون فائدة).

ولكل من هذه المناحي مجموعة من الرموز للمتحولات المزيفة في نموذج التراجع، لذلك نقوم بنفس العمل الذي نفذناه من أجل المقارنات المنظمة باستثناء أن الترميز المعتمد لتمثيل نوع المنحى المرغوب هو جاهز سلفاً. لقد تم في (الشكل 6.8) إنشاء المخططات برسم قيم الترميز للمجموعات الخمس. وإذا قمت بجمع الرموز لمنحى معين فإن نتيجة الجمع تساوي الصفر، وإذا قمت بضرب الرموز فإنك تجد أن مجموع الجداءات يساوي الصفر أيضاً. وهكذا فإن هذه المقارنات متعامدة. إن أهم ما يميز هذه المناحي أنك لست بحاجة لبناء قيم الترميز إذ أنها جاهزة سلفاً.

11.2.8 الإجرائيات Post hoc

غالباً ما نصادف الحالة التي لا نملك فيها أية توقعات مسبقة عن البيانات التي نقوم بجمعها، ولكننا نهتم في استكشاف البيانات بحثاً عن أي فروق قد تكون موجودة بين المتوسطات. تدعى هذه الإجرائيات أحياناً بتحليل البيانات الاستكشافي (Exploratory data analysis)، ولكنني أفضّل النظر إلى هذه الإجرائية على أنها "إيجاد الفروق التي يجب أن أكون قد توقعتُها إذا كنتُ ذكياً لحد معين".

تتألف اختبارات post hoc من مقارنات زوجية (ثنائية) (pairwise comparisons) مصممة لمقارنة جميع التراكيب المختلفة للمجموعات التي تتم معالجتها. ولذلك فهي تشبه أخذ كل زوج من المجموعات ثم تطبيق اختبار t عليه. وقد يبدو ذلك غبياً في ضوء ما ذكرناه سابقاً عن مشاكل معدلات الخطأ حسب العائلة المضخمة. ولكن المقارنات الزوجية تتحكم بالخطأ حسب العائلة وذلك بتصحيح مستوى الدلالة لكل اختبار بحيث يبقى المعدل الكلي الخطأ من النوع الأول (α) عبر جميع المقارنات عند القيمة 0.05. وهناك عدة طرق يمكن التحكم من خلالها بمعدل الخطأ حسب العائلة. ومن أشهر هذه الطرق وأسهلها تقسيم α على عدد المقارنات وهذا يضمن أن الخطأ التراكمي من النوع الأول يبقى أقل من 0.05. ولذلك إذا قمنا بعشرة اختبارات فإننا نستخدم القيمة 0.005 كمعيار للدلالة. تعرف هذه الطريقة بتصحيح Bonferroni نسبة إلى Carlo Bonferroni (الشكل 7.8).

هناك نقطة سلبية للتحكم بمعدل الخطأ حسب العائلة وهي ضياع القدرة الإحصائية. وهذا يعني أن احتمال رفض أثر موجود فعلياً يصبح أكبر (خطأ من النوع الثاني). إن استخدام معدل خطأ من النوع الأول أكثر صرامة لكل مقارنة يزيد احتمال فقدان فرق حقيقي في البيانات.

الشكل 7.8 Carlo Bonferroni

ولذلك عند البحث عن إجرائية post hoc التي يجب استخدامها فإن علينا أخذ العوامل الثلاث التالية بعين الاعتبار:

1. هل يتحكم الاختبار بمعدل الخطأ من النوع الأول؟
2. هل يتحكم الاختبار بمعدل الخطأ من النوع الثاني (هل للاختبار قدرة إحصائية جيدة)؟
3. هل الاختبار موثوق عند خرق فرضيات الاختبار لتحليل التباين (ANOVA)؟

هناك بعض الكتب الرائعة التي تتحدث عن آلية عمل الاختبارات post hoc، ويوفر برنامج SPSS ما لا يقل عن 18 إجرائية post hoc، ولكن المهم بالنسبة لك هو معرفة اختبارات post hoc التي تتوافق بأفضل شكل مع المعايير الثلاثة التي ذكرناها سابقاً.

1.11.2.8 الإجرائيات Post hoc ومعدلات الخطأ من النوع الأول (α) ومن النوع الثاني

إن معدل الخطأ من النوع الأول والقدرة الإحصائية لاختبار ما مرتبطان ببعضهما البعض. ولذلك هناك دائماً نقطة سلبية: إذا كان الاختبار صارماً (أي أن احتمال الخطأ من النوع الأول صغير) فمن المحتمل أن يفقد قدرته الإحصائية (أي أن احتمال الخطأ من النوع الثاني سيكون كبيراً). لذلك فمن المهم أن تتحكم إجرائيات المقارنة المتعددة بمعدل الخطأ من النوع الأول ولكن دون فقدان كبير في القدرة الإحصائية. إذا كان الاختبار صارماً جداً فمن المحتمل أن نرفض الفروق بين المتوسطات والتي هي في الحقيقة كبيرة وذات معنى.

لا تقوم المقارنة الزوجية ذات الفرق الأقل دلالة (LSD) بأية محاولة للتحكم بالخطأ من النوع الأول، وهي تكافئ تنفيذ اختبارات t متعددة على البيانات. والفرق الوحيد هو أن LSD تتطلب أن تكون

ANOVA الكلية ذات دلالة. وكذلك فإن إجرائية Studentized Newman-Keuls (SNK) هي اختبار متسامح جداً وتفتقد التحكم بمعدل الخطأ من النوع الأول. أما اختبارات Bonferroni وTukey فهي تتحكم بمعدل الخطأ من النوع الأول بشكل ممتاز ولكنها اختبارات صارمة (تفتقد القدرة الإحصائية). وعندما يكون عدد المقارنات صغيراً فإن قدرة الاختبار Bonferroni تكون أعلى، بينما تكون قدرة الاختبار Tukey أعلى عند اختبار عدد كبير من المتوسطات. عادةً يكون اختبار Tukey أكثر قدرة من اختبارات Dunn وScheffé. أما إجرائية Ryan, Einot, Gabriel and Welsch Q (REGWQ) فتملك قدرة جيدة وتحكماً صارماً بمعدل الخطأ من النوع الأول. عندما تريد اختبار جميع الأزواج من المتوسطات فإن هذه الإجرائية ربما تكون هي الأفضل. ولكن إذا كانت أحجام المجموعات مختلفة فيجب عدم استخدام هذه الإجرائية.

2.11.2.8 الإجرائيات Post hoc وخرق فرضيات الاختبار

تبحث معظم الأبحاث المجراة على اختبارات post hoc عما إذا كان أداء الاختبار جيداً عندما تكون أحجام المجموعات مختلفة (تصميم غير متوازن)، وعندما تكون تباينات المجتمع مختلفة جداً، وعندما تكون البيانات غير موزعة طبيعياً. والأخبار السارة هي أن معظم إجرائيات المقارنات المتعددة ذات أداء جيد نسبياً عند وجود تغايرات صغيرة عن الطبيعية أما الأخبار السيئة فهي أن أداءها سيء عندما تكون أحجام المجموعات غير متساوية وعندما تكون تباينات المجتمع مختلفة.

تم تصميم إجرائيات الاختبار المزدوجة Hochberg's GT2 و Gabriel لمواجهة الحالات التي تكون فيها أحجام المجموعات مختلفة. وعادة تكون إجرائية Gabriel أكثر فعالية ولكن يمكن أن تصبح متسامحة جداً عندما تكون أحجام العينات مختلفة جداً. وإجرائية Hochberg's GT2 غير موثوقة جداً عندما تكون تباينات المجتمع مختلفة، ولذلك يجب أن تُستخدم عند التأكد من عدم وجود تلك الحالة. وهناك مجموعة من إجرائيات المقارنة المتعددة التي تم تصميمها خصيصاً للحالات التي تكون فيها تباينات المجتمع مختلفة. ويوفر برنامج SPSS أربعة خيارات لهذه الوضع: Tamhane's T2 وDunnett's T3 وGames-Howell وDunnett's C. إن Tamhane's T2 صارم بينما تتحكم Dunnett's T3 وDunnett's C بمعدل الخطأ من النوع الأول بشكل محكم. تعتبر إجرائية Games-Howell أكثر فعالية ولكنها يمكن أن تكون متسامحة عندما تكون أحجام العينات صغيرة. وهي دقيقة أيضاً عندما تكون أحجام العينات غير متساوية.

3.11.2.8 ملخص الإجرائيات Post hoc

يعتمد اختيار إجرائية المقارنة على الوضع الفعلي المتوفر وفيما إذا كانت الأهمية هي للمحافظة على تحكم صارم بمعدل الخطأ حسب العائلة أو امتلاك قدرة إحصائية أكبر. على كل حال، هناك بعض التوجيهات العامة التي يمكن الالتزام بها. عندما تكون أحجام العينات متساوية وأنت واثق من أن

تباينات المجتمع متشابهة فيمكنك استخدام REGWQ أو Tukey لأن كلاً منهما تملك قدرة جيدة وتحكماً جيداً بمعدل الخطأ من النوع الأول. إن إجرائية Bunferroni صارمة عموماً ولكن إذا أردت تحكماً مضموناً بمعدل الخطأ من النوع الأول فإن هذا هو الاختبار الذي ينبغي استخدامه. إذا كانت أحجام العينات مختلفة قليلاً فعليك استخدام إجرائية Gabriel لأنها ذات قدرة أكبر، وإذا كانت أحجام العينات مختلفة بشكل كبير فعليك استخدام الإجرائية Hochberg's GT2. إذا كان هناك أي شك بأن تباينات المجتمع متساوية فعليك استخدام إجرائية Games-Howell لأنها تقدم أفضل أداء عادة. وننصح بتنفيذ إجرائية Games-Howell بجانب أي اختبار آخر تريد استخدامه بسبب عدم التأكد من معرفة فيما إذا كانت تباينات المجتمع متكافئة.

ومع أن هذه التوجيهات توفر دليلاً يمكن إتباعه، فإن عليك الإطلاع على بقية الإجرائيات المتوفرة ومعرفة متى يمكن استخدامها (إن اختبار Dunnett هو المقارنة المتعددة الوحيدة التي تسمح باختبار المتوسطات مقارنة مع متوسط مجموعة المراقبة).

3.8 تنفيذ ANOVA وحيد الاتجاه في برنامج SPSS

لقد تعلمنا بعض الأفكار النظرية لتحليل التباين ANOVA وسننتقل الآن لوضع هذه المعارف النظرية قيد التطبيق بتنفيذ ANOVA على بيانات Viagra. وكما في حالة اختبار t المستقل فإنه يجب أن ندخل البيانات إلى محرر البيانات باستخدام متحول ترميز لتحديد انتماء البيانات إلى المجموعات الثلاث. لذلك يجب إدخال البيانات في عمودين (يدعى أحدهما dose ويحدد مقدار Viagra المعطى لكل مشترك، والآخر Libido ويدل على مستوى الشهوة عند المشترك خلال الأسبوع التالي لتناول Viagra). يحوي الملف Viagra.sav تلك البيانات ولكننا ننصح بإدخالها يدوياً لاكتساب المهارة في إدخال البيانات. لقد قمنا بترميز متحول التجميع بحيث يكون 1= مجموعة الدواء التمويهي و2= مجموعة الجرعة المنخفضة و3= مجموعة الجرعة المرتفعة (أنظر الفقرة 4.4.2).

لتنفيذ ANOVA وحيد الاتجاه علينا أولاً الوصول إلى مربع الحوار الرئيسي باستخدام مسار القائمة Analyze ⇒ Compare Means ⇒ One-way ANOVA (الشكل 8.8). يحوي مربع الحوار حيزاً يتم فيه عرض المتحول التابع (أو المتحولات) وحيزاً آخر لتحديد متحول التجميع أو العامل. والعامل (Factor) هو مصطلح آخر للمتحول المستقل ويجب عدم الخلط بينه وبين العوامل التي سنصادفها عند الحديث عن تحليل العوامل. من الأمور غير المستحبة أن يشجّع برنامج SPSS في الإجرائيات المختلفة مثل ANOVA وحيد الاتجاه، على تنفيذ اختبارات متعددة، وهذا كما رأينا ليس أمراً جيداً. فعلى سبيل المثال، في هذه الإجرائية يمكنك تحديد عدة متحولات تابعة بحيث يمكنك تنفيذ عدة عمليات ANOVA. في الواقع، إذا قمت بقياس عدة متحولات تابعة (لنقل أنك قمت بقياس الإثارة الفيزيولوجية ومستوى القلق إضافة إلى الشهوة) فمن المفضل تحليل هذه البيانات باستخدام MANOVA بدلاً من معالجة كل قياس تابع بشكل منفصل (أنظر الفصل 14). من أجل المثال

Viagra نقوم باختيار المتحول Libido فقط من لائحة المتحولات وننقله إلى الحيز المسمى Dependent List وذلك بنقر زر السهم الموجود بين القسمين. نختار بعد ذلك متحول التجميع dose وننقله إلى الحيز المسمى Factor بنقر زر السهم الموجود بين القسمين.

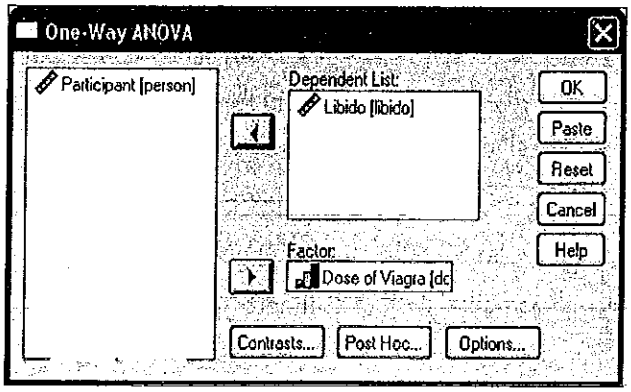

الشكل 8.8 مربع الحوار الرئيسي لتحليل التباين وحيد الاتجاه (One-way ANOVA)

1.3.8 المقارنات المنظمة باستخدام SPSS

إذا نقرت الزر ...Contrasts فإنك تصل لمربع الحوار الذي يسمح بتنفيذ المقارنات المنظمة التي تم شرحها في الفقرة 10.2.8. يبين (الشكل 9.8) مربع الحوار Contrasts الذي يتألف من قسمين. يختص القسم الأول بتحديد تحليل المنحى. إذا أردت اختبار المناحي في البيانات فانقر الخيار Polynomial ثم اختر درجة كثير الحدود الذي تريد استخدامه. تحوي بيانات Viagra ثلاث مجموعات فقط ولذلك فإن أعلى درجة لكثير الحدود الذي يمكن استخدامه هو المنحى التربيعي (أنظر الفقرة 3.10.2.8). من وجهة نظر تحليل المنحى فإن من المهم جداً ترميز متحولات التجميع بترتيب ذي معنى. نتوقع أن تكون الشهوة أدنى ما يمكن في مجموعة الدواء التمويهي، وتزداد في مجموعة الجرعة المنخفضة، ثم تزداد مرة أخرى في مجموعة الجرعة المرتفعة. لاكتشاف منحى ذو معنى ينبغي علينا ترميز هذه المجموعات بترتيب تصاعدي. وقد قمنا بذلك فعلاً حيث تم ترميز مجموعة الدواء التمويهي بأدنى قيمة وهي 1، وترميز مجموعة الجرعة المنخفضة بالقيمة الوسطى وهي 2، أما مجموعة الجرعة المرتفعة فأخذت القيمة العليا وهي 3. إذا أجرينا الترميز لهذه المجموعات بصورة مختلفة فإن ذلك يؤثر على اكتشاف المنحى، وعند اكتشاف المنحى فهل هو ذو معنى أم لا.

لدينا ثلاث مجموعات فقط في البيانات Viagra ولذلك نحدد الخيار Polynomial ثم نختار المنحى التربيعي من القائمة المنسدلة Degree وذلك بنقر الخيار Quadratic. عند اختيار المنحى التربيعي فإن برنامج SPSS يختبر المنحى الخطي والمنحى التربيعي.

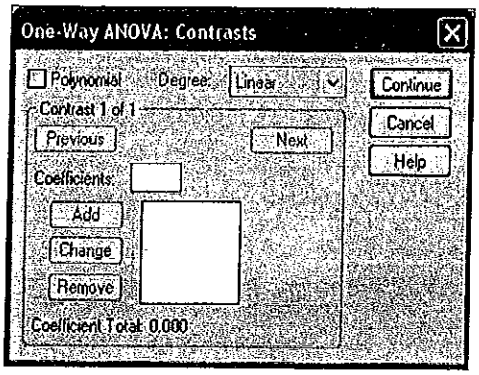

الشكل 9.8 مربع الحوار لتنفيذ المقارنات المنظمة

يختص القسم الأدنى في مربع الحوار 9.8 بتحديد المقارنات المنظمة. لتنفيذ المقارنات المنظمة ينبغي علينا إعلام البرنامج SPSS عن الأثقال التي يجب تعيينها لكل مجموعة. والخطوة الأولى هي تحديد المقارنات التي تريد تنفيذها ثم تعيين الأثقال لكل مجموعة في كل واحدة من المقارنات. لقد بحثنا هذه العملية في الفقرة 2.10.2.8 ولذلك نعلم أن الأثقال للمقارنة الأولى هي 2- لمجموعة الدواء التمويهي و1+ لمجموعة الجرعة المنخفضة و1+ لمجموعة الجرعة المرتفعة. نحدد هذه المقارنة أولاً. من المهم أن تتأكد من إدخال الأثقال الصحيحة لكل مجموعة، لذلك عليك أن تتذكر أن الثقل الأول الذي تقوم بإدخاله سيكون للمجموعة الأولى (أي المجموعة ذات الترميز بالقيمة الأدنى في محرر البيانات). ومن أجل بيانات Viagra فإن المجموعة ذات الترميز بالقيمة الأدنى هي مجموعة الدواء التمويهي (ذات الرمز 1) ولذلك علينا إدخال الثقل لهذه المجموعة أولاً. انقر في الحيز المسمى Coefficients ثم اكتب القيمة 2- وانقر الزر Add. بعد ذلك علينا إدخال الثقل للمجموعة الثانية (وهي مجموعة الجرعة المنخفضة التي تم ترميزها بالقيمة 2 في محرر البيانات). انقر في الحيز المسمى Coefficients ثم اكتب القيمة 1 وانقر الزر Add. وأخيراً ندخل الثقل للمجموعة الثالثة (وهي مجموعة الجرعة المرتفعة التي تم ترميزها بالقيمة الأعلى في محرر البيانات وهي 3). انقر في الحيز المسمى Coefficients ثم اكتب القيمة 1 وانقر الزر Add. يجب أن يبدو مربع الحوار كما في الشكل 10.8.

بعد الانتهاء من إدخال الأثقال يمكنك تغيير أو إزالة أي منها وذلك باستخدام الفأرة لاختيار الثقل الذي تريد تعديله. يظهر الثقل في الحيز المسمى Coefficients حيث يمكنك كتابة القيمة الجديدة للثقل ونقر الزر Change. كما يمكنك نقر الثقل الذي تريد حذفه بشكل كامل ثم نقر الزر Remove. يقوم برنامج SPSS بحساب المعامل الكلي الذي كما رأينا في الفقرة 2.10.2.8 يجب أن يساوي الصفر. إذا كان المعامل الكلي مخالفاً للصفر فيجب عليك التحقق من أن المقارنات المنظمة ذات معنى ومن أنك اتبعت القواعد في تعيين الأثقال.

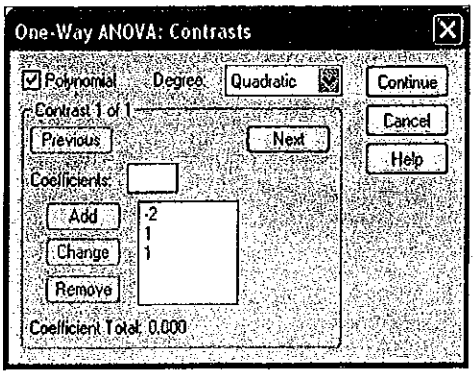

الشكل 10.8 مربع الحوار Contrasts المكتمل للمقارنة الأولى لبيانات Viagra

بعد الانتهاء من تعريف المقارنة الأولى، انقر الزر Next. تختفي الأثقال الذي أدخلتها سابقاً وتظهر عبارة Contrast 2 of 2 في مربع الحوار. نعلم من الفقرة 2.10.2.8 أن الأثقال للمقارنة الثانية هي: 0 لمجموعة الدواء التمويهي و1+ لمجموعة الجرعة المنخفضة و1- لمجموعة الجرعة المرتفعة. يمكننا تحديد هذه المقارنة كما في السابق. ومع معرفتنا أن الثقل الأول الذي نقوم بإدخاله سيكون لمجموعة الدواء التمويهي فإن علينا إدخال القيمة 0 كالثقل الأول. انقر في الحيز المسمى Coefficients ثم اكتب القيمة 0 وانقر الزر Add. بعد ذلك علينا إدخال الثقل لمجموعة الجرعة المنخفضة بالنقر في الحيز المسمى Coefficients وكتابة القيمة 1 ثم نقر الزر Add. وأخيراً ندخل الثقل لمجموعة الجرعة المرتفعة بالنقر في الحيز المسمى Coefficients وكتابة القيمة 1- ثم نقر الزر Add. يجب أن يبدو مربع الحوار كما في (الشكل 11.8).

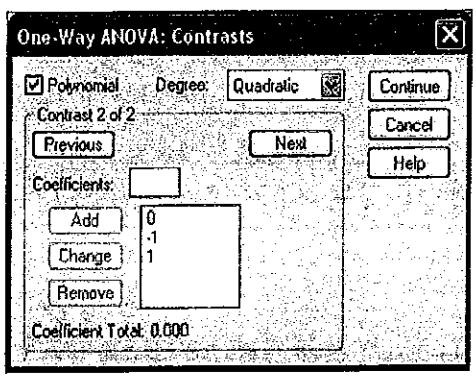

الشكل 11.8 مربع الحوار Contrasts المكتمل للمقارنة الثانية لبيانات Viagra

لاحظ أن مجموع الأثقال يساوي الصفر في المقارنة الأولى. ومن المهم أن تتذكر إدخال الثقل 0 للمجموعات غير المضمنة في المقارنة. عند الانتهاء من تعريف جميع المقارنات المنظمة انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

2.3.8 الاختبارات post hoc في برنامج SPSS

بعد تعريف المقارنات المنظمة في برنامج SPSS يمكننا اختيار الاختبارات post hoc التي نريد تنفيذها. ونظرياً إذا قمنا بالمقارنات المنظمة فإننا لسنا بحاجة لاختبارات post hoc (لأننا اختبرنا الفرضيات التي تهمنا). وبشكل مشابه، إذا اخترنا تنفيذ اختبارات post hoc فإننا لسنا بحاجة للمقارنات المنظمة (لعدم وجود فرضيات نريد اختبارها). على كل حال، سنقوم بتنفيذ بعض اختبارات post hoc على بيانات Viagra. انقر الزر Post Hoc... في مربع الحوار الرئيسي للوصول إلى مربع الحوار اختبارات post hoc المبين في (الشكل 12.8).

لقد قدمنا في الفقرة 3.11.2.8 إجرائيات post hoc المختلفة والمناسبة للأوضاع المختلفة. في بيانات Viagra لدينا عينات بأحجام متساوية ولذلك لا يمكننا استخدام اختبار Gabriel. يجب علينا استخدام اختبار Tukey و REGWQ والتحقق من النتائج باستخدام إجرائية Games-Howell. لدينا فرضيات محددة تنص على أن مجموعتي الجرعة المنخفضة والمرتفعة تختلفان عن مجموعة الدواء التمويهي ولذلك يمكننا استخدام اختبار Dunnett لفحص هذه الفرضيات. بعد تحديد اختبار Dunnett يمكنك تغيير فئة المراقبة (الخيار الافتراضي هو استخدام الفئة الأخيرة) وذلك لتحديد الفئة الأولى كفئة مراقبة (لأنه تم ترميز مجموعة الدواء التمويهي بالقيمة الأدنى). يمكنك أيضاً اختيار فيما إذا كنت تريد تنفيذ اختبار ثنائي الطرف (2-Sided) أو أحادي الطرف. إذا اخترت اختباراً أحادي الطرف فعليك أن تتوقع فيما إذا كان متوسط مجموعة المراقبة هو أقل من المتوسط لمجموعة تجريبية ما (Control>) أو أكبر من المتوسط لمجموعة تجريبية ما (Control<). هذا كل ما يتطلبه تحديد اختبارات post hoc، وعند الانتهاء يجب أن يبدو مربع الحوار كما في (الشكل 12.8). انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

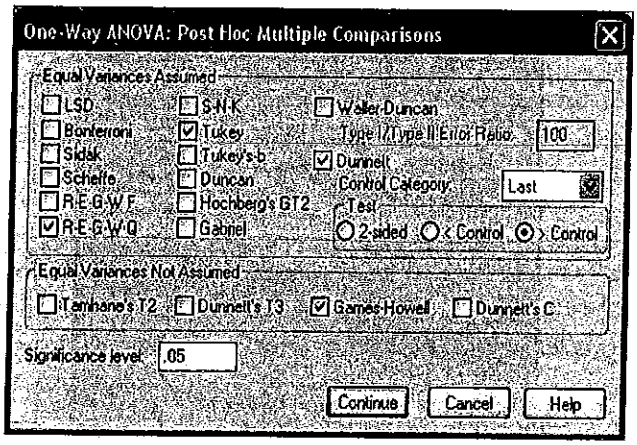

الشكل 12.8 مربع الحوار لتحديد اختبارات post hoc

3.3.8 الخيارات

إن خيارات ANOVA وحيد الاتجاه هي بسيطة ومباشرة. يمكنك في البداية تحديد الإحصائيات الوصفية حيث تحصل على جدول لقيم المتوسط والانحراف المعياري والخطأ المعياري ومجالات الثقة للمتوسط من أجل كل مجموعة. وهذا الخيار مفيد لأنه يساعد في تفسير النتائج النهائية. هناك خيار حيوي يجب تحديده وهو اختبار تجانس التباين. وكما في حالة الاختبار t فإن هناك فرضية تَسَاوي التباينات للمجموعات، وتحديد هذا الخيار سيختبر هذه الفرضية. يستخدم برنامج SPSS اختبار Levene الذي يختبر فرضية أن التباينات لكل المجموعات متساوية (أنظر الفقرة 6.3). إذا انهارت فرضية تجانس التباين فإن برنامج SPSS يقدم لنا نسختين بديلتين من النسبة F: Brown-Forsythe F وWelch F. سنتم مناقشة هاتين الإحصائيتين في المربع 3.8.

هناك أيضاً خيار رسم المتوسطات Means Plot (أنظر الشكل 13.8) الذي يعطي (إذا تم تحديده) مخططاً لمتوسطات المجموعات في الخرج. وأخيراً هناك الخيارات التي تسمح بتحديد فيما إذا كنا نريد استثناء بعض الحالات على أساس اللائحة أو على أساس التحليل. وهذا الخيار مفيد فقط عند تنفيذ عدة عمليات ANOVA على متحولات تابعة مختلفة. يستثني الخيار الأول Exclude cases analysis by analysis أية حالة فيها قيم مفقودة لأيّ من المتحولات المستقلة أو التابعة المستخدمة في تحليل معين. أما الخيار الثاني Exclude cases listwise فيستثني من جميع عمليات التحليل أية حالة فيها قيم مفقودة للمتحول المستقل أو أي من المتحولات التابعة المحددة. ولذلك إذا اعتدت على الممارسات الجيدة و لم تنفذ مئات عمليات ANOVA على متحولات تابعة مختلفة (أنظر الفصل 14 حول MANOVA) فإن الإعدادات الافتراضية ممتازة. عند الانتهاء من تحديد الخيارات المناسبة انقر الزر Continue للعودة إلى مربع الحوار الرئيسي ثم انقر الزر OK لتنفيذ عملية التحليل.

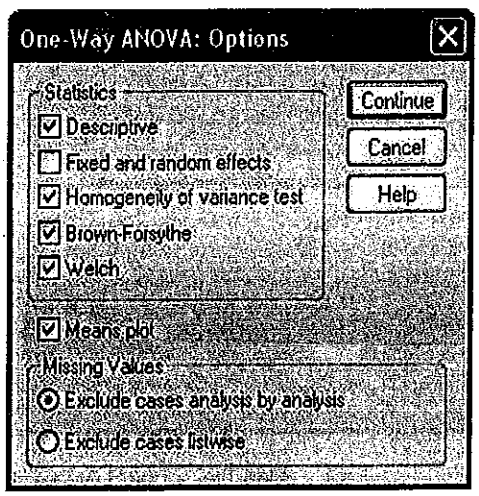

الشكل 13.8 الخيارات لتحليل التباين وحيد الاتجاه

المربع 3.8 ماذا نفعل في ANOVA إذا لم تكن فرضية تجانس التباينات محققة

ذكرنا في الفقرة 9.2.8 أنه عندما تكون أحجام المجموعات غير متساوية فإنه يمكن أن يكون لخرق فرضية تجانس التباينات آثار خطيرة. ويتضمن برنامج SPSS خيارات لنسب F بديلة. لقد تم اشتقاق هذه النسب لتكون متماسكة عندما يتم خرق فرضية تجانس التباينات. النسبة الأولى هي Brown & Forsythe F التي يمكن شرحها بسهولة. وقد ذكرنا سابقاً أنه عندما تكون أحجام المجموعات غير متساوية وتكون للمجموعات الكبيرة أكبر التباينات فإن ذلك يدفع النسبة F لتكون صارمة. إذا عدنا للمعادلة (7.8) يصبح لهذا الكلام معنى واضح، لأنه عند حساب SS_R تكون التباينات مضروبة بعدد أقل بواحد من حجم عيناتها وفي هذه الحالة نحصل على أحجام عينات كبيرة مضروبة بتباينات كبيرة مما يؤدي لتضخيم قيمة SS_R. ولكن ما أثر ذلك على النسبة F؟ حسناً، إن النسبة F متناسبة مع SS_M/SS_R فإذا كانت SS_R كبيرة فإن النسبة F تصبح أصغر (ولهذا تكون أكثر صرامة، إذ أن قيمتها قد انخفضت). وقد تحاشى Brown & Forsythe هذه المشكلة بتثقيل تباين المجموعات بمقلوب أحجام عيناتها وليس بأحجام العينات (عملياً يتم استخدام n/N لذلك فهو حجم العينة كنسبة من حجم العينة الكلي). وهذا يعني أن أثر العينات كبيرة الحجم مع التباينات الكبيرة قد انخفض:

$$F_{BF} = \frac{SS_M}{SS_{RBF}} = \frac{SS_M}{\sum s_k^2\left(1-\frac{n_k}{N}\right)}$$

لذلك، ومن أجل بيانات Viagra تكون SS_M=20.135 (كما هي سابقاً) وتصبح المعادلة:

$$F_{BF} = \frac{SS_M}{s^2_{group1}\left(1-\frac{n_{group1}}{N}\right)+s^2_{group2}\left(1-\frac{n_{group2}}{N}\right)+s^2_{group3}\left(1-\frac{n_{group3}}{N}\right)}$$

$$= \frac{20.135}{1.70\left(1-\frac{5}{15}\right)+1.70\left(1-\frac{5}{15}\right)+2.50\left(1-\frac{5}{15}\right)}$$

$$= 5.119$$

تم حساب هذه الإحصائية باستخدام عدد درجات الحرية للنموذج والخطأ. من أجل النموذج df_M هو كالسابق (k-1=2) ولكن يجب إجراء عملية تعديل لعدد درجات الحرية للبواقي df_R. إن هذه الحسابات، والنسبة Welch F تتعدى نطاق هذا الكتاب، ولكن يمكن للمهتمين بهذا الموضوع مراجعة الملحق A5.

السؤال البديهي هو أي من هاتين الإجرائيتين هي الأفضل؟. لقد قام Tomarken & Serlin بمراجعة هذه التقنيات وغيرها وخلصا إلى أن كلتا التقنيتان تتحكمان بمعدل الخطأ من النوع الأول بشكل جيد (وعندما لا يكون هناك أثر في المجتمع فإننا نحصل على F بدون دلالة طبعاً). أما من ناحية القدرة الإحصائية (التي تختبر اكتشاف الأثر عند وجوده) فإن اختبار Welch يبدو هو الأفضل إلا في حالة قيمة قصوى للمتوسط وتملك تبايناً كبيراً.

4.8 الخرج من ANOVA وحيد الاتجاه

1.4.8 الخرج للتحليل الأساسي

إذا قمت بتحميل بيانات Viagra (أو قمت بإدخالها يدوياً) واخترت جميع الخيارات التي اقترحناها فإنك ستجد أن الخرج الذي تحصل عليه يشبه ما سنعرضه لاحقاً. وإذا كان الخرج مختلفاً فعلينا أن نشعر بالذعر لأن أحدنا قام بعمليات خاطئة. يعرض (الشكل 14.8) مخطط عمود الخطأ لبيانات Viagra مع خط يوضح المنحى العام لقيم المتوسط عبر المجموعات. لم يتم إنتاج هذا المخطط بشكل تلقائي من برنامج SPSS، ولكن يمكن الحصول على مخطط الخط إذا حددنا الخيار Means Plot (ويبدو هذا المخطط كالشكل 14.8 إلا أنه لا يحوي أعمدة الخطأ). لقد اخترنا إظهار مخطط أعمدة الخطأ لأنه مفيد أكثر من مخطط الخط لوحده. من الواضح تطابق جميع أعمدة الخطأ مما يدل على عدم وجود فروق بين المجموعات (مع أن هذا القياس تقريبي فقط). يدل الخط الذي يصل قيم المتوسط على منحى خطي أي أنه عند زيادة جرعة Viagra يزداد متوسط الشهوة.

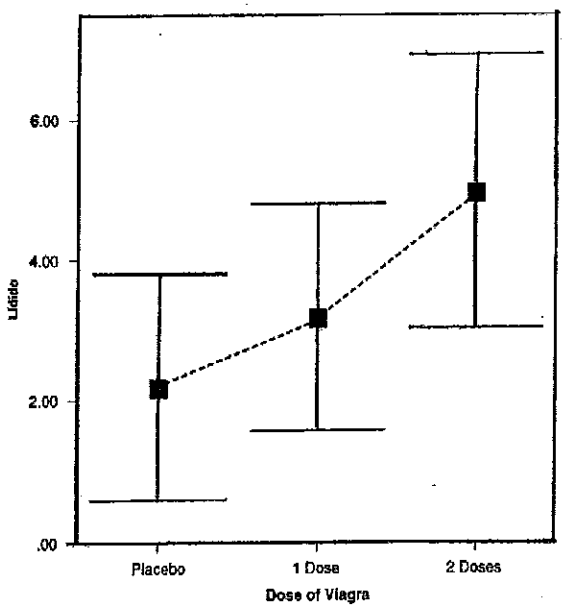

الشكل 14.8 مخطط أعمدة الخطأ لبيانات Viagra

يعرض الخرج 3.8 جدول الإحصائيات الوصفية من الإجرائية وحيدة الإتجاه لبيانات Viagra. وأول ما يجب ملاحظته أن قيم المتوسط والانحراف المعياري توافق ما وجدناه في الجدول 1.8. ونجد في الجدول قيم الخطأ المعياري أيضاً. يجب أن تتذكر أن الخطأ المعياري هو الانحراف المعياري لتوزيع أخذ العينات لهذه البيانات (فبالنسبة لمجموعة الدواء التمويهي، إذا أخذنا مجموعة من العينات من المجتمع الذي جاءت منه تلك البيانات، فإن لمتوسط هذه العينات انحرافاً معيارياً قدره 0.5831).

لقد حصلنا أيضاً على مجالات الثقة للمتوسط. وهذا يعني أنه إذا أخذنا 100 عينة من المجتمع الذي جاءت منه مجموعة الدواء التمويهي وأنشأنا مجالات الثقة للمتوسط، فإن 95 من هذه المجالات سيحوي القيمة الصحيحة للمتوسط، وبكلمة أخرى فإن القيمة الصحيحة للمتوسط ستكون بين 0.5811 و 3.8189. ومع أن هذه القيم التشخيصية ليست هامة حالياً فإننا سنعود إليها لاحقاً.

Descriptives

Libido

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
Placebo	5	2.2000	1.30384	.58310	.5811	3.8189	1.00	4.00
Low Dose	5	3.2000	1.30384	.58310	1.5811	4.8189	2.00	5.00
High Dose	5	5.0000	1.58114	.70711	3.0368	6.9632	3.00	7.00
Total	15	3.4667	1.76743	.45635	2.4879	4.4454	1.00	7.00

الخرج 3.8

الجزء التالي في الخرج هو جدول يلخص اختبار Levene (الخرج 4.8). إن هذا الاختبار مصمم لاختبار فرضية العدم والتي تنص على أن التباينات للمجموعات هي ذاتها. وهو عبارة عن عملية ANOVA منفّذة على الفروق المطلقة بين البيانات المشاهدة والمتوسط للمجموعة التي جاءت منها تلك البيانات[1]. في هذه الحالة يختبر اختبار Levene فيما إذا كانت البيانات للمجموعات الثلاث مختلفة بشكل كبير. إذا كان اختبار Levene ذا دلالة (أي أن قيمة الدلالة .Sig هي أصغر من 0.05) فإنه يمكننا القول أن التباينات هي مختلفة بشكل كبير. وهذا يعني أننا خرقنا إحدى فرضيات ANOVA وعلينا اتخاذ خطوات لتصحيح هذه المسألة. وكما رأينا في الفصل 3، فإن هناك طريقة شائعة لتصحيح الفروق بين تباينات المجموعات وهي تحويل جميع البيانات: إذا كانت التباينات غير متساوية فيمكن أحياناً جعلها مستقرة وذلك بأخذ الجذر التربيعي لكل قيمة من قيم المتحول التابع ثم إعادة عملية التحليل لهذه البيانات المحوّلة (أنظر الفصل 3). على كل حال يمكنك عوضاً عن ذلك تقديم النسبة Welch F (وذلك ما لم يكن لديك قيم قصوى للمتوسط مما يسبب مشكلة مع التباينات). ولحسن الحظ فإنه من أجل هذه البيانات فإن التباينات متشابهة جداً (ولذلك لدينا القيمة المرتفعة للاحتمال)، وإذا نظرنا إلى الخرج 3.8 فإننا نرى أن التباينات لمجموعة الدواء التمويهي ولمجموعة الجرعة المنخفضة هي متساوية.

1 يمكن للقارئ المهتم أن يقوم بما يلي: إنشاء متحول جديد diff يساوي حاصل طرح العلامة من قيمة المتوسط للمجموعة التي تنتمي إليها العلامة. ثم أخذ القيم المطلقة وتنفيذ ANOVA وحيد الاتجاه باعتماد المتحول dose كمتحول مستقل و diff المتحول التابع. ستجد أن قيمة النسبة F لهذا التحليل هي 0.092 وهي ذات دلالة عند مستوى p=0.913.

Test of Homogeneity of Variances

Libido

Levene Statistic	df1	df2	Sig.
.092	2	12	.913

الخرج 4.8

يعرض الخرج 5.8 الجدول التلخيصي لتحليل ANOVA الأساسي. وقد تم تقسيم هذا الجدول إلى قسمين: الآثار بين المجموعات (الآثار العائدة للنموذج: الأثر التجريبي) والآثار ضمن المجموعات (وهو التغاير اللامنهجي في البيانات). وتم تقسيم الأثر بين المجموعات إلى مكونات خطية وتربيعية، وهذه المكونات هي تحليل المناحي الذي تم وصفه في الفقرة 5.10.2.8. تمت تسمية الأثر بين المجموعات بالمركب (Combined) وهو الأثر التجريبي الكلي. وفي هذا الصف لدينا مجموع المربعات للنموذج (SS_M=20.133) وهذه القيمة توافق القيمة المحسوبة في الفقرة 5.2.8. يبلغ عدد درجات الحرية 2 أما قيمة متوسط المربعات للنموذج فتوافق القيمة المحسوبة في الفقرة 7.2.8 وهي 10.067. يعبّر مجموع المربعات ومتوسط المربعات عن الأثر التجريبي. يتم تقسيم هذا الأثر الكلي لأننا طلبنا من برنامج SPSS أن ينفذ تحليل المنحى لهذه البيانات (وسنعود لهذه المناحي لاحقاً). وبما أننا لم نحدد ذلك في الفقرة 1.3.8 فإنه لن يتم إنتاج هذين الصفين من جدول الملخص. يعطي الصف المسمى Within Group تفاصيل التغاير اللامنهجي ضمن هذه البيانات (التغاير العائد للفروق الطبيعية الفردية في الشهوة وردود الفعل المختلفة للدواء Viagra). يخبرنا هذا الجدول عن مقدار التغاير اللامنهجي الموجود (مجموع المربعات للبواقي SS_R) وهذه القيمة (23.60) توافق القيمة المحسوبة في الفقرة 6.2.8. يعطي هذا الجدول بعد ذلك المقدار الوسطي للتغاير اللامنهجي ومتوسط المربعات (MS_R) الذي يوافق القيمة (1.967) المحسوبة في الفقرة 7.2.8. إن اختبار فيما إذا كانت قيم المتوسط للمجموعات هي نفسها هو مُمَثّل بالنسبة F للأثر المركب بين المجموعات. إن قيمة هذه النسبة 5.12 وهي نفس القيمة التي حصلنا عليها في الفقرة 8.2.8. يخبرنا برنامج SPSS أخيراً عما إذا كانت هذه القيمة ناتجة عن الصدفة. يدل العمود الأخير .Sig على احتمال أن تحدث قيمة النسبة F بمحض الصدفة. في هذه الحالة هناك احتمال 0.025 أن تحدث قيمة النسبة F عن طريق الصدفة (أي 2.5% فقط). وقد رأينا في الفصول السابقة أن علماء الاجتماع يستخدمون القيمة 0.05 كمعيار للدلالة الإحصائية. بما أن القيمة المشاهدة للدلالة هي أقل من 0.05 فإنه يمكننا القول بأن هناك أثر ملموس للدواء Viagra. على كل حال، نحن لا نعلم بالضبط حتى الآن ما هو أثر Viagra (لا نعرف ما هي المجموعات المختلفة). هناك أمر مهم هنا وهو أننا حصلنا على أثر تجريبي ذو دلالة مع أن مخطط أعمدة الخطأ يشير إلى عدم وجود فرق. توضح هذه المفارقة كيف يمكن لمخطط أعمدة الخطأ أن يعمل كدليل خشن فقط للبيانات.

ANOVA

Libido

			Sum of Squares	df	Mean Square	F	Sig.
Between Groups	(Combined)		20.133	2	10.067	5.119	.025
	Linear Term	Contrast	19.600	1	19.600	9.966	.008
		Deviation	.533	1	.533	.271	.612
	Quadratic Term	Contrast	.533	1	.533	.271	.612
Within Groups			23.600	12	1.967		
Total			43.733	14			

الخرج 5.8

بمعرفة أن الأثر الكلي لـــ Viagra كان مهماً، يمكننا أن ننظر الآن إلى تحليل المنحى. يقسم تحليل المنحى الأثر التجريبي لمعرفة فيما إذا كان ممكناً تفسيره بعلاقة خطية أو تربيعية في البيانات. لننظر أولاً إلى المكون الخطي. تختبر هذه المقارنة فيما إذا كانت قيم المتوسط تزداد عبر المجموعات بطريقة خطية. لدينا مجموع المربعات ومتوسط المربعات، ولكن القيم الأكثر أهمية التي يجب ملاحظتها هي قيمة النسبة F وقيمة مستوى الدلالة الموافقة. بالنسبة للمنحى الخطي فإن قيمة النسبة F هي 9.97 وهذه القيمة ذات دلالة عند مستوى 0.008 لذلك يمكننا أن نقول أنه عند زيادة جرعة Viagra من لا شيء إلى جرعة منخفضة ثم جرعة مرتفعة فإن مستوى الشهوة يزداد بشكل متناسب. عند الانتقال إلى المنحى التربيعي فإن هذه المقارنة تختبر فيما إذا كان نمط القيم المتوسطة منحنياً (أي ممثلاً بمنحني ذي ميل واحد). يقترح مخطط أعمدة الخطأ للبيانات أنه لا يمكن تمثيل قيم المتوسط بمنحني، وتثبت نتائج المنحى التربيعي صحة ذلك. إن قيمة النسبة F للمنحى التربيعي ليست ذات دلالة (تبلغ قيمة F أقل من 1 وهذا يعني بشكل مباشر أن هذه المقارنة لن تكون مهمة أو ذات دلالة).

وأخيراً، يعرض (الخرج 6.8) النسب F لكل من Brown-Farsythe وWelch. وكما اتضح فإننا لا نحتاج هذه النسب لأن اختبار Levene بدون دلالة مما يشير إلى أن التباينات متساوية. على كل حال، عندما يتم خرق فرضية تجانس التباين فإنه يجب أن ننظر إلى قيم F بدلاً من القيم الموجودة في الجدول الرئيسي. إذا كنت مهتماً بكيفية حساب هذه القيم فيمكنك العودة للمربع 3.8 والملحق A5.

Robust Tests of Equality of Means

Libido

	Statistic[a]	df1	df2	Sig.
Welch	4.320	2	7.943	.054
Brown-Forsythe	5.119	2	11.574	.026

a. Asymptotically F distributed.

الخرج 6.8

2.4.8 الخرج للمقارنات المنظمة

لقد طلبنا في الفقرة 1.3.8 من برنامج SPSS أن يقوم بمقارنتين، الأولى لاختبار فيما إذا كانت مجموعة المراقبة مختلفة عن المجموعتين اللتين تناولتا الدواء Viagra، والثانية لمعرفة فيما إذا كانت الجرعتان المختلفتان من Viagra تعطيان فرقاً في الشهوة. يعرض الخرج 7.8 نتائج المقارنات المنظمة التي طلبناها لبيانات Viagra. يعرض الجدول الأول معاملات المقارنة، وهي القيم التي أدخلناها في الفقرة 1.3.8، ومن المهم النظر إلى هذا الجدول للتأكد من أن المقارنات تقارن فعلاً ما هو مطلوب منها. وكقاعدة عامة، تذكر أنه عند القيام بمقارنات منظمة فإننا نقوم بترتيب الأثقال بحيث نقارن أية مجموعة ذات ثقل موجب مع أية مجموعة ذات ثقل سالب. لذلك فإن جدول الأثقال يبين أن المقارنة الأولى تقارن مجموعة الدواء التمويهي مع المجموعتين التجريبيتين، والمقارنة الثانية تقارن مجموعة الجرعة المنخفضة مع مجموعة الجرعة المرتفعة. من المفيد أيضاً التحقق في هذا الجدول من أن الأثقال التي تم إدخالها في برنامج SPSS توافق الأثقال التي نريد فعلاً إدخالها في البرنامج.

Contrast Coefficients

	Dose of Viagra		
Contrast	Placebo	Low Dose	High Dose
1	-2	1	1
2	0	-1	1

Contrast Tests

		Contrast	Value of Contrast	Std. Error	t	df	Sig. (2-tailed)
Libido	Assume equal variances	1	3.8000	1.53623	2.474	12	.029
		2	1.8000	.88694	2.029	12	.065
	Does not assume equal variances	1	3.8000	1.48324	2.562	8.740	.031
		2	1.8000	.91652	1.964	7.720	.086

الخرج 7.8

يعطي الجدول الثاني الإحصائيات لكل مقارنة، وأول ما يجب ملاحظته هو أن الإحصائيات تنتج للأوضاع التي تكون فيها تباينات المجموعات متساوية، وعندما تكون غير متساوية. إذا كان اختبار Levene ذا دلالة فيجب عليك أن تقرأ النتائج في القسم المسمى Does not assume equal variances في الجدول. وبالنسبة لبيانات Viagra فإن اختبار Levene لم يكن ذا دلالة لذلك نقرأ النتائج الموجودة في القسم المسمى Assume equal variances. يعطي الجدول قيمة المقارنة ذاتها وهي المجموع المثقّل لقيم المتوسط للمجموعات. ونحصل على هذه القيمة بأخذ المتوسط لكل مجموعة وضربها بالثقل للمقارنة المعنية ثم جمع هذه الجداءات معاً (من أجل المقارنة الأولى فإن هذه القيمة هي: $\Sigma(\overline{X}W) = [(2.2 \times -2) + (3.2 \times 1) + (5.0 \times 1)] = 3.8$). يعطي هذا الجدول أيضاً الخطأ المعياري لكل مقارنة والإحصائية t. يتم اشتقاق الإحصائية t بتقسيم قيمة المقارنة على الخطأ المعياري

(t=3.8/1.5362=2.47) ومقارنته بالقيم الحرجة للتوزيع t. يحوي العمود الأخير قيمة الدلالة للمقارنة وهي القيمة للاحتمال ثنائي الطرف. لنأخذ المقارنة الأولى كمثال، إذا استخدمنا هذه المقارنة لاختبار الفرضية العامة بأن المجموعات التجريبية ستختلف عن مجموعة الدواء التمويهي فيجب علينا استخدام قيمة الاحتمال ثنائي الطرف. على كل حال، نحن نختبر الفرضية بأن المجموعات التجريبية ستزيد الشهوة لمستويات أعلى مما نجده في مجموعة الدواء التمويهي، وهذه الفرضية وحيدة الطرف. إن قيم المتوسط للمجموعات تثبت صحة هذه الفرضية ولذلك نقسم قيم الدلالة على 2 للحصول على الاحتمال وحيد الطرف. فمن أجل المقارنة الأولى يمكننا أن نقول أن تناول Viagra يزيد الشهوة بشكل كبير مقارنة مع مجموعة المراقبة (p=0.0145). ومن أجل المقارنة الثانية، لدينا فرضية وحيدة الطرف (وهي أن الجرعة المرتفعة من Viagra تزيد الشهوة بشكل كبير مقارنة مع الجرعة المنخفضة) وتثبت قيم المتوسط هذه الفرضية. تدل قيم الدلالة للمقارنة الثانية على أن الجرعة المرتفعة من Viagra تزيد الشهوة أكثر من الجرعة المنخفضة (p=0.065/2=0.0325). لاحظ أنه ليست لدينا فرضية معينة تحدد المجموعة التي ستملك المتوسط الأعلى ولذلك كان علينا أن نستنتج أنه ليس لجرعة Viagra أثر مهم على الشهوة. ولهذا السبب فمن المهم توليد الفرضيات قبل جمع البيانات لأن هذه الطريقة في الاكتشاف العلمي هي أكثر فعالية.

ونلخص ما سبق بالقول أن هناك أثراً كلياً للدواء Viagra على الشهوة. وقد أظهرت المقارنات المنظمة أن تناول Viagra يزيد الشهوة بشكل كبير مقارنة مع مجموعة المراقبة t(12)=2.47, p<0.05، وإن تناول جرعة مرتفعة من Viagra يزيد الشهوة بشكل كبير مقارنة مع الجرعة المنخفضة t(12)=2.03, p<0.05.

3.4.8 الخرج لاختبارات post hoc

إذا لم تكن لدينا فرضيات محددة بخصوص أثر Viagra على الشهوة فإنه يمكننا تنفيذ الاختبارات post hoc لمقارنة جميع مجموعات المشتركين مع بعضها البعض. لقد قمنا في الفقرة 2.3.8 بطلب هذه الاختبارات من برنامج SPSS، وتظهر نتائج هذا التحليل في الخرج 8.8. يعرض الجدول نتائج اختبار Tukey (المعروف بالرمز Tukey´s HSD وهي اختصار Honestly Significant Difference) والإجرائية Games-Howell واختبار Dunnett التي تم تحديدها سابقاً. إذا نظرنا أولاً على اختبار Tukey (لعدم وجود سبب يدفعنا للشك بأن تباينات المجتمع غير متساوية) فمن الواضح من الجدول أنه تتم مقارنة المشتركين في كل مجموعة مع بقية المجموعات. فمن أجل كل زوج من المجموعات، يتم عرض الفرق بين قيم المتوسط للمجموعتين والخطأ المعياري ومستوى الدلالة لذلك الفرق ومجال الثقة 95%. تمت في البداية مقارنة مجموعة الدواء التمويهي مع مجموعة الجرعة المنخفضة وقد تبين أن الفرق غير مهم (الدلالة .Sig أكبر من 0.05) ولكن عند مقارنتها مع مجموعة الجرعة المرتفعة فإن هناك فرقاً مهماً (الدلالة .Sig أصغر من 0.05). إن هذه النتيجة مهمة

لأن المقارنة المنظمة أظهرت أن أية جرعة من Viagra تعطي زيادة ملحوظة في الشهوة، مع أن هذه المقارنة قد أظهرت أنه ليس للجرعة المنخفضة ذلك الأثر. لماذا ظهرت هذه المفارقة؟ (فكّر بهذا السؤال قبل متابعة القراءة).

لقد شرحنا في الفقرة 2.10.2.8 أن المقارنة المنظمة الأولى ستقارن المجموعات التجريبية مع مجموعة الدواء التمويهي. وستقوم بشكل خاص بمقارنة متوسط المجموعتين التجريبيتين ((3.2+5.0)/2=4.1) مع متوسط مجموعة الدواء التمويهي (2.2). لذلك فهي تقيّم فيما إذا كان الفرق بين هذه القيم (4.1-2.2=1.9) كبيراً أم لا. في اختبارات post hoc، وعندما تتم مقارنة مجموعة الجرعة المنخفضة مع مجموعة الدواء التمويهي فإن المقارنة تختبر فيما إذا كان الفرق بين قيم المتوسط لهاتين المجموعتين ذو دلالة. إن الفرق في هذه الحالة يساوي 1 فقط مقارنة مع الفرق 1.9 للمقارنة المنظمة الأولى. يوضح هذا الشرح كيف يكون ممكناً وجود نتائج متعارضة ظاهرياً بين المقارنات المنظمة والمقارنات post hoc. والأهم من ذلك، أنه يبين مدى أهمية الحذر عند تفسير المقارنات المنظمة.

تتم بعد ذلك مقارنة مجموعة الجرعة المنخفضة مع كل من مجموعة الدواء التمويهي ومجموعة الجرعة المرتفعة: إن أول ما يجب ملاحظته هو أن المقارنة التي تتضمن مجموعة الجرعة المنخفضة ومجموعة الدواء التمويهي مماثلة للمقارنة التي تم وصفها سابقاً. والمعلومة الجديدة الوحيدة هي المقارنة بين الحالتين التجريبيتين. تختلف قيم المتوسط للمجموعات بمقدار 1.8 وهو فرق غير مهم. وتتعارض هذه النتيجة مع المقارنات المنظمة (تذكر أن المقارنة الثانية تقارن هاتين المجموعتين وقد عَثَرت على فرق مهم). لماذا نجد مثل هذا التعارض؟. إن الاختبارات post hoc ثنائية الطرف بطبيعتها (نستخدمها عندما لا نضع فرضيات محددة، ولا يمكننا التنبؤ باتجاه الفرضيات غير الموجودة!). وكانت المقارنة الثانية ذات دلالة فقط عندما اعتبرناها كفرضية وحيدة الطرف. على كل حال، حتى على المستوى ثنائي الطرف فإن المقارنة المنظمة كانت أقرب للدلالة من الاختبار post hoc، وتوضح هذه الحقيقة أن إجرائيات post hoc أكثر صرامة (تتمتع بقدرة أقل على اكتشاف الآثار الحقيقية) من المقارنات المنظمة.

ويصف بقية الجدول اختبار Games-Howell، ويكشف التفتيش السريع نفس النمط من النتائج، فالمجموعات الوحيدة التي تختلف بشكل كبير هي مجموعات الجرعة المرتفعة والدواء التمويهي. وتعطينا هذه النتائج الثقة في استنتاجاتنا من اختبار Tukey لأنه إذا كانت تباينات المجتمعات غير متساوية (ويبدو ذلك غير محتمل لأننا نعلم أن تباينات العينات متشابهة جداً). فإن شكل النتائج سيبقى صحيحاً. وأخيراً يتم وصف اختبار Dunnett، ولنتذكر أننا طلبنا من البرنامج مقارنة المجموعتين التجريبيتين مع مجموعة المراقبة باستخدام فرضية وحيدة الطرف تنص على أن متوسط مجموعة المراقبة سيكون أصغر من المتوسط للمجموعتين التجريبيتين. وحتى لو كانت الفرضية وحيدة الطرف فإن مستويات الشهوة في مجموعة الجرعة المنخفضة مكافئة لمجموعة الدواء التمويهي. على كل حال، لمجموعة الجرعة المرتفعة مستوى شهوة أعلى بكثير من مجموعة الدواء التمويهي.

Multiple Comparisons

Dependent Variable: Libido

	(I) Dose of Viagra	(J) Dose of Viagra	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
Tukey HSD	Placebo	Low Dose	-1.0000	.88694	.516	-3.3662	1.3662
		High Dose	-2.8000*	.88694	.021	-5.1662	-.4338
	Low Dose	Placebo	1.0000	.88694	.516	-1.3662	3.3662
		High Dose	-1.8000	.88694	.147	-4.1662	.5662
	High Dose	Placebo	2.8000*	.88694	.021	.4338	5.1662
		Low Dose	1.8000	.88694	.147	-.5662	4.1662
Games-Howell	Placebo	Low Dose	-1.0000	.82462	.479	-3.3563	1.3563
		High Dose	-2.8000*	.91652	.039	-5.4389	-.1611
	Low Dose	Placebo	1.0000	.82462	.479	-1.3563	3.3563
		High Dose	-1.8000	.91652	.185	-4.4389	.8389
	High Dose	Placebo	2.8000*	.91652	.039	.1611	5.4389
		Low Dose	1.8000	.91652	.185	-.8389	4.4389
Dunnett t (>control)a	Placebo	High Dose	-2.8000	.88694	.999	-4.6697	
	Low Dose	High Dose	-1.8000	.88694	.992	-3.6697	

*. The mean difference is significant at the .05 level.

a. Dunnett t-tests treat one group as a control, and compare all other groups against it.

الخرج 8.8

يعرض الجدول المبين في الخرج 9.8 نتائج اختبار Tukey واختبار REGWQ. تعرض هذه الاختبارات مجموعات فرعية من المجموعات ذات نفس المتوسط. ولذلك ينشئ اختبار Tukey مجموعتين فرعيتين من المجموعات مع قيم للمتوسط متماثلة إحصائياً. تحوي المجموعة الفرعية الأولى مجموعة الدواء التمويهي ومجموعة الجرعة المنخفضة (لأن لهاتين المجموعتين متوسطات متشابهة) بينما تحوي المجموعة الفرعية الثانية مجموعة الجرعة المنخفضة ومجموعة الجرعة المرتفعة. وتوضح هذه النتائج أن لمجموعة الدواء التمويهي متوسطاً مشابهاً لمجموعة الجرعة المنخفضة ولكن غير مشابه لمجموعة الجرعة المرتفعة، وأن لمجموعة الجرعة المنخفضة متوسطاً مشابهاً لمجموعتي الدواء التمويهي والجرعة المرتفعة. وبعبارة أخرى، المجموعات الوحيدة التي لها متوسطات مختلفة بشكل كبير هي مجموعة الدواء التمويهي ومجموعة الجرعة المرتفعة. توفر هذه الاختبارات قيمة دلالة لكل من المجموعات الفرعية، ومن الواضح من قيم الدلالة تلك أن المجموعات في المجموعات الفرعية لها قيم متوسطة بدون دلالة (كما تدل قيم .Sig>0.05).

تستخدم هذه الحسابات حجم العينة للمتوسط التوافقي. والمتوسط التوافقي (Harmonic mean) هو نسخة مثقّلة من المتوسط تأخذ بعين الاعتبار العلاقة بين التباين وحجم العينة. ومع أنك غير مضطر لمعرفة تفاصيل المتوسط التوافقي، فمن المفيد استخدام حجم العينة التوافقي لأنه يلغي أي أثر قد يدخل عبر أحجام العينات غير المتساوية. ولذلك فإن ANOVA وحيد الاتجاه يوفر نتائج موثوقة حتى في التصاميم غير المتوازنة.

Libido

	Dose of Viagra	N	Subset for alpha = .05	
			1	2
Tukey HSD[a]	Placebo	5	2.2000	
	Low Dose	5	3.2000	3.2000
	High Dose	5		5.0000
	Sig.		.516	.147
Ryan-Einot-Gabriel-Welsch Range	Placebo	5	2.2000	
	Low Dose	5	3.2000	3.2000
	High Dose	5		5.0000
	Sig.		.282	.065

Means for groups in homogeneous subsets are displayed.

a. Uses Harmonic Mean Sample Size = 5.000.

الخرج 9.8

أفكار مهمة

- يقارن ANOVA المستقل وحيد الاتجاه عدة قيم للمتوسط لمجموعات مختلفة من الناس، كحالة تجارب متعددة واستخدام مشتركين مختلفين في كل حالة تجريبية.
- استخدم المقارنات المنظمة إذا قمت بوضع فرضيات قبل التجربة، أما إذا لم تكن لديك فرضيات محددة فاستخدم الاختبارات post hoc.
- هناك مجموعة من اختبارات post hoc المختلفة. استخدم REGWQ أو Tukey HSD إذا كانت أحجام العينات متساوية وتتحقق فرضية تجانس التباين. استخدم Gabriel إذا كانت أحجام العينات مختلفة قليلاً، واستخدم Hochberg's GT2 إذا كانت أحجام العينات مختلفة كثيراً. إذا كان هناك أي شك حول تجانس التباين استخدم إجرائية Games-Howell.
- يتم اختبار تجانس التباين باختبار Levene. إذا كانت القيمة في العمود المسمى Sig. أقل من 0.05 فإن الفرضية غير محققة. ابحث في هذه الحالة عن الجدول المسمى Robust Test of Equality of Means. إذا تحقق تجانس التباين (قيمة الدلالة لاختبار Levene أكبر من 0.05) ابحث عن الجدول المسمى ANOVA.
- ابحث في الجدول المسمى ANOVA (أو الجدول Robust Test of Equality of Means - أنظر الفكرة السابقة) عن العمود المسمى Sig.، فإذا كانت القيمة أقل من 0.05 فإن قيم المتوسط للمجموعات مختلفة بشكل كبير.
- ومن أجل المقارنات واختبارات post hoc، ابحث مرة أخرى في العمود المسمى Sig. لاكتشاف فيما إذا كانت المقارنات ذات دلالة (ستكون كذلك إذا كانت قيمة الدلالة أقل من 0.05).

5.8 حساب حجم الأثر

ربما لاحظت أن برنامج SPSS لا يقدم حجم الأثر لتقنية ANOVA المستقلة وحيدة الاتجاه. على كل حال، رأينا في المعادلة (4.5) أن:

$$r^2 = \frac{SS_M}{SS_T}$$

ونعرف هذه القيم من الخرج لبرنامج SPSS، لذلك يمكننا ببساطة حساب r^2 باستخدام الأثر بين المجموعات (SS_M) والمقدار الكلي للتباين في البيانات (SS_T)، ويدعى هذا المقدار أحياناً إيتا مربع η^2. ثم يتم بعد ذلك حساب الجذر التربيعي للمقدار r^2 للحصول على حجم الأثر r:

$$r^2 = \frac{SS_M}{SS_T} = \frac{20.13}{43.73} = 0.42$$

$$r = \sqrt{0.42} = 0.65$$

باستخدام معايير حجم الأثر، فإن هذه القيمة تمثل كبيراً (إنها أكبر من العتبة 0.5 للأثر الكبير). ولذلك فإن أثر Viagra على الشهوة هو نتيجة فعلية.

على كل حال، إن هذا القياس لحجم الأثر منحاز قليلاً لأنه يعتمد بشكل تام على مجاميع المربعات من العينة و لم يخضع لعمليات تعديل تأخذ بعين الاعتبار محاولتنا تقدير حجم الأثر في المجتمع. لذلك فإننا نستخدم غالباً قياساً أكبر تعقيداً يدعى أوميغا مربع ω^2. ومع أن تقدير حجم الأثر هذا مازال يعتمد على مجاميع المربعات التي قابلناها في هذا الفصل فإنه كالنسبة F يستخدم التباين المبرر من قبل النموذج وتباين الخطأ (وفي كلتا الحالتين يتم استخدام التباين المتوسط أو متوسط مربع الخطأ):

$$\omega^2 = \frac{SS_M - (df_M)MS_R}{SS_T + MS_R}$$

يمثل df_M في هذه المعادلة عدد درجات الحرية للأثر والذي يمكن الحصول عليه من خرج البرنامج SPSS (في حالة الأثر الرئيسي يكون أقل بواحد من عدد الحالات التجريبية). لذلك ومن أجل هذا المثال لدينا:

$$\omega^2 = \frac{20.13 - 2 \times 1.97}{43.73 + 1.97} = \frac{16.19}{45.70} = 0.35$$

$$\omega = \sqrt{0.35} = 0.60$$

وكما نرى فإن ذلك قادنا إلى تقدير أعلى قليلاً من r، وبشكل عام فإن ω هو مقياس أكثر دقة من r. ومع أننا نستخدم ω في الفقرات الخاصة بتقنية ANOVA كمقياس لحجم الأثر، فإننا نأخذه كالقيمة r ونطبق عليه نفس المعايير للحكم على حقيقة أثر معين.

في معظم الأحيان لا يكون مهماً معرفة حجم الأثر لـــ ANOVA الكلي لأنه يختبر فرضية عامة. وما يهمنا هو حجم الأثر للمقارنات (لأنها تقارن مجموعتين فقط ولذلك فإن تفسير حجم الأثر يكون أسهل بكثير). تم اختبار المقارنات المنظمة بالإحصائية t ولذلك يمكننا استخدام نفس المعادلة كما في الفقرة 5.5.7:

$$r_{contrast} = \sqrt{\frac{t^2}{t^2 + df}}$$

ونعرف قيمة t و df من الخرج 7.8 لذلك يمكننا حساب r كما يلي:

$$r_{contrast1} = \sqrt{\frac{2.474^2}{2.474^2 + 12}} = \sqrt{\frac{6.12}{18.12}} = 0.58$$

إذا عدنا لمعايير حجم الأثر فإن هذه القيمة تمثل أثراً كبيراً (القيم التي تكون أعلى من العتبة 0.05 للأثر الكبير). لذلك ومع كونه ذو دلالة إحصائية فإن هذا الأثر كبير ويمثل نتيجة واقعية. ومن أجل المقارنة الثانية نجد:

$$r_{contrast2} = \sqrt{\frac{2.029^2}{2.029^2 + 12}} = \sqrt{\frac{4.12}{16.12}} = 0.51$$

وهذه نتيجة واقعية أيضاً وتمثل حجم أثر كبير.

6.8 تقديم نتائج ANOVA وحيد الاتجاه المستقل

عند تقديم نتائج ANOVA علينا أن نعطي تفاصيل النسبة F وعدد درجات الحرية التي تم حساب النسبة منها. فمن أجل الأثر التجريبي في هذه البيانات، لقد تم اشتقاق النسبة F من تقسيم متوسط المربعات للأثر على مربع المتوسطات للبواقي. ولذلك فإن عدد درجات الحرية المستخدم لتقييم النسبة F هو عدد درجات الحرية للأثر في النموذج (df_M=2) وعدد درجات الحرية للبواقي في النموذج (df_R=12). ولذلك فإن الطريقة الصحيحة لتقديم النتيجة الأساسية هي:

- ✓ هناك أثر مهم للدواء Viagra على مستويات الشهوة $F(2,12)=5.12, p<0.05, \omega=0.60$.

لاحظ أن قيمة F متبوعة بقيم درجات الحرية لذلك الأثر. ونادراً ما نذكر القيمة الدقيقة للدلالة من أجل النسبة F، وعوضاً عن ذلك نذكر أن قيمة الدلالة p هي أصغر من المعيار 0.05 كما نضع قيمة حجم الأثر. يمكن تقديم المقارنة الخطية بطريقة مشابهة:

- ✓ هناك منحى خطي مهم $F(1,12)=9.97, p<0.01, \omega=0.62$ يدل على أنه عند زيادة جرعة Viagra تزداد الشهوة بشكل متناسب.

لاحظ أن عدد درجات الحرية قد تغير ليعكس كيفية حساب النسبة F. وذكرنا أيضاً قيمة حجم الأثر (حاول حساب هذه القيمة بإتباع الطريقة التي استخدمناها من أجل النسبة F الرئيسية). لقد ذكرنا أن قيمة F كانت ذات دلالة عند قيمة أدنى من قيمة المعيار 0.01. يمكننا أيضاً تقديم المقارنات المنظمة بالشكل التالي:

- ✓ أظهرت المقارنات المنظمة أن تناول أي جرعة من Viagra يزيد الشهوة بشكل ملحوظ مقارنة مع تناول الدواء التمويهي: r=0.58 ,(وحيد الطرف) t(12)=2.47, p<0.05، وأن تناول جرعة مرتفعة يزيد الشهوة بشكل ملحوظ مقارنة مع الجرعة المنخفضة: r=0.51، (وحيد الطرف) t(12)=2.03, p<0.05.

لاحظ أننا ذكرنا استخدام الاحتمال وحيد الطرف في الحالتين.

7.8 خرق الفرضيات في ANOVA وحيد الاتجاه المستقل

ذكرنا عدة مرات في هذا الفصل أن ANOVA قوي مقاوم لخرق الفرضيات. وقد رأينا أن هناك عدة إجراءات يمكن اتخاذها عند وجود عدم تجانس في التباين (المربع 3.8). على كل حال، هناك طريقة بديلة. توجد مجموعة من الاختبارات (تدعى عادة بإحدى التسميات التالية: الاختبارات الخالية من الفرضيات، الخالية من التوزيع، اللابارامترية، وجميعها تسميات غير دقيقة). هناك اختبار لابارامتري يقابل ANOVA يدعى اختبار Kruskal-Wallis. إذا كانت البيانات غير موزعة طبيعياً أو أنها تخرق بعض الفرضيات الأخرى فيمكنك استخدام هذا الاختبار لحل المشكلة. سيتم وصف هذا الاختبار في الفصل 13.

8.8 ما الذي اكتشفناه عن الإحصاء؟

قدم هذا الفصل تحليل التباين (ANOVA) وهو موضوع الفصول القادمة أيضاً. يتم استخدام ANOVA وحيد الاتجاه المستقل في الحالات التي نريد فيها مقارنة عدة قيم للمتوسط، وقد تم جمع البيانات باستخدام مشتركين مختلفين في كل حالة. لقد بدأنا الفصل بشرح الحالة التي يتم فيها تنفيذ عدة اختبارات t على نفس البيانات مما يؤدي لتضخيم معدل الخطأ من النوع الأول، ولذلك نستخدم ANOVA. وبحثنا في كيفية النظر إلى ANOVA كنموذج خطي عام (GLM) وكذلك كتراجع متعدد. وكما في حالة التراجع المتعدد فإن هناك ثلاثة قياسات هامة يجب أن نستخدمها في ANOVA: المجموع الكلي للمربعات SS_T (قياس التغايرية في البيانات) ومجموع المربعات للنموذج SS_M (قياس الجزء من التغايرية الذي يمكن تبريره بالتلاعب التجريبي) ومجموع المربعات للبواقي SS_R (قياس الجزء من التغايرية الذي لا يمكن تبريره بالتلاعب التجريبي). وقد اكتشفنا أن النسبة F هي نسبة التباين الذي يمكن تبريره إلى التباين الذي لا يمكن تبريره. كما اكتشفنا أن قيمة النسبة F ذات الدلالة تدلنا فقط على وجود اختلاف بين المجموعات، وليس على كيفية اختلافها. ولإيجاد مواقع الخلاف هناك خياران: تحديد مقارنات معينة لاختبار الفرضيات (المقارنات المنظمة) أو اختبار كل مجموعة مقابل بقية المجموعات الأخرى (اختبارات post hoc). تُستخدم الاختبارات الأولى عندما نقوم بوضع فرضيات قبل التجربة، بينما تُستخدم الاختبارات الأخيرة لاستكشاف البيانات عند عدم وجود فرضيات معينة. وأخيراً اكتشفنا كيفية تنفيذ هذه الإجرائيات في برنامج SPSS.

9.8 المصطلحات الأساسية التي اكتشفناها

تحليل التباين ANOVA	(Analysis of variance)
تصحيح Bonferroni	(Bonferroni correction)
النسبة Brown-Forsythe F	(Brown-Forsythe F)
المنحى التكعيبي	(Cubic trend)
درجات الحرية	(Degrees of freedom)
مقارنة التباعد	(Deviation contrast)
مقارنة الفرق	(Difference contrast)
معدل الخطأ حسب التجربة	(Experimentwise error rate)
معدل الخطأ حسب العائلة	(Familywise error rate)
التباين الكلي	(Grand variance)
المتوسط التوافقي	(Harmonic mean)
مقارنة Helmert	(Helmert contrast)
تحليل التباين المستقل	(Independent ANOVA)
أوميغا مربع	(Omega squared)
متعامد	(Orthogonal)
المقارنات الثنائية	(Pairwise comparisons)
المقارنات المنظمة	(Planned contrasts)
المقارنة كثيرة الحدود	(Polynomial contrast)
اختبارات post hoc	(Post hoc tests)
المنحى التربيعي	(Quadratic trend)
المنحى الرباعي	(Quartic trend)
المقارنة المكررة	(Repeated contrast)
المقارنة البسيطة	(Simple contrast0)
الأثقال	(Weights)
النسبة Welch F	(Welch F)

10.8 مهمات يجب تنفيذها

- **المهمة الأولى:** تخيل أننا نهتم في كيفية تأثير طرق التدريس المختلفة على تعلّم الطلاب. نلاحظ أن بعض المحاضرين متحفظون ومتعجرفون في أسلوب تدريسهم، يهينون أي طالب يتجرأ على سؤالهم، بينما يشجع الآخرون طرح الأسئلة والتعليقات. لقد قام أحد المدرسين لمادة الإحصاء باختيار ثلاث مجموعات من الطلاب. اعتمد مع المجموعة الأولى أسلوب العقاب (punish) حيث كان يعاقب كل طالب يطرح سؤالاً سخيفاً أو خاطئاً. واعتمد مع المجموعة الثاني أسلوب المكافأة (reward) حيث كان يشجع الطلاب على مناقشة الأفكار الصعبة ويكافئ من يقوم بعمل جيد. أما المجموعة الثالثة فكان لا يبالي بها (indifferent) حيث لم يعاقب أو يكافئ أحداً. وقد اعتمد علامات الامتحان (percentage) كمتحول تابع، واعتماداً على نظريات التكيف فإننا نتوقع أن يكون العقاب طريقة غير ناجحة في تعزيز التعلم على عكس المكافأة التي ستكون طريقة ناجحة جداً. لذلك فإن أحد التوقعات هو أن تعطي المكافأة أفضل تعليم. والفرضية الثانية هي أن العقاب سيؤخر التعلّم عملياً وأنه أسوأ من طريقة اللامبالاة في التعليم. يحوي الملف Teach.sav بيانات هذه المهمة. ينبغي عليك تنفيذ ANOVA وحيد الاتجاه واستخدام المقارنات المنظمة لاختبار الفرضيات التالية: 1- تؤدي المكافأة إلى أفضل النتائج في الامتحان مقارنة مع العقاب أو اللامبالاة. 2- تؤدي اللامبالاة إلى نتائج أفضل بشكل ملموس مما يعطيه أسلوب العقاب.
- **المهمة الثانية:** تحوي الفقرة 4.13 (الفصل 13) بعض البيانات التي تبحث فيما إذا كان تناول وجبات الصويا يقلل عدد الحيوانات المنوية. ادرس تلك الفقرة وحلل بيانات المثال الموجود فيها باستخدام ANOVA. ما الفرق بين النتائج التي حصلت عليها وما تجده في الفقرة 4.13؟ ولماذا ظهر هذا الفرق برأيك؟
- **المهمة الثالثة:** يحب الطلاب (والمدرسون) هواتفهم المحمولة، وهو أمر مقلق بسبب الجدل حول العلاقة بين استخدام الهاتف والمحمول وأورام المخ. وتتلخص الفكرة الأساسية بأن الهاتف المحمول يرسل أمواجاً ميكروية، ولذلك فإن وضعها بجوار المخ لفترات طويلة من اليوم يشبه لصق المخ بفرن ميكروي الأمواج وضغط الزر "الطبخ حتى اكتمال الطهي". إذا أردنا اختبار ذلك تجريبياً فإنه يمكننا أن نأخذ 6 مجموعات من الأشخاص ونلصق هاتفاً محمولاً على رأس كل شخص بحيث لا يمكنه نزعه. نقوم بعد ذلك بتشغيل أجهزة الهاتف لمدة معينة في كل يوم. نقيس بعد 6 أشهر حجم الورم (mm^3) في المنطقة القريبة من هوائي الهاتف (خلف الأذن تماماً). تخضع المجموعات التجريبية لمدة 0 و1 و2 و3 و4 و5 ساعات يومياً لمدة 6 أشهر. يحوي الملف Tumour.sav هذه البيانات.

يحوي الملف Answers(Chapter 8).pdf الإجابات على هذه المهمات.

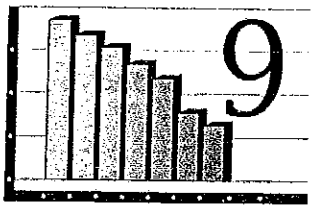

تحليل التباين المشترك ANCOVA (GLM2)

1.9 ماذا يخبرنا هذا الفصل

رأينا في الفصل السابق كيف يمكننا توصيف تحليل التباين وحيد الاتجاه (ANOVA) بشكل معادلة تراجع متعدد تستخدم متحولات مزيفة لترميز عضوية المجموعة. ورأينا في الفصل 5 كيف يمكن تضمين عدة متحولات تنبؤية مستمرة في التراجع المتعدد. لذلك يجب أن لا يكون مفاجئاً توسيع معادلة التراجع التي تمثل ANOVA لتشمل متحولاً أو عدة متحولات مستمرة يمكنها التنبؤ بالنتيجة (أو المتحول التابع). تدعى مثل هذه المتحولات المستمرة، التي لا تكون جزءاً من التلاعب التجريبي الرئيسي ولكن يمكنها التأثير على المتحول التابع، بالمتغيرات المشتركة (Covariates) ويمكن تضمينها في تحليل التباين ANOVA. عند قياس المتغيرات المشتركة وتضمينها في تحليل التباين فإننا ندعوه تحليل التباين المشترك (analysis of covariance) أو اختصاراً ANCOVA. يركز هذا الفصل على هذه التقنية. وسنبدأ بإلقاء نظرة على نظرية تحليل التباين المشترك (لن ندخل بالتفاصيل المعمقة) وعلى حقيقة أن هناك فرضية إضافية يجب أن نأخذها بعين الاعتبار (تجانس انحدارات التراجع). كما سندرس كيفية تنفيذ مثال في برنامج SPSS ونتعلم تفسير النتائج وتقديمها عند استخدام هذه التقنية.

2.9 ما هو تحليل التباين المشترك ANCOVA؟

استخدمنا في الفصل السابق مثالاً يبحث في آثار Viagra على الشهوة الجنسية. لنفكر بأشياء أخرى غير Viagra يمكنها أن تؤثر على تلك الشهوة. ومن الأشياء البديهية يمكن نأخذ الشهوة الجنسية لشريك المشترك، ولكن هناك أشياء أخرى أيضاً كالأدوية التي تكبت الشهوة (كالحبوب المضادة للاكتئاب وحبوب منع الحمل) والتعب. إذا تم قياس هذه المتحولات (أو المتغيرات المشتركة (Covariates)) يصبح من الممكن التحكم بتأثيرها على المتحول التابع وذلك بتضمينها في نموذج التراجع. ومما نعرفه عن التراجع المنطقي (انظر الفصل 5) يجب أن يكون واضحاً أنه إذا أدخلنا المتغير المشترك في نموذج التراجع أولاً، ثم أدخلنا المتحولات المزيفة التي تمثل التلاعب التجريبي فإنه

يمكننا أن نعرف الأثر الذي يملكه متحول مستقل بعد أثر المتغير المشترك. وهكذا نتحكم بأثر المتغير المشترك. هناك سببان لتضمين المتغيرات المشتركة في ANOVA:

- **تقليص تباين الخطأ ضمن المجموعة:** عند مناقشة ANOVA واختبارات t تعودنا على فكرة أن نقيّم أثر التجربة بمقارنة مقدار التغايرية في البيانات والتي يمكن أن تبررها التجربة مع التغايرية التي لا يمكنها أن تبررها. إذا استطعنا تفسير جزء من التباين غير المبرر (SS_R) بدلالة متحولات أخرى (المتغيرات المشتركة) فإننا نقلل تباين الخطأ مما يسمح لنا بتقييم أدق لأثر المتحول المستقل (SS_M).
- **إلغاء العوامل المربكة:** في تجربة ما، قد تكون هناك متحولات غير مقاسة تُشوّش النتائج (كالمتحولات التي تتغير بشكل منهجي مع التلاعب التجريبي). إذا تم قياس أي متحولات معروفةٍ بتأثيرها على المتحول التابع فإن تحليل التباين المشترك (ANCOVA) يكون مثالياً في التخلص من تأثير هذه المتحولات. بعد تحديد متحول مُربِك محتمل، يمكن عندئذٍ قياسه وإدخاله في التحليل كمتغير مشترك.

هناك أسباب أخرى لتضمين المتغيرات المشتركة في ANOVA، ولكن بما أننا لن ندخل في طريقة حساب ANCOVA فإننا ننصح القارئ المهتم بمراجعة أحد المرجعين Wildt & Ahtola (1978) أو Stevens (1992).

تخيل أن الباحث الذي قام بدراسة أثر Viagra في الفصل السابق اكتشف فجأة أن الشهوة الجنسية للشريك ستؤثر على الشهوة الجنسية للمشترك ذاته. ولذلك فقد كرر الدراسة على مجموعة مختلفة من المشتركين، وقام في هذه المرة بقياس الشهوة للشريك وذلك بدلالة كيفية محاولة البدء بالعلاقة الجنسية. رأينا في الفصل السابق أنه يمكن توصيف هذا السيناريو للتجربة باستخدام المعادلة (2.8). لنعد إلى ما تعلمناه عن التراجع المتعدد (في الفصل 5) وسنعرف أنه يمكن توسيع هذه المعادلة لتشمل هذا المتغير المشترك (انظر المعادلة (1.9)):

$$\begin{aligned} Libido_i &= b_0 + b_3.Covariate_i + b_2.High_i + b_1.Low_i + \varepsilon_i \\ Libido_i &= b_0 + b_3.Partener's\ Libido_i + b_2.High_i + b_1.Low_i + \varepsilon_i \end{aligned} \qquad (1.9)$$

3.9 تنفيذ ANCOVA في برنامج SPSS

يحوي الجدول 1.9 بيانات هذا المثال، وهي موجودة في الملف ViagraCovariate.sav أيضاً. يعرض الجدول 1.9 مستوى الشهوة للمشترك، ومستوى الشهوة لشريكه، والقيم المتوسطة (والانحراف المعياري بين قوسين) للعلامات المختلفة. وننصح بإدخال هذه البيانات يدوياً. ويمكن أن يتم ذلك بنفس طريقة إدخال بيانات Viagra في الفصل السابق، إضافة إلى أنه يجب إنشاء متحول إضافي ليحوي قيم المتغير المشترك.

الجرعة	مستوى الشهوة للمشترك	مستوى الشهوة للشريك
الدواء التمويهي	3	5
	2	2
	5	6
	2	2
	2	3
	2	3
	7	7
	2	4
	4	5
المتوسط	3.22	4.11
الانحراف المعياري	(1.79)	(1.76)
الجرعة المنخفضة	7	10
	5	8
	3	6
	4	7
	4	7
	7	11
	5	9
	4	7
المتوسط	4.88	8.13
الانحراف المعياري	(1.46)	(1.73)
الجرعة المرتفعة	9	2
	2	3
	6	5
	3	4
	4	3
	4	3
	4	2
	6	0
	4	1
	6	3
	2	0
	8	1
	5	0
المتوسط	4.85	2.08
الانحراف المعياري	(1.12)	(1.61)

الجدول 1.9 البيانات من الملف ViagraCovariate.sav

1.3.9 إدخال البيانات

يجب أن تتوضع البيانات في محرر البيانات كما هي في الجدول 1.9 (باستثناء الصفوف التي تحوي قيم المتوسط والانحراف المعياري). لذلك يجب عليك إنشاء متحول ترميز dose واستخدام الخيار Labels لتعريف تسمية لهذا المتحول (وكما في الفصل 8 فإننا ننصح باستخدام القيمة 1 لمجموعة الدواء التمويهي Placebo، و 2 لمجموعة الجرعة المنخفضة Low dose، و 3 لمجموعة الجرعة المرتفعة High dose). هناك عدد مختلف من المشتركين في كل حالة لذلك يجب عليك إدخال القيمة 1 تسع مرات في هذا العمود (لذلك فإن الصفوف التسعة الأولى تحوي القيمة 1)، تليها 8 صفوف تحوي القيمة 2، ثم 13 صفاً تحوي القيمة 3. لديك الآن عمود يحوي 30 صفاً من البيانات التي تم إدخالها. أنشئ بعد ذلك متحولاً ثانياً Libido وأدخل 30 علامة التي توافق مستويات الشهوة للمشترك. أخيراً، أنشئ متحولاً ثالثاً Partner واستخدم الخيار Labels لإعطائه تسمية وصفية مناسبة "Partner's Libido". أدخل بعد ذلك 30 علامة التي توافق مستويات الشهوة للشريك. تذكر أن قيم المتوسط والانحراف المعياري الموجودة في الجدول غير مطلوبة في البيانات.

2.3.9 التحليل الأساسي

تتضمن معظم إجرائيات ANOVA في برنامج SPSS إمكانية تضمين متغير مشترك أو أكثر. على كل حال، ومن أجل التصاميم الأبسط (معظم التصاميم التي لا تتضمن قياسات مكررة) فإنه من الأفضل تنفيذ تحليل التباين المشترك ANCOVA عن طريق إجرائية العاملي العامة. للوصول إلى مربع الحوار الرئيسي استخدم أمر القائمة Analyze ⇒ General Linear Model ⇒ Univariate... (انظر الشكل 1.9). يشبه مربع الحوار الرئيسي ما شاهدته في حالة ANOVA وحيد الاتجاه باستثناء أن هناك حيزاً لتحديد المتغيرات المشتركة. اختر المتحول Libido وانقله إلى الحيز المسمى Dependent Variable (المتحول التابع). اختر المتحول dose وانقله إلى الحيز المسمى Fixed Factor(s) (العوامل الثابتة) ثم اختر المتحول partner وانقله إلى الحيز المسمى Covariate(s) (المتغيرات المشتركة).

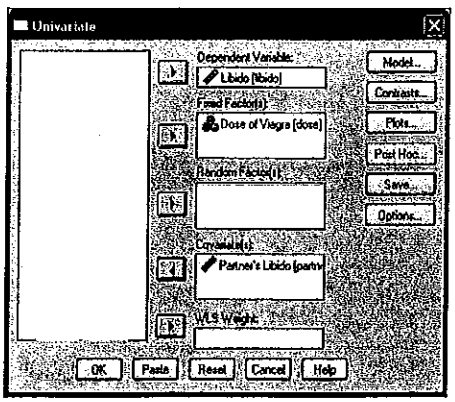

الشكل 1.9 مربع الحوار الرئيسي GLM وحيد المتغير

3.3.9 المقارنات والخيارات الأخرى

هناك مربعات حوار مختلفة يمكن الوصول إليها من مربع الحوار الرئيسي. وأول ما يجب ملاحظته أنه إذا اخترنا متغيراً مشتركاً فإن اختبارات post hoc تصبح غير فعالة (ولا يمكنك الوصول لمربع الحوار الخاص بها). إن اختبارات post hoc غير مصممة للأوضاع التي يتم فيها تحديد متغير مشترك، وعلى كل حال، يمكنك تنفيذ بعض المقارنات عند نقر الزر Contrasts.

انقر الزر ...Contrasts للوصول إلى مربع الحوار Contrasts. يختلف مربع الحوار الناتج عما رأيناه في الفصل 8 من حيث أنه لا يمكنك إدخال رموز لتحديد مقارنات خاصة. وبدلاً من ذلك يمكنك تحديد واحدة أو أكثر من المقارنات القياسية التي تم عرضها في الجدول 6.8. في هذا المثال، هناك حالة مجموعة المراقبة (الدواء التمويهي) التي تم ترميزها كمجموعة أولى، ولذلك فإن هناك مجموعة حساسة من المقارنات هي البسيطة التي تقارن كل مجموعة تجريبية مع مجموعة المراقبة. المقارنة الافتراضية في برنامج SPSS هي التباعد Deviation، ولتغيير ذلك ننقر زر السهم المجاور للحيز المسمى Contrast حيث تظهر قائمة منسدلة نختار منها المقارنة المطلوبة (وفي هذه الحالة Simple). عند استخدام المقارنة البسيطة يتوفر الخيار لتحديد فئة مرجعية (الفئة التي تتم مقارنة جميع المجموعات الأخرى معها). وبشكل افتراضي تكون الفئة الأخيرة هي الفئة المرجعية، ولكن في هذه الحالة نريد أن تكون الفئة الأولى هي الفئة المرجعية لذلك نغير هذا الخيار بنقر الخيار First. عند اختيار مقارنة جديدة يجب عليك نقر الزر Change لتسجيل هذا التغير. بعد الانتهاء يجب أن يبدو مربع الحوار الأول كما في الشكل 2.9 انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

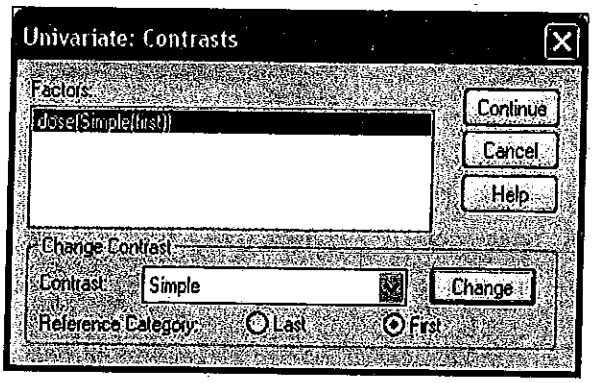

الشكل 2.9 خيارات المقارنات القياسية في GLM وحيد المتغير

هناك طريقة للوصول إلى اختبارات post hoc وذلك بنقر الزر ...Options للوصول إلى مربع الحوار Options المبين في الشكل 3.9. لتحديد اختبارات post hoc نختار المتحول المستقل (في هذه الحالة المتحول dose) من الحيز المسمى Factor(s) and Factor Interactions (العوامل والتفاعلات بين العوامل) في القسم Estimated Marginal Means (المتوسطات الهامشية المقدّرة) وننقله إلى الحيز

المسمى Display Means for (إظهار المتوسطات من أجل). بعد نقل المتحول، يصبح الخيار المسمى Compare Main Effects (مقارنة الآثار الرئيسية) فعالاً، حدد هذا الخيار. عند تحديد هذا الخيار تصبح القائمة المنسدلة Confidence Interval adjustment (تعديل مجالات الثقة) فعالة حيث يمكنك رؤية 3 مستويات من التعديل. الخيار الافتراضي هو عدم وجود تعديل وتنفيذ اختبار Tukey LSD ببساطة (ولا ننصح باستخدام هذا الخيار). المستوى الثاني من التعديل هو طلب استخدام تصحيح Bonferroni. أما المستوى الثالث فهو استخدام تصحيح Sidak. ويشبه تصحيح Sidak تصحيح Bonferroni إلا أنه أقل صرامة ولذلك يجب اختياره عندما نهتم بفقدان القدرة المرتبط بتصحيح Bonferroni. سنستخدم في هذا المثال تصحيح Sidak (وسنستخدم تصحيح Bonferroni في هذا الفصل لاحقاً). ومع إجراء اختبارات post hoc للمتحول dose، فإن وضع المتحول dose في الحيز Display Means for سيعطي جدولاً لقيم المتوسط الحدية التقديرية لهذا المتحول. توفر قيم المتوسط تلك تقديراً لقيم المتوسط المعدّلة للمجموعات (أي قيم المتوسط بعد أخذ المتغير المشترك بعين الاعتبار). بعد تحديد الخيارات المطلوبة (انظر المربع 1.9) انقر الزر Continue للعودة إلى مربع الحوار الرئيسي. هناك خيارات أخرى يوفرها مربع الحوار الرئيسي. فعلى سبيل المثال، إذا اخترت عدة متحولات مستقلة فإنه يمكنك رسمها مقابل بعضها البعض (وهو مفيد لتفسير الآثار المتبادلة، انظر الفقرة 3.3.10). في المثال الحالي لدينا متحول مستقل واحد لذلك ننقر الزر OK لتنفيذ عملية التحليل.

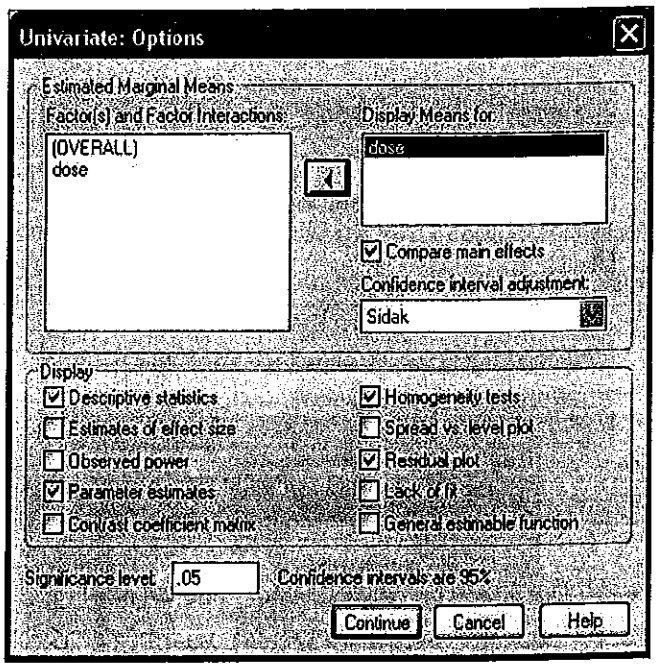

الشكل 3.9 مربع الحوار Options في GLM وحيد المتغير

المربع 1.9 الخيارات من أجل ANCOVA

بقية الخيارات في مربع الحوار هي التالية:

- **الإحصائيات الوصفية (Descriptive statistics):** ويعطي جدولاً بقيم المتوسط والانحراف المعياري لكل مجموعة.
- **تقديرات حجم الأثر (Estimates of effect size):** يعطي هذا الخيار قيمة إيتا مربع η^2 الموصوفة في الفقرة 5.8 وهي قياس لحجم الأثر التجريبي. وفي الواقع فإن η^2 هي معامل التراجع(R^2) لخط التراجع غير الخطي (منحني مثلاً) الذي يُفترض أن يمر عبر جميع متوسطات المجموعات. في مجتمع ما، يكون هذا الافتراض صحيحاً، ولكنه غير صحيح في العينات، لذلك تكون η^2 منحازة عادة (انظر الفقرة 5.8). ولهذا السبب هناك القليل ممن يفضل هذا الخيار، ويمكن أن يتم تقدير حجم الأثر باستخدام أوميغا مربع ω^2. انظر الفقرة 7.9.
- **القدرة المراقبة (Observed power):** يوفر هذا الخيار تقديراً لاحتمال أن يكون الاختبار الإحصائي قادراً على اكتشاف الفرق بين قيم المتوسط المراقبة للمجموعات (انظر الفقرة 5.8.1). وهذا الخيار قليل الاستخدام لأنه إذا كانت النسبة F ذات دلالة فإن احتمال اكتشاف الأثر سيكون كبيراً. وبشكل مشابه، إذا كانت فروق المجموعات صغيرة فإن القدرة المراقبة ستكون منخفضة. إن القدرة المراقبة قليلة الاستخدام وننصح بإجراء حسابات القدرة (بالنسبة لحجم العينة) قبل تنفيذ التجربة. يمكنك العودة لأحد المراجع Cohen, 1988, 1992 و Howell, 2002 للتعرف على بعض الأفكار في حساب القدرة يدوياً، أو المرجع Field, 1988b للتعرف على بعض الأفكار في حساب القدرة باستخدام الحاسب، أو يمكنك استخدام البرنامج المجاني G*Power المتوفر على القرص المضغوط المرفق مع الكتاب، أو من الموقع: http://www.psycho.uni-duesseldorf.de/aap/projects/gpower/.
- **تقدير البارامترات (Parameter estimates):** يعطي هذا الخيار جدولاً لمعاملات التراجع واختبارات الدلالة لها من أجل المتحولات من نموذج التراجع (انظر الفقرة 5.9).
- **مصفوفة معاملات المقارنة (Contrasts coefficient matrix):** يعطي هذا الخيار المصفوفات لقيم الترميز المستخدمة في المقارنات في التحليل. وهذا الخيار مفيد فقط في التحقق من المجموعات التي تتم مقارنتها في كل مقارنة.
- **اختبارات التجانس (Homogeneity tests):** يعطي هذا الخيار اختبار Levene لفرضية تجانس التباين (انظر الفقرات 6.3 و 1.4.8).
- **مخطط الانتشار مع المستوى (Spread vs. level plot):** يعطي هذا الخيار مخططاً يرسم المتوسط لكل مجموعة من عامل ما (X-axis) مقابل الانحراف المعياري لتلك المجموعة (Y-axis). وهذا المخطط مفيد للتحقق من عدم وجود علاقة بين المتوسط والانحراف المعياري. إذا وجدت علاقة ما بينهما فقد تكون البيانات بحاجة لتحويل لوغاريتمي (انظر الفصل 3).
- **مخطط البواقي (Residual plot):** يعطي هذا الخيار مخططات لقيم البواقي المعايرة المتوقعة المراقبة. ويمكن استخدام هذه المخططات لتقييم فرضية تساوي التباين.

4.9 تفسير الخرج من ANCOVA

1.4.9 التحليل الأساسي

يعرض الخرج 1.9 (لأهداف توضيحية) جدول ANOVA لهذه البيانات عند عدم تضمين المتغير المشترك. من الواضح بالنظر إلى قيمة الدلالة (0.05>) عدم وجود فرق في الشهوة بين المجموعات الثلاث، ولذلك يبدو أن Viagra لا تؤثر على الشهوة بشكل واضح. يجب أن نلاحظ أيضاً المقدار الكلي للتغير الواجب تبريره (SS_T) هو 110.97 (المقدار الكلي المصحح (Corrected Total))، والمعتبر للتلاعب التجريبي (SS_M) هو 16.84 بينما المقدار غير المبرر (SS_T) هو 94.12.

Tests of Between-Subjects Effects

Dependent Variable: Libido

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	16.844[a]	2	8.422	2.416	.108
Intercept	535.184	1	535.184	153.522	.000
DOSE	16.844	2	8.422	2.416	.108
Error	94.123	27	3.486		
Total	683.000	30			
Corrected Total	110.967	29			

a. R Squared = .152 (Adjusted R Squared = .089)

الخرج 1.9

يعرض الخرج 2.9 نتائج اختبار Levene وجدول ANOVA عند تضمين شهوة الشريك في النموذج كمتغير مشترك. إن اختبار Levene ذو دلالة مما يشير إلى أن تباينات المجموعات ليست متساوية (أي أن فرضية تجانس التباين غير محققة). على كل حال، وكما ذكرنا في الفقرة 6.3 فإن اختبار Levene ليس أفضل طريقة للحكم فيما إذا كانت التباينات غير متساوية لحد يجعل منها سبباً للمشاكل. هناك طريقة للتحقق المضاعف وهي النظر إلى التباينات القصوى والدنيا. ومن أجل المجموعات الثلاث فإن الانحرافات المعيارية هي 1.79 لمجموعة الدواء التمويهي، و 1.46 لمجموعة الجرعة المنخفضة، و2.12 لمجموعة الجرعة المرتفعة (انظر الجدول 1.9). نقوم بتربيع هذه القيم فنحصل على قيم التباين وهي 3.20 لمجموعة الدواء التمويهي، و 2.13 لمجموعة الجرعة المنخفضة، و4.49 لمجموعة الجرعة المرتفعة. ثم نأخذ القيمة الكبرى ونقسمها على القيمة الصغرى (4.49/2.13=2.11)، فإذا كانت القيمة الناتجة أقل من 2 فربما لا يكون هناك داعٍ للقلق، أما إذا كانت القيمة أكبر من 2 (وهي الحالة هنا) فربما علينا أن نقلق. على كل حال، لا تقلق كثيراً في الوقت الحالي حول الفروق في التباينات.

إن تنسيق جدول ANOVA هو ذاته تقريباً باستثناء وجود سطر إضافي للمعلومات عن المتغير المشترك partner. لننظر أولاً إلى قيم الدلالة، من الواضح أن المتغير المشترك يتوقع المتحول التابع بشكل جيد، وذلك لأن قيمة الدلالة أصغر من 0.05، لذلك فإن شهوة المشترك تتأثر بشهوة الشريك. والأهم من ذلك هو أنه عند إلغاء أثر شهوة الشريك، يصبح أثر Viagra مهماً (p=0.016<0.05). لقد ازداد مقدار التغايرية المنسوبة للنموذج (SS_M) إلى 34.75 وحدة (النموذج المصحح (Corrected Model)) تأخذ Viagra منها 28.34 وحدة. والأهم من ذلك هو أن الجزء الأكبر من التغايرية للشهوة والذي يعود للمتغير المشترك يعني أن التباين غير المبرر (SS_R) قد انخفض إلى 76.22 وحدة. لاحظ أن SS_T لم يتغير، وما تغير هو كيفية تبرير هذه التغايرية.

يوضح هذا المثال كيف يمكن لتحليل التباين المشترك (ANCOVA) أن يساعدنا في ممارسة تحكم تجريبي أكثر صرامة وذلك بأخذ المتحولات المربكة بعين الاعتبار لتعطينا قياساً أنقى لأثر التلاعب التجريبي. وعندما لا نأخذ شهوة الشريك بعين الاعتبار فإن علينا أن نستنتج أنه ليس لدواء Viagra أثر على الشهوة، مع أن له (كما هو واضح) أثر معين. وعلى كل حال، يبدو أن شهوة الشريك أقوى من أثر Viagra. لننظر مرة أخرى إلى قيم المتوسط للمجموعات في الجدول 1.9، يبدو واضحاً أن ANOVA ذو الدلالة يعكس فرقاً بين مجموعة الدواء التمويهي والمجموعتين التجريبيتين (وذلك لأن لمجموعة الجرعة المنخفضة ولمجموعة الجرعة المرتفعة قيم متوسط متشابهة جداً هي 4.88 و4.85 بينما قيمة المتوسط لمجموعة الدواء التمويهي أدنى بكثير وتبلغ 3.22). وعلى كل حال، فإننا نضطر للتحقق من ذلك عبر بعض المقارنات.

يعرض الخرج 3.9 تقديرات البارامترات المحددة في مربع الحوار Options. وقد تم حساب هذه التقديرات باستخدام تحليل التراجع مع تقسيم المتحول dose إلى متحولي ترميز مزيفين (انظر الفقرة 2.2.8 والفقرة 5.9). يقوم برنامج SPSS بترميز هذين المتحولين المزيفين بحيث تكون الفئة الأخيرة (الفئة ذات القيمة الأعلى في محرر البيانات، وهي في هذه الحالة لمجموعة الجرعة المرتفعة) هي الفئة المرجعية. يتم ترميز هذه الفئة المرجعية (ذات التسمية DOSE=3 في الخرج) بالقيمة 0 لكلا المتحولين المزيفين (انظر الفقرة 2.2.8 لتتذكر كيفية عمل الترميز المزيف)، أما DOSE=2 فتمثل الفرق بين المجموعة ذات الرمز 2 (لمجموعة الجرعة المنخفضة) والفئة المرجعية (لمجموعة الجرعة المرتفعة)، وتمثل DOSE=1 الفرق بين المجموعة ذات الرمز 1 (لمجموعة الدواء التمويهي) والفئة المرجعية (لمجموعة الجرعة المرتفعة). تمثل القيم b الفروق بين قيم المتوسط لهذه المجموعات، ولذلك فإن قيم الدلالة لاختبارات t تدلنا فيما إذا كانت قيم المتوسط للمجموعات تختلف بشكل كبير، يمكن حساب عدد درجات الحرية لاختبارات t كما في حالة التراجع العادي (انظر الفقرة 4.2.5) أي N-P-1 حيث N حجم العينة الكلي (وفي هذه الحالة 30) وP عدد المتحولات التنبؤية (وفي هذه الحالة 3 هم المتحولان المزيفان والمتغير المشترك، انظر المعادلة (1.9)). ومن أجل هذا المثال فإننا نجد df=30-3-1=26.

Levene's Test of Equality of Error Variances[a]

Dependent Variable: Libido

F	df1	df2	Sig.
5.525	2	27	.010

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a. Design: Intercept+PARTNER+DOSE

Tests of Between-Subjects Effects

Dependent Variable: Libido

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	34.760[a]	3	11.583	3.952	.019
Intercept	12.171	1	12.171	4.152	.052
PARTNER	17.906	1	17.906	6.109	.020
DOSE	28.337	2	14.169	4.833	.016
Error	76.216	26	2.931		
Total	683.000	30			
Corrected Total	110.967	29			

a. R Squared = .313 (Adjusted R Squared = .234)

الخرج 2.9

Parameter Estimates

Dependent Variable: Libido

Parameter	B	Std. Error	t	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
Intercept	3.843	.625	6.150	.000	2.558	5.127
PARTNER	.493	.196	2.472	.020	8.134E-02	.885
[DOSE=1]	-2.607	.842	-3.095	.005	-4.338	-.876
[DOSE=2]	-2.894	1.411	-2.051	.050	-5.794	.006
[DOSE=3]	0[a]	.	.	.	.	.

a. This parameter is set to zero because it is redundant.

الخرج 3.9

لذلك، ومن هذه التقديرات يمكننا أن نستنتج أن مجموعة الجرعة المرتفعة تختلف بشكل كبير عن مجموعة الدواء التمويهي (DOSE=1 في الجدول)، وأن مجموعة الجرعة المرتفعة تختلف بشكل كبير أيضاً عن مجموعة الجرعة المنخفضة (DOSE=2). والنتيجة الأخيرة غريبة نوعاً ما لأنها تتعارض مع استنتاجنا الأولي من ANOVA (تذكر أن قيم المتوسط لمجموعات الجرعة المنخفضة والجرعة المرتفعة

كانت متماثلة ظاهرياً). الأمر الأخير الذي يجب ملاحظته هو قيمة b للمتغير المشترك (0.483). تدلنا هذه القيمة على أنه عندما تتساوى العوامل الأخرى، فإنه إذا ازدادت شهوة الشريك بمقدار وحدة واحدة فإن شهوة المشترك ستزداد بأقل من نصف وحدة (مع أنه لا يوجد ما يدعو لوجود رابط سببي بين الاثنين). وتدل إشارة هذا المعامل على اتجاه العلاقة بين المتغير المشترك والنتيجة. لذلك وفي هذا المثال، تدل الإشارة الموجبة للمعامل على أن هناك علاقة طردية بين شهوة الشريك وشهوة المشترك، فعند زيادة إحداهما تزداد الأخرى. أما الإشارة السالبة فتعني علاقة عكسية، أي أن زيادة إحداهما تؤدي لنقص الأخرى.

2.4.9 المقارنات

يعرض الخرج 4.9 نتيجة تحليل المقارنة المحدد في الشكل 2.9، وتقارن المستوى 2 (الجرعة المنخفضة) مع المستوى 1 (الدواء التمويهي) كمقارنة أولى، والمستوى 3 (الجرعة المرتفعة) مع المستوى 1 (الدواء التمويهي) كمقارنة ثانية. ويتم عرض فروق المجموعات: قيمة الفرق، الخطأ المعياري، قيمة الدلالة، ومجال الثقة 95%. وتبين هذه القيم أن قيمة الشهوة لمجموعة الجرعة المنخفضة لا تختلف كثيراً عن مجموعة الدواء التمويهي (p=0.005). وهذه النتائج متوافقة مع تقديرات البارامترات للتراجع (لاحظ أن المقارنة 2 مماثلة لبارامترات التراجع من أجل DOSE=1 في الفقرة السابقة).

Contrast Results (K Matrix)

Dose of Viagra Simple Contrast[a]			Dependent Variable: Libido
Level 2 vs. Level 1	Contrast Estimate		-.287
	Hypothesized Value		0
	Difference (Estimate - Hypothesized)		-.287
	Std. Error		1.144
	Sig.		.804
	95% Confidence Interval for Difference	Lower Bound	-2.638
		Upper Bound	2.064
Level 3 vs. Level 1	Contrast Estimate		2.607
	Hypothesized Value		0
	Difference (Estimate - Hypothesized)		2.607
	Std. Error		.842
	Sig.		.005
	95% Confidence Interval for Difference	Lower Bound	.876
		Upper Bound	4.338

a. Reference category = 1

الخرج 4.9

ومرة أخرى يبدو ذلك غريباً جداً لأن الأثر الهام للشهوة يعكس فرقاً بين مجموعة الدواء التمويهي ومجموعتي Viagra (اللتان تملكان قيماً متشابهة للمتوسط) مع أن المقارنات تعارض هذه الاستنتاجات. وسبب هذا التضارب أن النتيجة البدائية كانت مبنية على قيم المتوسط للمجموعات التي لم يتم تعديلها من أجل أثر المتغير المشترك. ولا تدلنا هذه القيم على أي شيء بخصوص فروق المجموعات التي يعكسها تحليل التباين المشترك ANCOVA. يعطي الخرج 5.9 القيم المعدّلة لمتوسطات المجموعات، ويجب استخدام هذه القيم في التفسير (وهذا هو السبب الرئيسي لتحديد الخيار Display Means for). تبين قيم المتوسط المعدّلة نمطاً مختلفاً جداً من الاستجابات، إذ يبدو أن ANCOVA ذو الدلالة يعكس فرقاً بين مجموعة الجرعة المرتفعة وكلاً من مجموعة الجرعة المنخفضة ومجموعة الدواء التمويهي. يبدو أن مجموعتي الجرعة المنخفضة والدواء التمويهي تملكان قيماً متشابهة جداً للمتوسط المعدّل مما يدل على أن المقادير غير الكافية من Viagra لا تزيد الشهوة فوق المستويات العادية، أي يجب تناول جرعة مرتفعة. وتدعم هذه الاستنتاجات ما عرفناه من المقارنات وبارامترات التراجع، ولكن يمكن التحقق منها باختبارات post hoc المحددة في قائمة الخيارات Options.

Estimates

Dependent Variable: Libido

Dose of Viagra	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
Placebo	3.313[a]	.572	2.138	4.489
Low Dose	3.027[a]	.962	1.049	5.004
High Dose	5.920[a]	.644	4.597	7.244

a. Evaluated at covariates appeared in the model: Partner's Libido = 4.30.

الخرج 5.9

يعرض الخرج 6.9 نتائج مقارنات post hoc ذات تصحيح Sidak والتي طلبناها في مربع الحوار Options. إن الفرق الكبير بين مجموعتي الجرعة المرتفعة والدواء التمويهي باق، ولكن الفرق الكبير بين مجموعتي الجرعة المرتفعة والجرعة المنخفضة والذي تعرضه بارامترات التراجع (الخرج 3.9) قد اختفى (p=0.14). وقد ينتج هذا التناقض عن فقد القدرة في اختبارات post hoc (تذكر أن المقارنات المنظمة ذات قدرة أكبر من إجرائيات post hoc في اكتشاف الآثار). وعلى كل حال، قد توجد أسباب أخرى تبرر عدم دلالة هذه المقارنات، ويجب أن نكون حذرين جداً في تفسيرنا لتحليل التباين المشترك ANCOVA ذو الدلالة والمقارنات اللاحقة.

Pairwise Comparisons

Dependent Variable: Libido

(I) Dose of Viagra	(J) Dose of Viagra	Mean Difference (I-J)	Std. Error	Sig.[a]	95% Confidence Interval for Difference[a]	
					Lower Bound	Upper Bound
Placebo	Low Dose	.287	1.144	.992	-2.631	3.205
	High Dose	-2.607*	.842	.014	-4.756	-.458
Low Dose	Placebo	-.287	1.144	.992	-3.205	2.631
	High Dose	-2.894	1.411	.144	-6.493	.706
High Dose	Placebo	2.607*	.842	.014	.458	4.756
	Low Dose	2.894	1.411	.144	-.706	6.493

Based on estimated marginal means

*. The mean difference is significant at the .05 level.

a. Adjustment for multiple comparisons: Sidak.

الخرج 6.9

3.4.9 تفسير المتغير المشترك

ذكرنا سابقاً أن تقديرات البارامترات (الخرج 3.9) تدلنا على كيفية تفسير المتغير المشترك. إذا كانت قيمة b للمتغير المشترك موجبة فهذا يعني وجود علاقة طردية بين المتغير المشترك ومتحول النتيجة (عند ازدياد المتغير المشترك يزداد متحول النتيجة). أما إذا كانت قيمة b سالبة فهذا يعني وجود علاقة عكسية بين المتغير المشترك ومتحول النتيجة (عند ازدياد المتغير المشترك ينخفض متحول النتيجة). بالنسبة للمثال الحالي كانت قيمة b موجبة مما يدل على أنه عند زيادة شهوة الشريك تزداد شهوة المشترك. هناك طريقة أخرى لاكتشاف نفس النتيجة وهي رسم المخطط المبعثر للمتغير المشترك مع متحول النتيجة. لقد درسنا المخططات المبعثرة في الفقرة 4.4 ويمكنك العودة لهذه الفقرة لرسم المخطط المبعثر. يعرض الشكل 4.9 المخطط المبعثر الناتج لهذه البيانات، ويؤكد ما نعرفه سابقاً عن أثر المتغير المشترك، فإذا ازدادت شهوة الشريك ازدادت شهوة المشترك (كما يوضح ذلك ميل خط التراجع).

5.9 تنفيذ ANCOVA كتراجع متعدد

على الرغم من تنفيذ ANCOVA بشكل أساسي، فقد يكون من المفيد إعادة تنفيذ التحليل كتراجع متعدد هرمي. أدخل هذه البيانات كتمرين ونفذ التحليل بنفسك وذلك بإضافة متحولين مزيفين إلى الملف ViagraCovariate.sav الذي استخدمناه في هذا الفصل (انظر الفقرة 2.2.8 للتعرف على الترميز المزيف). إذا لم ترغب بهذا التمرين فيمكنك استخدام الملف ViagraCovariateDummy.sav الموجود على القرص المضغوط المرفق والذي يحوي البيانات الكاملة. لتنفيذ التحليل، استخدمنا إجرائية التراجع (انظر الفصل 5) مع المتحول Libido كمتحول

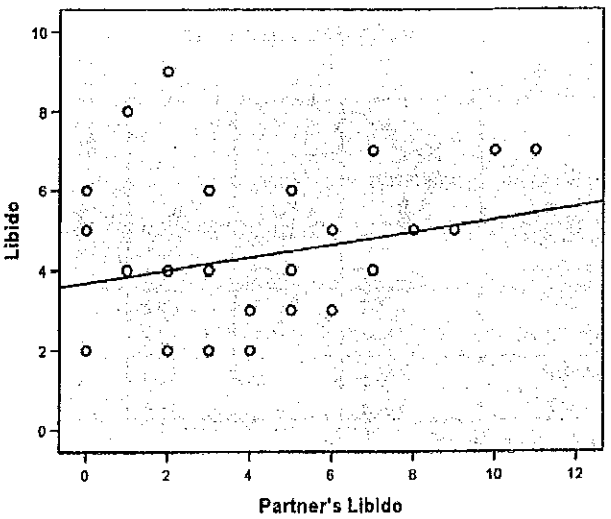

الشكل 4.9 المخطط المبعثر لشهوة المشترك مقابل شهوة الشريك

النتيجة (المتحول التابع بحسب اصطلاحات البرنامج SPSS) وأدخلنا في الكتلة الأولى شهوة الشريك (Partner) كمتحول تنبؤي، وفي الكتلة الثانية أدخلنا كلا المتحولين المزيفين. وفي جميع الحالات نستخدم طريقة الإدخال Enter (انظر الفقرة 7.5 لمعرفة كيفية إدخال المتحولات في التراجع الهرمي ولكن تذكر استخدام الطريقة Enter من أجل الكتلتين). يعرض الخرج 7.9 ملخص نموذج التراجع الناتج ويبين قيمة جودة التوافق للنموذج عند استخدام المتغير المشترك في النموذج أولاً، وعند استخدام المتغير المشترك والمتحولين المزيفين ثانياً.

يمثل الفرق بين قيم R^2 (0.313-0.058=0.255) المساهمة المنفصلة لجرعة Viagra. لذلك يمكننا القول أن جرعة Viagra تساهم بمقدار 25.5% من التغايرية في الشهوة، بينما تساهم شهوة الشريك بمقدار 5.8% فقط. توفر هذه المعلومة الإضافية بعض المعرفة عن الأهمية الفعلية للدواء Viagra. الجدول الثاني هو جدول ANOVA الذي ينقسم إلى قسمين. يمثل النصف العلوي أثر المتغير المشترك لوحده، بينما يمثل النصف السفلي النموذج الكامل (أي المتغير المشترك مع جرعة Viagra). لاحظ في النصف السفلي لجدول ANOVA (Model 2) أن النموذج الكامل (شهوة الشريك والمتحولات المزيفة) يساهم بمقدار 34.57 وحدة من التباين (SS_M). وهناك 110.97 وحدة من التباين الكلي (SS_T) و 76.22 وحدة من التباين غير المبرر (SS_R). ولذلك فإن النصف السفلي يحوي نفس القيم كما في الجدول الملخص ANCOVA المبين في الخرج 2.9. وهذه القيم هي نفس القيم الموجودة في الصف المسمى Corrected Model (النموذج المصحّح) في جدول ANCOVA عند تنفيذ التحليل ANCOVA.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.240[a]	.058	.024	1.932
2	.560[b]	.313	.234	1.712

a. Predictors: (Constant), Partner's Libido

b. Predictors: (Constant), Partner's Libido, Dummy Variable 2 (Placebo vs. High), Dummy Variable 1 (Placebo vs. Low)

ANOVA[c]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	6.413	1	6.413	1.717	.201[a]
	Residual	104.554	28	3.734		
	Total	110.967	29			
2	Regression	34.750	3	11.583	3.952	.019[b]
	Residual	76.216	26	2.931		
	Total	110.967	29			

a. Predictors: (Constant), Partner's Libido

b. Predictors: (Constant), Partner's Libido, Dummy Variable 2 (Placebo vs. High), Dummy Variable 1 (Placebo vs. Low)

c. Dependent Variable: Libido

الخرج 7.9

يعرض الخرج 8.9 ما تبقى من تحليل التراجع. وهذا الجدول لمعاملات التراجع مهم جداً، وقد تم تقسيمه أيضاً إلى قسمين، حيث يحوي النصف السفلي النموذج الكامل. عند اعتبار جرعة Viagra مع المتغير المشترك فإن قيمة b للمتغير المشترك تساوي 0.483. وهي توافق القيمة التي نجدها في تقديرات بارامترات ANCOVA (الخرج 3.9). تمثل قيم b للمتحولات المزيفة الفرق بين قيم المتوسط لمجموعة الجرعة المنخفضة ومجموعة الدواء التمويهي (Dummy1) ومجموعة الجرعة المرتفعة ومجموعة الدواء التمويهي (Dummy2)، انظر الفقرة 2.2.8 لمعرفة السبب. إن قيم المتوسط لمجموعة الجرعة المنخفضة ولمجموعة الجرعة المرتفعة هي 4.88 و4.85 بالترتيب، وقيمة المتوسط لمجموعة الدواء التمويهي هي 3.22. لذلك فإن قيم b للمتحولين المزيفين ستكون ذاتها تقريباً (Dummy1:4.88-3.22=1.66 و Dummy2:4.85-3.22=1.63). ويمكن للعبقري فقط أن يلاحظ في خرج SPSS أن قيم b ليست فقط مختلفة جداً عن بعضها البعض (وهذا ما لا يجب أن يكون، لأن قيم المتوسط لمجموعتي الجرعة المرتفعة والجرعة المنخفضة متماثلة ظاهرياً) ولكنها مختلفة عن القيم التي قمنا بحسابها. إذاً هل كنا نكذب في الصفحات الخمسين السابقة حول ما تمثله قيم بيتا؟ أبداً. إن السبب في هذا الشذوذ الظاهري هو أن قيم b في التراجع تمثل الفروق بين قيم المتوسط

المعدّل adjusted means، وليس بين قيم المتوسط الأصلي، أي الفرق بين قيمة المتوسط لكل مجموعة ومجموعة الدواء التمويهي عندما يتم تعديل هذه المتوسطات من أجل شهوة الشريك. تم إعطاء القيم المعدّلة في الخرج 5.9، ومن هذا الجدول يمكننا أن نجد:

$$b_{Dummy1} = \overline{X}_{Low(adjusted)} - \overline{X}_{Placebo(adjusted)} = 3.027 - 3.313 = -0.286$$
$$b_{Dummy2} = \overline{X}_{High(adjusted)} - \overline{X}_{Placebo(adjusted)} = 5.920 - 3.313 = +2.607 \quad (2.9)$$

وهذه القيم هي التي نراها في الجدول المبين في الخرج 8.9. تبين اختبارات t المنفذة على هذه القيم أن ANCOVA ذو الدلالة يعكس فرقاً مهماً بين مجموعتي الجرعة المرتفعة والدواء التمويهي. ليس هناك فرق بين مجموعتي الجرعة المنخفضة والدواء التمويهي. يجب أن تلاحظ أيضاً أن قيم الدلالة للقيم t هي ذاتها التي رأيناها في جدول المقارنات لتحليل ANCOVA الأصلي (انظر الخرج 4.9).

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients		
		B	Std. Error	Beta	t	Sig.
1	(Constant)	3.689	.626		5.894	.000
	Partner's Libido	.158	.120	.240	1.311	.201
2	(Constant)	1.236	.986		1.253	.221
	Partner's Libido	.483	.196	.737	2.472	.020
	Dummy Variable 1 (Placebo vs. Low)	-.287	1.144	-.066	-.251	.804
	Dummy Variable 2 (Placebo vs. High)	2.607	.842	.672	3.095	.005

a. Dependent Variable: Libido

الخرج 8.9

النقطة الأخيرة التي نريد ذكرها هي أننا لانعلم بشكل بديهي فيما إذا كان هناك فرق بين مجموعتي الجرعة المنخفضة والجرعة المرتفعة، ولإيجاد ذلك الفرق علينا استخدام ترميز مزيف مختلف (ربما تتم مقارنة كل من مجموعتي الجرعة المنخفضة والجرعة المرتفعة مع مجموعة الدواء التمويهي، ثم مقارنة مجموعة الجرعة المنخفضة مع مجموعة الجرعة المرتفعة كما فعلنا في المقارنات المنظمة في الفصل 8- انظر المربع 2.9).

المربع 2.9 المقارنات المنظمة من أجل ANCOVA

ربما لاحظت أنه يمكننا أن نطلب من برنامج SPSS تنفيذ بعض المقارنات القياسية ولكن ليس هناك خيار لتحديد المقارنات المنظمة كما كانت الحال مع ANOVA وحيد الاتجاه المستقل (انظر الفقرة 1.3.8). على كل حال، يمكن تنفيذ هذه المقارنات إذا نفذنا ANCOVA عبر قائمة التراجع Regression. تخيل أنك اخترت بعض المقارنات المنظمة كما في الفصل 8، حيث تقوم المقارنة الأولى بمقارنة مجموعة الدواء التمويهي مع جميع مجموعات جرعة Viagra، وتقوم المقارنة الثانية بعد ذلك بمقارنة مجموعة الجرعة المرتفعة مع مجموعة الجرعة المنخفضة (انظر الفقرة 10.2.8). لقد رأينا في الفقرات 10.2.8 و 1.3.8 أنه لتنفيذ ذلك في برنامج SPSS ينبغي علينا إدخال أرقام معينة لترميز

هذه المقارنات. وقد اكتشفنا مجموعة مناسبة من الرموز للمقارنة الأولى هي 2- لمجموعة الدواء التمويهي، و 1 لكل من مجموعة الجرعة المرتفعة والمنخفضة. وبالنسبة للمقارنة الثانية كانت الرموز هي 0 لمجموعة الدواء التمويهي و 1- لمجموعة الجرعة المنخفضة و 1+ لمجموعة الجرعة المرتفعة (انظر الجدول 4.8). إذا أردت تنفيذ هذه المقارنات من أجل ANCOVA فعليك إدخال هذه القيم كمتحولين مزيفين. لذلك نقوم بإضافة متحول جديد ندعوه Dummy1 ونضع في عمود هذا المتحول القيمة 2- لكل شخص ينتمي لمجموعة الدواء التمويهي، والقيمة 1 لجميع المشتركين الآخرين. ثم نقوم بإضافة متحول جديد آخر ندعوه Dummy2 ونضع في عمود هذا المتحول القيمة 0 لكل عنصر من مجموعة الدواء التمويهي، والقيمة 1- لكل عنصر من مجموعة الجرعة المنخفضة، والقيمة 1+ لكل عنصر من مجموعة الجرعة المرتفعة. يحوي الملف ViagraCovariateContrasts.sav على القرص المضغوط المرفق البيانات الكاملة.

نفذ عملية التحليل كما في الفقرة 5.9. يبدأ الخرج الناتج بملخص النموذج وجدول ANOVA والتي يجب أن تكون مطابقة لمثيلاتها في الخرج 7.9 (لأننا نفذنا نفس التحليل مع فارق وحيد هو كيفية تقسيم تباين النموذج عبر المقارنات). ستكون معاملات التراجع للمتحولات المزيفة مختلفة وذلك لأننا اعتمدنا ترميزاً مختلفاً.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients		
		B	Std. Error	Beta	t	Sig.
1	(Constant)	3.689	.626		5.894	.000
	Partner's Libido	.158	.120	.240	1.311	.201
2	(Constant)	2.009	.986		2.038	.052
	Partner's Libido	.483	.196	.737	2.472	.020
	Dummy Variable 1 (Placebo vs. Low & High)	.387	.238	.276	1.623	.117
	Dummy Variable 2 (Low vs. High)	1.447	.705	.617	2.051	.050

a. Dependent Variable: Libido

يقارن المتحول المزيف الأول مجموعة الدواء التمويهي مع مجموعتي الجرعة المنخفضة والجرعة المرتفعة. ولذلك فهو يقارن قيمة المتوسط المعدّل لمجموعة الدواء التمويهي (3.313) مع متوسط قيم المتوسطات المعدّلة لمجموعتي الجرعة المنخفضة والجرعة المرتفعة ((3.027+5.920)/2=4.474). ولذلك يجب أن تكون قيمة b للمتحول المزيف الأول هي الفرق بين هاتين القيمتين (4.474-3.313=1.161). وقد اكتشفنا في الفقرة 2.10.2.8 أنه يجب تقسيم هذه القيمة على عدد المجموعات في المقارنة (وهو 3 في المقارنة الأولى) لذلك تكون 1.161/3=0.387 وهي القيمة التي نراها في الخرج. إن إحصائية t المرتبطة بها ليست ذات دلالة مما يشير إلى أن مجموعة الدواء التمويهي ليست مختلفة بشكل كبير عن المتوسط المركب لمجموعتي Viagra.

يقارن المتحول المزيف الثاني مجموعة الجرعة المرتفعة مع مجموعة الجرعة المنخفضة، ولذلك يجب أن تكون قيمة b هي الفرق بين قيم المتوسط المعدّلة لهاتين المجموعتين: 5.920-3.027=2.893. وقد اكتشفنا في الفقرة 2.10.2.8 أنه يجب تقسيم هذه القيمة على عدد المجموعات في المقارنة (وهو 2 في المقارنة الثانية) لذلك تكون 2.893/2=1.447 وهي القيمة التي نراها في الخرج. إن إحصائية t المرتبطة بها ذات دلالة (وقيمة الدلالة هي 0.05 بالضبط) مما يشير إلى أن لمجموعة الجرعة المرتفعة مستوى شهوة أعلى بكثير من مجموعة الجرعة المنخفضة وذلك بعد التحكم بأثر شهوة الشريك.

يوضح ذلك كيف يمكن تطبيق المبادئ من الفقرة 10.2.8 على ANCOVA، فعلى الرغم من أن برنامج SPSS لا يوفر واجهة تخاطب سهلة لتنفيذ المقارنات المنظمة، فإنه يمكننا تنفيذها باستخدام قائمة التراجع Regression بدلاً من قوائم ANCOVA.

6.9 فرضيات إضافية في ANCOVA

1.6.9 تجانس انحدارات التراجع

عند تنفيذ ANCOVA فإننا ننظر إلى العلاقة الكلية بين النتيجة (المتحول التابع) والمتغير المشترك، أي أننا نقوم بملاءمة خط تراجع على مجموعة البيانات كاملة بإهمال انتماء الأشخاص إلى المجموعات المختلفة. وبملاءمة هذا النموذج فإننا نفترض أن هذه العلاقة الكلية هي صحيحة من أجل جميع مجموعات المشتركين. فعلى سبيل المثال، إذا كانت العلاقة طردية بين المتغير المشترك والنتيجة في مجموعة ما، فإننا نفترض أن هناك علاقة طردية في جميع المجموعات الأخرى أيضاً. لذلك إذا كانت العلاقة بين المتغير المشترك والنتيجة تختلف بين المجموعات المختلفة فإن نموذج التراجع لن يكون دقيقاً (لأنه لا يمثل جميع المجموعات). إن هذه الفرضية هامة جداً وتدعى فرضية تجانس انحدارات التراجع (Homogeneity of regression slopes). إن أفضل طريقة لفهم هذه الفرضية هي رسم المخطط المبعثر لكل مجموعة تجريبية حيث يكون المتغير المشترك على أحد المحورين والنتيجة على المحور الآخر. إذا حسبنا بعد ذلك خط التراجع ورسمناه لكل من هذه المخططات المبعثرة فإننا نلاحظ الفرق بين خطوط التراجع وهل هي متشابهة أم لا (يجب أن تكون قيم b في كل المجموعات متساوية).

يعرض (الشكل 5.9) المخططات المبعثرة التي تبين العلاقة بين شهوة الشريك (المتغير المشترك) وشهوة المشترك (النتيجة) لكل من المجموعات التجريبية الثلاث. تمثل النقطة في كل مخطط مبعثر البيانات لمشترك معين أما الخط فيمثل ميل التراجع للمجموعة (أي أنه يلخص العلاقة بين شهوة المشترك وشهوة الشريك المبينة بالنقاط). يجب أن يكون واضحاً وجود علاقة طردية (يميل خط التراجع باتجاه الأعلى عند الانتقال من اليسار إلى اليمين) بين شهوة المشترك وشهوة الشريك في كل من مجموعتي الدواء التمويهي والجرعة المنخفضة. بينما يبدو عدم وجود أي علاقة بين شهوة المشترك وشهوة الشريك في مجموعة الجرعة المرتفعة (النقاط مبعثرة بشكل عشوائي، ويميل خط التراجع قليلاً باتجاه الأسفل عند الانتقال من اليسار إلى اليمين مما يدل على علاقة عكسية ضعيفة). تعطي هذه الملاحظات سبباً للشك فيما إذا كان هناك تجانس لانحدارات التراجع (لأن العلاقة بين شهوة المشترك وشهوة الشريك ليست متجانسة عبر المجموعات التجريبية المختلفة).

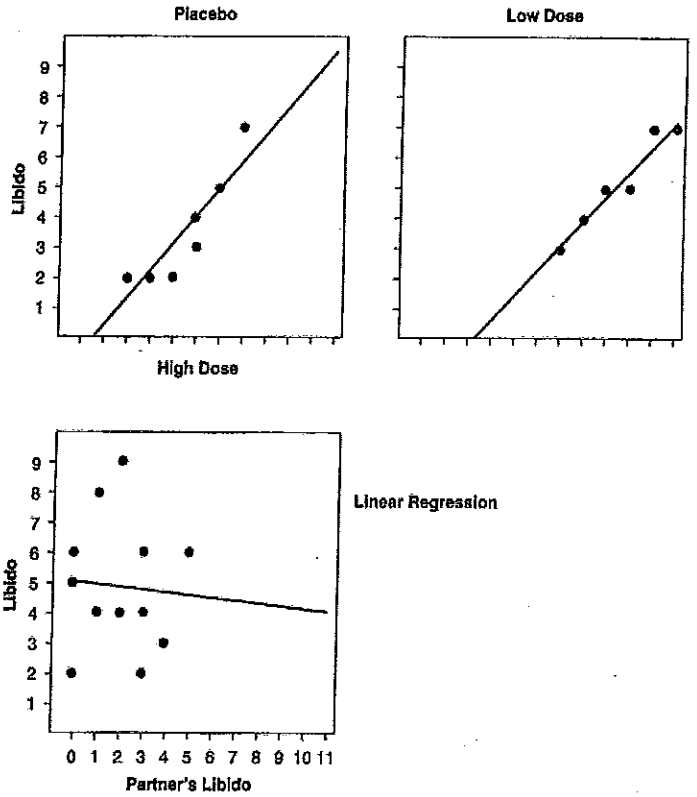

الشكل 5.9 المخططات المبعثرة وخطوط التراجع لشهوة المشترك كتابع لشهوة الشريك في كل من المجموعات التجريبية

2.6.9 اختبار تجانس انحدارات التراجع في برنامج SPSS

لاختبار فرضية تجانس انحدارات التراجع علينا إعادة تنفيذ ANCOVA ولكن باستخدام نموذج مخصص هذه المرة. نفتح مربع الحوار الرئيسي ونضع المتحولات في نفس الأماكن (كما في الشكل 1.9). لتخصيص النموذج علينا فتح مربع الحوار Model (المبين في الشكل 6.9) وذلك بنقر الزر Model...

انقر الخيار Custom لتفعيل مربع الحوار. يعرض القسم الأيسر من مربع الحوار المتحولات المحددة في مربع الحوار الرئيسي، ويكون اسم المتحول متبوعاً بحرف يدل على نوع المتحول (F=عامل ثابت (Fixed factor)، C=متغير مشترك (Covariate)). لاختبار فرضية تجانس انحدارات التراجع، علينا تحديد نموذج يتضمن التفاعل بين المتغير المشترك ومتحول النتيجة. يتضمن ANCOVA عادة الأثر الرئيسي للمتحولين dose وpartner ولا يتضمن حد التفاعل. ولاختبار هذا التفاعل فمن المهم تضمين الآثار الرئيسية للمتحولين dose وpartner بحيث يتم اختبار حد التفاعل للتحكم بتلك الآثار الرئيسية.

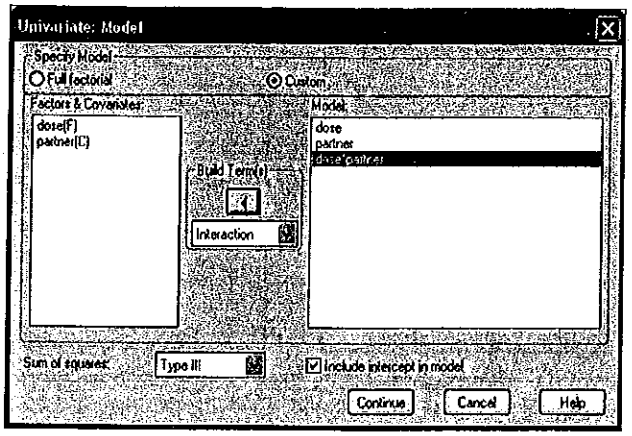

الشكل 6.9 مربع الحوار Model في GLM وحيد المتغير

ونبدأ باختيار dose وpartner بنفس الوقت، ثم ننقر القائمة المنسدلة Build Term(s) ونختار منها (الآثار الرئيسية) Main effects. ثم ننقر زر السهم بين القسمين لننقل الآثار الرئيسية لكل من dose وpartner إلى الحيز المسمى Model. ينبغي علينا بعد ذلك تحديد حد التفاعل. نختار المتحولين dose وpartner بنفس الوقت وننقر القائمة المنسدلة Build Term(s) ونختار منها (التفاعل) Interaction. ثم ننقر زر السهم بين القسمين لننقل التفاعل بين dose وpartner إلى الحيز المسمى Model. وعند الانتهاء من تحديد الخيارات يبدو مربع الحوار المكتمل كما في الشكل 6.9. وللمزيد عن تحديد الآثار يمكنك الاطلاع على الفقرة 2.3.10. انقر الزر Continue للعودة إلى مربع الحوار الرئيسي ثم انقر الزر OK لتنفيذ عملية التحليل.

يعرض الخرج 9.9 الجدول الملخص الرئيسي للتحليل ANCOVA الذي يتضمن حد التفاعل. ما تزال آثار جرعة Viagra وشهوة الشريك مهمة، ولكن الشيء الممتع هنا هو حد التفاعل، لذلك ننظر إلى قيمة الدلالة للتفاعل بين المتغير المشترك والنتيجة (dose×partner): إذا كان هذا الأثر مهماً فإن فرضية تجانس انحدارات التراجع تكون غير محققة، وهي الحالة التي نصادفها هنا ($p<0.05$). ومع أن هذه النتيجة غير مفاجئة نظراً لنمط العلاقات المبينة في الشكل 5.9 فإنها تزيد الاهتمام بالتحليل الأساسي، وخاصة في ضوء النتائج المتناقصة للمقارنات المتعددة. يوضح هذا المثال أهمية اختبار الفرضيات وعدم قبول نتائج التحليل كما هي.

Tests of Between-Subjects Effects

Dependent Variable: Libido

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	52.000[a]	5	10.400	4.233	.007
Intercept	1.706	1	1.706	.694	.413
DOSE	40.068	2	20.034	8.154	.002
PARTNER	22.430	1	22.430	9.129	.006
DOSE * PARTNER	17.250	2	8.625	3.510	.046
Error	58.967	24	2.457		
Total	683.000	30			
Corrected Total	110.967	29			

a. R Squared = .469 (Adjusted R Squared = .358)

الخرج 9.9

أفكار مهمة

- يقارن تحليل المشترك (ANCOVA) عدة قيم للمتوسط ولكن مع التحكم بأثر واحد أو أكثر من المتحولات (التي تدعى المتغيرات المشتركة Covariates). فعلى سبيل المثال، عندما تكون لدينا عدة حالات تجريبية ونريد التحكم حسب عمر المشتركين.
- نبحث في الجدول المسمى Test of between-Subjects effects وفي العمود المسمى .Sig عن قيم الدلالة لكل من المتغير المشترك والمتحول المستقل (متحول التجميع) فإذا كانت القيمة أقل من 0.05 للمتغير المشترك فهذا يعني أن لهذا المتحول علاقة مهمة بمتحول النتيجة (المتحول التابع)، وإذا كانت أقل من 0.05 لمتحول التجميع فهذا يعني أن قيم المتوسط للمجموعات هي مختلفة بشكل كبير بعد التحكم بالأثر الذي يملكه المتغير المشترك على النتيجة.
- وكما في حالة ANOVA، إذا وضعنا فرضيات معينة قبل التجربة فإن علينا استخدام المقارنات المنظمة، ولكن إذا لم تكن هناك فرضيات محددة فإننا نستخدم اختبارات post host. ومع أن برنامج SPSS يسمح بتحديد مقارنات قياسية معينة فإن المقارنات المنظمة الأخرى يمكن تنفيذها بتحليل البيانات باستخدام إجرائيات التراجع في برنامج SPSS.
- من أجل المقارنات واختبارات post host ننظر مرة أخرى إلى العمود .Sig لاكتشاف فيما إذا كانت المقارنات ذات دلالة أم لا (تكون ذات دلالة إذا كانت قيمة الدلالة أصغر من 0.05).
- اختبر نفس الفرضيات كما في ANOVA، إضافة إلى اختبار فرضية تجانس انحدارات التراجع. ويتم ذلك بتخصيص نموذج ANCOVA في برنامج SPSS.

7.9 حساب حجم الأثر

رأينا في المربع 1.9 أنه يمكننا أن نطلب من برنامج SPSS حساب إيتا مربع η^2 وهي r^2 محسوبة من الأثر بين المجموعات (SS_M) مقسوماً على المقدار الكلي للتباين في البيانات (SS_T). إن هذا المقياس لحجم الأثر منحاز قليلاً ولا ننصح باستخدامه. لذلك، وكما في ANOVA فإننا ننصح باستخدام أوميغا مربع ω^2 وهي أقل انحيازاً من إيتا مربع η^2 (انظر الفقرة 5.8). على كل حال، وكما رأينا في الفقرة 5.8 فإنه يمكن قياس ذلك عندما تكون أعداد المشتركين في كل مجموعة متساوية (وهذا غير محقق في هذا المثال).

إن حجم الأثر الكلي ليس مهماً كحجم الأثر للمقارنات الأكثر تحديداً. ويمكن حساب هذه الآثار بسهولة لأننا اخترنا بارامترات التراجع (انظر الخرج 3.9) ولدينا الإحصائيات t للمتغير المشترك وللمقارنات بين مجموعتي الجرعة المنخفضة والجرعة المرتفعة، ومجموعتي الدواء التمويهي والجرعة المرتفعة. ولإحصائيات t عدد من درجات الحرية يبلغ N-2 (انظر الفصل 5) حيث N حجم العينة الكلي (وفي هذا المثال N=30). يمكننا استخدام نفس المعادلة كما في الفقرة 5.5.7:

$$r_{Contrast} = \sqrt{\frac{t^2}{t^2 + df}}$$

ولذلك نحصل من الخرج 3.9 على ما يلي:

$$r_{Covariate} = \sqrt{\frac{2.47^2}{2.47^2 + 28}} = \sqrt{\frac{6.10}{34.10}} = 0.42$$

$$r_{High\ vs.Placebo} = \sqrt{\frac{-3.095^2}{-3.095^2 + 28}} = \sqrt{\frac{9.58}{37.57}} = 0.50$$

$$r_{High\ vs.\ Low} = \sqrt{\frac{-2.051^2}{-2.051^2 + 28}} = \sqrt{\frac{4.21}{32.21}} = 0.36$$

إذا عدنا لمعايير حجم الأثر فإن جميع القيم السابقة تمثل آثار متوسطة إلى كبيرة الحجم (لأنها تقع بين 0.3 و0.5). لذلك فإن هذه الآثار هي نتائج واقعية إضافة إلى أنها ذات دلالة إحصائية.

8.9 تقديم النتائج

يتم تقديم ANCOVA بنفس طريقة تقديم ANOVA باستثناء أننا نقدم أثر المتغير المشترك أيضاً. وبالنسبة للمتغير المشترك والأثر التجريبي فإننا نعطي تفاصيل النسبة F وعدد درجات الحرية المستخدم لحسابها. وفي كلتا الحالتين تكون النسبة F مشتقة من تقسيم متوسط المربعات للأثر على متوسط المربعات للبواقي. ولذلك فإن أعداد درجات الحرية المستخدمة لتقييم النسبة F هي: عدد درجات الحرية لأثر النموذج (df_M=1 للمتغير المشترك وdf_M=2 للأثر التجريبي) وعدد درجات الحرية لبواقي النموذج (df_R=26 لكل من المتغير المشترك والأثر التجريبي)، انظر الخرج 2.9. لذلك فإن الطريقة الصحيحة لتقديم النتائج الأساسية هي:

- ✓ إن المتغير المشترك (شهوة الشريك) مرتبط بشكل كبير بشهوة المشترك F(1,26)=6.11, p<0.05, r=0.42 هناك أيضاً أثر هام لـــ Viagra على مستويات الشهوة بعد التحكم بأثر شهوة الشريك، F(2,26)=4.83, p<0.05.

ويمكن تقديم بعض المقارنات بالشكل:

- ✓ أظهرت المقارنات المنظمة أن تناول جرعة مرتفعة من Viagra يزيد الشهوة بشكل كبير مقارنة بتناول الدواء التمويهي t(26)=-3.10, p<0.05, r=0.50, وتناول الجرعة المنخفضة t(26)=-2.05, p<0.05, r=0.36.

9.9 ما الذي اكتشفناه عن الإحصاء

عرض هذا الفصل كيفية توسيع النموذج الخطي العام (GLM) المقدم في الفصل 8 ليتضمن متحولات إضافية. ومن فوائد ذلك أنه يمكننا التحكم بالعوامل عدا التلاعب التجريبي والتي يمكنها أن تؤثر على قياس النتيجة. يمنحنا ذلك تحكماً تجريبياً أكثر شدة كما يساعدنا في تبرير جزء من تباين الخطأ ولذلك نحصل على قياس أكثر نقاءً للتلاعب التجريبي. لم نبحث الأسس النظرية للتحليل ANCOVA بشكل معمق، واكتفينا ببحث كيفية توسيع نموذج التراجع ليتضمن المتحولات الإضافية (المتغيرات المشتركة). وبدلاً من ذلك انتقلنا مباشرة إلى مثال يبحث عن أثر Viagra على الشهوة الجنسية (كما في الفصل 8) وأدخلنا فيه شهوة الشريك كمتغير مشترك. شرحنا كيفية تنفيذ التحليل في برنامج SPSS وقمنا بتفسير النتائج، كما أظهرنا كيفية الحصول على نفس الخرج بتنفيذ التحليل كتراجع. والهدف هو تأكيد الرسالة بأن ANOVA وANCOVA هي أشكال من التراجع. وأنهينا الفصل بالنظر إلى فرضية إضافية يجب اعتبارها عند تنفيذ ANCOVA وهي فرضية تجانس انحدارات التراجع. وهذا يعني أن العلاقة بين المتغير المشترك ومتحول النتيجة يجب أن تكون ذاتها في جميع المجموعات التجريبية. كما ألقينا نظرة على اختبار هذه الفرضية في برنامج SPSS. سننتقل الآن لبحث الحالات التي يكون لدينا فيها أكثر من تلاعب تجريبي واحد.

10.9 المصطلحات الأساسية التي اكتشفناها

المتوسطات المعدّلة	(Adjusted means)
تحليل التباين المشترك ANCOVA	(Analysis of covariance)
تجانس انحدارات التراجع	(Homogeneity of regression slopes)
تصحيح Sidak	(Sidak correction)
المتغيرات المشتركة	(Covariates)

11.9 مهمات يجب تنفيذها

- **المهمة الأولى:** يعتبر الترصّد عملية مشوِّشة ومقلقة جداً (للشخص الذي يتم تعقبه) حيث يقوم الشخص المتعقِّب بمضايقة شخص آخر. ويمكن أن تأخذ عدة أشكال تبدأ من الإرسال الكثيف لرسائل التهديد وصولاً للملاحقة الشخصية لمعرفة الهوايات والرغبات وجميع التحركات. وقد قرر أحد الأطباء النفسيين والذي عانى من مضايقات الناس أن يجرب نوعين من المعالجة على مجموعتين مختلفتين من المترصدين (25 مترصداً في كل مجموعة، وسمّى هذا المتحول group). وقد عالج المجموعة الأولى بما دعاه العلاج القاسي ليصبح الشخص لطيفاً. ويعتمد على معاقبة الشخص المترصد عند قيامه بأي سلوك شبيه بالترصد والملاحقة، وكان يأمل بأن يؤدي ذلك لردع المترصد عن القيام بمثل تلك الأعمال. أما المجموعة الثانية فقد اعتمد معها طريقة حديثة تعتمد الخداع. وفي نهاية المعالجة تم إحصاء عدد الساعات التي يقضيها الشخص في ملاحقة ضحيته خلال أسبوع كامل (وقد سمّى هذا المتحول stalk2). يعتقد الطبيب النفسي أن نجاح العلاج يعتمد أيضاً على مدى سوء حالة الشخص في بداية العلاج، لذلك فقد قاس عدد الساعات التي كان يقضيها الشخص في ملاحقة ضحيته خلال أسبوع كامل (وقد سمّى هذا المتحول stalk1). يحوي الملف Stalker.sav بيانات هذه المهمة. حلل أثر المعالجة على سلوك الترصد بعد المعالجة، مع التحكم بمقدار سلوك الترصد قبل المعالجة.
- **المهمة الثانية:** اهتم مدير التسويق في إحدى شركات صناعة المشروبات بالفوائد العلاجية لبعض المشروبات في معالجة الأعراض التي تظهر بعد شرب الكحول (hangover). فأخذ 15 شخصاً ذات ليلة وجعلهم يشربون الكحول حتى أصبحوا مخمورين. وفي صباح اليوم التالي، وعندما استيقظ هؤلاء الأشخاص وهم يشعرون بالعطش، أعطى 5 منهم الماء ليشربوه، وأعطى 5 آخرين مشروباً سكرياً، وأعطى 5 المتبقين مشروب الكولا (وقد سمّى هذا المتحول drink). وبعد ساعتين من ذلك قاس شعورهم بالحيوية (على مقياس من 0=أشعر كأنني ميت، إلى 10=أشعر بالصحة والحيوية) وسمّى هذا المتحول well. وقد أراد معرفة المشروب الذي أعطى أفضل مستوى من الشعور بالحيوية. على كل حال، لقد أدرك مدير التسويق أنه من الضروري معرفة حالة الثمالة للشخص في الليلة السابقة على مقياس يتراوح بين 0=غير ثمل إطلاقاً و 10=ثمل جداً. يحوي الملف HangoverCure.sav بيانات هذه المهمة. ينبغي عليك تنفيذ ANCOVA لمعرفة الأشخاص الذين يشعرون بالحيوية بعد تناول المشروبات المختلفة مع التحكم بمدى ثمالتهم في الليلة السابقة.

يحوي الملف Answers(Chapter9).pdf الإجابات على هذه المهمات.

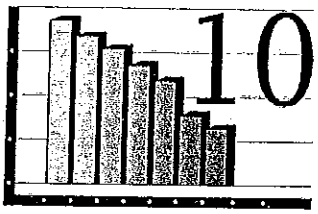

تحليل التباين العاملي (GLM3)

1.10 ماذا يخبرنا هذا الفصل

تعرفنا في الفصلين السابقين على الأوضاع التي حاولنا فيها اختبار الفروق بين المجموعات بوجود متحول مستقل وحيد (يتم التلاعب بمتحول واحد فقط). وقلنا في بداية الفصل 8 أن إحدى مزايا ANOVA هي إمكانية البحث عن الآثار لعدة متحولات مستقلة (وكيفية التفاعل بين هذه المتحولات). يوسّع هذا الفصل ما تعلمناه سابقاً عن ANOVA وذلك بالبحث في الأوضاع التي تحوي متحولين مستقلين. وقد رأينا في الفصل السابق أنه من السهل جداً تضمين متحول ثان في إطار ANOVA عندما يكون ذلك المتحول مستمراً (ليس مقسماً إلى مجموعات)، ولكننا سننتقل الآن إلى الأوضاع التي يتم فيها التلاعب بالمتحول المستقل الثاني بشكل منهجي وذلك بتعيين الأشخاص في حالات مختلفة.

2.10 نظرية ANOVA العاملي (بين المجموعات)

1.2.10 التصاميم العاملية

يُستخدم ANOVA العاملي (Factorial ANOVA) عند وجود متحولين مستقلين أو أكثر (تدعى هذه المتحولات أحياناً بالعوامل Factors ومن هنا جاءت التسمية ANOVA العاملي). وهناك عدة أنواع من التصميم العاملي:

- **التصميم العاملي المستقل (Independent factorial design):** وهو تصميم يضم عدة متحولات مستقلة، ويتم قياس كل منها باستخدام مشتركين مختلفين (بين المجموعات).
- **التصميم العاملي المرتبط (Related factorial design):** وهو تصميم يضم عدة متحولات مستقلة، ويتم قياس كل منها باستخدام نفس المشتركين في جميع الحالات (القياسات المكررة).
- **التصميم المختلط (Mixed design):** تصميم يتم فيه قياس عدة متحولات مستقلة باستخدام مشتركين مختلفين، وقياس متحولات مستقلة أخرى باستخدام نفس المشتركين.

توسّع هذه الفقرة نموذج ANOVA وحيد الاتجاه إلى الحالة العاملية، وتبحث الفصول اللاحقة في تصاميم القياسات المكررة، وتصاميم القياسات المكررة العاملية، وأخيراً التصاميم المختلطة.

المربع 1.10 تسمية ANOVA

يمكن أن تكون أنواع ANOVA مربكة لأن هناك الكثير منها. ونصادف أحياناً عبارة مثل "تم تطبيق ANOVA ثنائي الاتجاه المستقل" أو "تم تطبيق ANOVA ثنائي الاتجاه للقياسات المكررة". وتبدو هذه العبارة مربكة، ولكنها تصبح سهلة إذا استطعنا تقسيمها. تشترك جميع أنواع ANOVA بأمرين اثنين: فهي تتضمن بعض المتحولات المستقلة، ويمكن قياس هذه المتحولات باستخدام نفس المشتركين أو مشتركين مختلفين. إذا استخدمنا نفس المشتركين فإننا نستخدم عبارة القياسات المكررة (Repeated measures)، وإذا استخدمنا مشتركين مختلفين فإننا نستخدم كلمة المستقلة (Independent). عند وجود متحولَين مستقلّين أو أكثر فمن الممكن أن تَستخدم بعضُ المتحولات نفس المشتركين بينما تَستخدم المتحولاتُ الأخرى مشتركين مختلفين، وفي هذه الحالة نستخدم كلمة المختلط (Mixed). عند تسمية ANOVA فإننا نخبر القارئ بعدد المتحولات المستقلة التي نستخدمها وكيفية قياسها. وبشكل عام يمكننا أن نكتب اسم ANOVA كما يلي:

ANOVA - عدد المتحولات المستقلة - كيفية قياس المتحولات المستقلة.

وفيما يلي بعض الأمثلة (حاول معرفة عدد المتحولات المستقلة وكيفية قياسها):

- ANOVA وحيد الاتجاه مستقل
- ANOVA ثنائي الاتجاه للقياسات المكررة
- ANOVA ثنائي الاتجاه مختلط
- ANOVA ثلاثي الاتجاه مستقل

والإجابات التي يجب الحصول عليها هي:

- متحول مستقل واحد يُقاس باستخدام مشتركين مختلفين.
- متحولين مستقلين اثنين يتم قياسهما باستخدام نفس المشتركين.
- متحولين مستقلين اثنين: يُقاس أحدهما باستخدام مشتركين مختلفين، والآخر باستخدام نفس المشتركين.
- ثلاثة متحولات مستقلة تُقاس جميعها باستخدام مشتركين مختلفين.

2.2.10 مثال بمتحولين مستقلين اثنين

سنتعامل في هذا الفصل مع مثال يحوي متحولَين مستقلين اثنين، ولذلك يدعى التحليل ANOVA ثنائي الاتجاه (انظر المربع 1.10). يهتم باحث في علم الإنسان بآثار الكحول على اختيار الرفيق في النوادي الليلية. والتعليل المنطقي هو أنه بعد تناول الكحول يصبح الإدراك الشخصي للجاذبية الجسدية غير دقيق. ويهتم هذا الباحث أيضاً بدراسة فيما إذا كان هذا الأثر مختلفاً بين الذكور والإناث. لذلك فقد اختار 48 طالباً: 24 ذكراً و24 أنثى. ثم اصطحبهم كمجموعات مؤلفة من 8

مشتركين إلى أحد النوادي الليلية وأعطى قسماً منهم مشروباً خالياً من الكحول، وأعطى قسماً آخر قدحين من البيرة، وأعطى قسماً ثالثاً 4 أقداح من البيرة. وفي نهاية السهرة التقط صورة الشخص الذي كان المشترك يتحدث معه. بعد ذلك عَرَضَ الصور على لجنة من الحكام المستقلين لتقييم جاذبية الشخص في الصورة (كعلامة من 100). يحوي الملف goggles.sav والجدول 1.10 هذه البيانات.

الكحول	خالي من الكحول		قدحين من البيرة		4 أقداح من البيرة	
الجنس	ذكر	أنثى	ذكر	أنثى	ذكر	أنثى
	50	65	45	70	30	55
	55	70	60	65	30	65
	80	60	85	60	30	70
	65	60	65	70	55	55
	70	60	70	65	35	55
	75	55	70	60	20	60
	75	60	80	60	45	50
	65	55	60	50	40	50
الكلي	535	485	535	500	285	460
المتوسط	66.875	60.625	66.875	62.50	35.625	57.50
التباين	106.70	24.55	156.70	42.86	117.41	50.00

الجدول 1.10 البيانات من الملف goggles.sav

3.2.10 المجموع الكلي للمربعات (SS_T)

إن مبدأ ANOVA ثنائي الاتجاه مشابه جداً لـ ANOVA وحيد الاتجاه. إذ ما نزال نبحث عن المجموع الكلي لمربعات الأخطاء (SS_T) والتباين الذي يمكن تبريره من قبل النموذج (SS_M) والتباين الذي لا يمكن تبريره (SS_R). على كل حال، في ANOVA ثنائي الاتجاه يتكون التباين الذي يمكن تبريره من قبل النموذج من تلاعبَين تجريبيين اثنين. لذلك نقسم مجموع المربعات للنموذج إلى التباين الذي يمكن تبريره من قبل المتحول المستقل الأول (SS_A)، والتباين الذي يمكن تبريره من قبل المتحول المستقل الثاني (SS_B) والتباين الذي يمكن تبريره من قبل التفاعل بين هذين المتحولين ($SS_{A\times B}$).

ونبدأ بنفس الطريقة التي اتبعناها في ANOVA وحيد الاتجاه. أي أننا نحسب مقدار التغايرية بين العلامات عندما نهمل الحالة التجريبية التي تنتمي لها تلك العلامات. تذكّر من ANOVA وحيد الاتجاه (المعادلة (4.8)) أنه يتم حساب SS_T باستخدام المعادلة التالية:

$$SS_T = s^2_{grand}(N - 1)$$

إن التباين الكلي هو ببساطة التباين لجميع العلامات عندما نهمل المجموعة التي تنتمي إليها تلك العلامات. لذلك إذا أردنا معالجة البيانات كمجموعة كبيرة واحدة فإنها تأخذ الشكل:

55	30	70	45	65	50
65	30	65	60	70	55
70	30	60	85	60	80
55	55	70	65	60	65
55	35	65	70	60	70
60	20	60	70	55	75
50	45	60	80	60	75
50	40	50	60	55	65
المتوسط الكلي =58.33					

إذا حسبنا التباين لجميع هذه العلامات فإننا نحصل على 190.78. لقد استخدمنا 48 علامة لحساب هذه القيمة، أي أن N=48.

ولذلك تصبح المعادلة بالشكل:

$$SS_T = s^2_{grand}(N-1) = 190.78 \times (48-1) = 8966.66$$

ويكون عدد درجات الحرية للمجموع الكلي للمربعات هو N-1=47.

4.2.10 مجموع المربعات للنموذج (SS_M)

الخطوة التالية هي إيجاد مجموع المربعات للنموذج. وكما اقترحنا سابقاً فإنه سيتم تقسيم هذا المجموع إلى 3 مكونات: التباين الذي يبرره المتحول المستقل الأول (SS_A) والتباين الذي يبرره المتحول المستقل الثاني (SS_B) والتباين الذي يبرره التفاعل بين هذين المتحولين ($SS_{A\times B}$).

قبل تقسيم مجموع المربعات للنموذج إلى مكوناته الثلاثة، علينا حساب قيمته أولاً. نعلم من الخطوة السابقة أنه لدينا 8966.66 وحدة من التباين المطلوب تبريرها، والخطوة الأولى هي حساب الجزء من ذلك التباين الذي يمكن تبريره بالتلاعب التجريبي الكلي (دون معرفة المتحول المستقل المسؤول عن ذلك). عند تنفيذ ANOVA وحيد الاتجاه وجدنا مجموع المربعات للنموذج بالنظر إلى الفرق بين المتوسط لكل مجموعة والمتوسط الكلي (انظر الفقرة 5.2.8). ويمكننا تنفيذ هذه العملية هنا أيضاً. لدينا عملياً 6 مجموعات تجريبية وذلك إذا جمّعنا كل المستويات للمتحولين المستقلين (3 جرعات للمشتركين الذكور، و3 جرعات للمشتركات الإناث). بما أنه لدينا 6 مجموعات مختلفة من الأشخاص فإنه يمكننا تطبيق المعادلة المستخدمة في حالة ANOVA وحيد الاتجاه لحساب مجموع المربعات للنموذج (المعادلة (5.8)):

$$SS_M = \sum n_k(\bar{x}_k - \bar{x}_{grand})^2$$

المتوسط الكلي هو المتوسط لكل العلامات (وقد حسبناه سابقاً وكانت قيمته 58.33)، و n هو عدد العلامات في كل مجموعة (أي عدد المشتركين في كل مجموعة من المجموعات التجريبية الست، ويساوي 8 في هذا المثال). لذلك تصبح المعادلة بالشكل:

$$SS_M = 8 \times (60.625 - 58.33)^2 + 8 \times (66.875 - 58.33)^2 + 8 \times (62.5 - 58.33)^2$$
$$+ 8 \times (66.875 - 58.33)^2 + 8 \times (57.5 - 58.33)^2 + 8 \times (35.625 - 58.33)^2$$
$$SS_M = 5479.167$$

ويكون عدد درجات الحرية لمجموع المربعات للنموذج أقل بواحد من عدد المجموعات المستخدمة (k=6) أي $df_M=6-1=5$.

عند هذه المرحلة أصبحنا نعلم أن النموذج (التلاعبين التجريبيين) يمكنه تبرير 5479.167 وحدة من التباين الكلي البالغ 8966.66 وحدة. المرحلة التالية هي تقسيم مجموع المربعات للنموذج لمعرفة مقدار التباين الذي يمكن تبريره من قبل كل من المتحولين المستقلين بشكل منفصل.

1.4.2.10 الأثر الرئيسي للجنس (SS_A)

لإيجاد التباين الذي يساهم به المتحول المستقل الأول (وهو الجنس Gender في هذه الحالة) فإننا نقوم بتجميع العلامات في مجموعة البيانات وفقاً للجنس الذي تنتمي إليه هذه العلامات. لذلك نهمل جرعة الكحول التي تم تناولها، ونضع جميع علامات الذكور في مجموعة واحدة، وجميع علامات الإناث في مجموعة أخرى. لذلك تأخذ البيانات الشكل التالي:

الإناث: A1

55	70	65
65	65	70
70	60	60
55	70	60
55	65	60
60	60	55
50	60	60
50	50	55
المتوسط للإناث =60.21		

الذكور: A2

30	45	50
30	60	55
30	85	80
55	65	65
35	70	70
20	70	75
45	80	75
40	60	65
المتوسط للذكور =56.46		

نستطيع بعد ذلك تطبيق المعادلة التي استخدمناها سابقاً لحساب المجموع الكلي لمربعات النموذج من أجل حساب مجموع المربعات للنموذج:

$$SS_A = \sum n_k(\overline{x}_k - \overline{x}_{grand})^2$$

المتوسط الكلي هو المتوسط لجميع العلامات (58.33)، و n عدد العلامات في كل مجموعة (أي عدد الذكور وعدد الإناث ويساوي 24 في هذه الحالة). لذلك تأخذ المعادلة الشكل التالي:

$$SS_{Gender} = 24 \times (60.21 - 58.33)^2 + 24 \times (56.46 - 58.33)^2$$

$$SS_{Gender} = 168.75$$

ويكون عدد درجات الحرية لهذا المجموع أقل بواحد من عدد المجموعات (k)، وبما أنه لدينا مجموعتان فقط (مجموعة الذكور ومجموعة الإناث) فإن عدد درجات الحرية يكون $df_A=2-1=1$.

2.4.2.10 الأثر الرئيسي للكحول (SS_B)

لإيجاد التباين الذي يساهم به المتحول المستقل الثاني (وهو الكحول Alcohol في هذه الحالة) فإننا نقوم بتجميع العلامات في مجموعة البيانات وفقاً لمقدار الكحول الذي استهلكته. لذلك نهمل جنس المشترك، ونضع جميع علامات المشتركين الذين لم يتناولوا الكحول في مجموعة واحدة، وجميع علامات المشتركين الذين تناولوا قدحين من البيرة في مجموعة ثانية، وجميع علامات المشتركين الذين تناولوا 4 أقداح من البيرة في مجموعة ثالثة، لذلك تأخذ البيانات الشكل التالي:

خالي من الكحول: B1	
65	50
70	55
60	80
60	65
60	70
55	75
60	75
55	65
المتوسط =63.75	

قدحين من البيرة: B2	
70	45
65	60
60	85
70	65
65	70
60	70
60	80
50	60
المتوسط =64.6875	

4 أقداح بيرة: B3	
55	30
65	30
70	30
55	55
55	35
60	20
50	45
50	40
المتوسط =46.5625	

نستطيع بعد ذلك تطبيق المعادلة التي استخدمناها سابقاً لحساب المجموع الكلي لمربعات النموذج من أجل حساب مجموع المربعات للنموذج:

$$SS_B = \Sigma n_k(\overline{x}_k - \overline{x}_{grand})^2$$

المتوسط الكلي هو المتوسط لجميع العلامات (58.33)، و n عدد العلامات في كل مجموعة (عدد العلامات في كل من المربعات السابقة ويساوي 16 في هذه الحالة). لذلك تأخذ المعادلة الشكل التالي:

$$SS_{alcohol} = 16(63.75-58.33)^2+16(64.6875-58.33)^2+16(46.5625-85.33)^2$$

$$SS_{alcohol} = 3332.292$$

ويكون عدد درجات الحرية لهذا المجموع أقل بواحد من عدد المجموعات (k=3) أي أن $df_B=3-1=2$.

3.4.2.10 أثر التفاعل ($SS_{A\times B}$)

المرحلة الأخيرة هي حساب مقدار التباين الذي يمكن أن يبرره التفاعل بين المتحولين. إن أبسط طريقة لتنفيذ ذلك هي أن نتذكر أن SS_M مؤلف من 3 مكونات (SS_A وSS_B و$SS_{A\times B}$)، وبما أننا نعلم قيمة كل من SS_A وSS_B فإنه يمكننا حساب $SS_{A\times B}$ من المعادلة التالية:

$$SS_{A\times B} = SS_M - (SS_A + SS_B)$$

$$SS_{A\times B} = 5479.167 - (168.75 + 3332.292)$$

$$SS_{A\times B} = 1978.125$$

ويمكن حساب عدد درجات الحرية بنفس الطريقة:

$$df_{A\times B} = df_M - (df_A + df_B) = 5 - (1 + 2) = 2$$

كما أنه يساوي أيضاً جداء عدد درجات الحرية للآثار الرئيسية:

$$df_{A\times B} = df_A \times df_B = 1 \times 2 = 2$$

5.2.10 مجموع المربعات للبواقي (SS_R)

يتم حساب مجموع المربعات للبواقي بنفس الطريقة المتبعة من أجل ANOVA وحيد الاتجاه (انظر الفقرة 6.2.8) وهو يمثل الفروق الفردية في الأداء أو التباين الذي لا يمكن تبريرها من قبل العوامل التي تم التلاعب بها بشكل منهجي. وقد رأينا في ANOVA وحيد الاتجاه أنه يتم حساب تلك القيمة بأخذ مربع الخطأ بين كل نقطة من البيانات ومتوسط المجموعة الموافقة لها. وهناك طريقة بديلة للتعبير عن ذلك هي (انظر المعادلة (7.8)):

$$SS_R = s^2_{group1}(n_1 - 1) + s^2_{group2}(n_2 - 1) + s^2_{group3}(n_3 - 1) + \cdots + s^2_{groupn}(n_n - 1)$$

وهكذا، نستخدم البيانات الفردية لكل مجموعة ونضربها بحد يساوي عدد الأشخاص في المجموعة ناقصاً منه 1. يحوي الجدول 1.10 التباينات الفردية لكل مجموعة، وهناك 8 أشخاص في كل مجموعة (n=8) ولذلك تأخذ المعادلة الشكل:

$$SS_R = (24.55)(8 - 1) + (106.7)(8 - 1) + (42.86)(8 - 1) + (156.7)(8 - 1) + (50)(8 - 1) + (117.41)(8 - 1)$$

$$SS_R = 3487.52$$

ويكون عدد درجات الحرية لكل مجموعة أقل بواحد من عدد العلامات في المجموعة (n=8). ولذلك إذا جمعنا درجات الحرية لكل المجموعات فإننا نحصل على $df_R=6\times7=42$.

6.2.10 النسب F

لكل أثر في ANOVA ثنائي الاتجاه (الأثرين الرئيسيين والتفاعل بينهما) نسبة F الخاصة به. لحساب هذه النسب علينا أولاً حساب متوسط المربعات لكل أثر وذلك بتقسيم مجموع المربعات على عدد درجات الحرية الموافق (انظر الفقرة 7.2.8). نحتاج أيضاً لمتوسط المربعات لحد الباقي. ومن أجل هذا المثال علينا حساب 4 قيم لمتوسط المربعات كما يلي:

$$MS_A = \frac{SS_A}{df_A} = \frac{168.75}{1} = 168.75$$

$$MS_B = \frac{SS_B}{df_B} = \frac{3332.292}{2} = 1666.146$$

$$MS_{A\times B} = \frac{SS_{A\times B}}{df_{A\times B}} = \frac{1978.125}{2} = 989.062$$

$$MS_R = \frac{SS_R}{df_R} = \frac{3487.52}{42} = 83.036$$

يتم ذلك بعد حساب النسب F لكل من المتحولين المستقلين والتفاعل بينهما بتقسيم متوسط المربعات على متوسط المربعات للباقي، وهي نفس العملية المتبعة في ANOVA وحيد الاتجاه:

$$F_A = \frac{MS_A}{MS_R} = \frac{168.75}{83.036} = 2.032$$

$$F_B = \frac{MS_B}{MS_R} = \frac{1666.146}{83.036} = 20.065$$

$$F_{A\times B} = \frac{MS_{A\times B}}{MS_R} = \frac{989.062}{83.036} = 11.911$$

يمكن مقارنة كل نسبة من هذه النسب مع القيم الحرجة (اعتماداً على عدد درجات الحرية، الذي يمكن أن يكون مختلفاً بين الآثار) لمعرفة فيما إذا كانت الآثار تعكس البيانات التي نتجت بالصدفة، أو أنها تعكس أثراً للتلاعب التجريبي الذي قمنا به (يمكن إيجاد القيم الحرجة من الملحق A3). إذا تجاوزت قيمة F المراقبة القيم الحرجة الموافقة فإنها تكون ذات دلالة. سيقوم برنامج SPSS بحساب النسب F والدلالة الدقيقة لكل منها، ولكن نأمل أننا وفقنا في هذه الفقرة في توضيح أن ANOVA ثنائي الاتجاه مماثل بشكل أساسي لـ ANOVA وحيد الاتجاه باستثناء أن مجموع المربعات للنموذج مؤلف من ثلاثة مكونات: الأثر لكل من المتحولين المستقلين، وأثر التفاعل بين هذين المتحولين المستقلين.

3.10 تنفيذ ANOVA العاملي باستخدام برنامج SPSS

1.3.10 إدخال البيانات والوصول لمربع الحوار الرئيسي

لإدخال بيانات المثال في محرر البيانات لبرنامج SPSS تذكر القاعدة الذهبية: توضع مستويات المتحول بين المجموعات في عمود وحيد. بتطبيق هذه القاعدة على البيانات فإننا بحاجة لمتحولي ترميز في محرر البيانات. يمثل هذان العمودان الجنس واستهلاك الكحول. لذلك ننشئ المتحول gender في محرر البيانات وننشط مربع الحوار Labels لتعريف تسميات تمثل الجنسين. نستخدم الرمز 0 لتمثيل الذكور (male=0) والرمز 1 لتمثيل الإناث (female=1). بعد الانتهاء من ذلك، يمكننا إدخال القيمة 0 أو 1 في هذا العمود لتحديد المجموعة التي ينتمي إليها المشترك. ننشئ المتحول alcohol في محرر البيانات وننشط مربع الحوار Labels لتعريف تسميات تمثل القيم الثلاث لتناول الكحول: 1=خالي من الكحول (شراب تمويهي Placebo)، 2=قدحين من البيرة، 3=أربعة أقداح من البيرة. يمكننا الآن إدخال القيمة 1 أو 2 أو 3 في هذا العمود لتمثيل مقدار الكحول المستهلك من قبل المشترك. تذكّر أنه إذا قمت بتفعيل خيار عرض التسميات فإنك سترى نصاً في محرر البيانات بدلاً من القيم العددية. ونعرض الآن طريقة عمل هذا الترميز:

الجنس Gender	الكحول Alcohol	حالة المشترك
0	1	ذكر لم يتناول الكحول
0	2	ذكر تناول قدحين من البيرة
0	3	ذكر تناول 4 أقداح من البيرة
1	1	أنثى لم تتناول الكحول
1	2	أنثى تناولت قدحين من البيرة
1	3	أنثى تناولت 4 أقداح من البيرة

بعد إنشاء متحولي الترميز، يمكننا إنشاء متحول ثالث نضع فيه قيم المتحول التابع. ندعو هذا المتحول attract ونستخدم خيار التسمية لإعطائه الاسم التالي "attractiveness of date". في هذا المثال، استخدمنا متحولَين مستقلين ومشتركين مختلفين في كل حالة تجريبية، لذلك يمكننا استخدام إجرائية ANOVA العاملية العامة في برنامج SPSS، وهي مصممة لتحليل التصاميم العاملية بين المجموعات.

للوصول إلى مربع الحوار الرئيسي لهذه الإجرائية نستخدم أمر القائمة Analyze ⇒ General Linear Model ⇒ Univariate ... يبين الشكل 1.10 مربع الحوار الناتج. نختار أولاً المتحول التابع attract من لائحة المتحولات في القسم الأيسر من مربع الحوار وننقله إلى الحيز المسمى Dependent Variable (المتحول التابع) بنقر الزر الموجود بين القسمين. نضع في الحيز المسمى Fixed Factor(s) (العوامل الثابتة) المتحولات المستقلة المتعلقة بالتحليل. لذلك نختار المتحولين gender وalcohol من لائحة المتحولات وننقلهما إلى الحيز Fixed Factor(s) بنقر الزر الموجود بين

القسمين. هناك أماكن أخرى في مربع الحوار يمكن استخدامها لتنفيذ عمليات تحليل أكثر تعقيداً مثل ANOVA ذات العوامل العشوائية (وهي خارج إطار هذا الكتاب) وANOVA العاملية (وهي توسيع للمفاهيم المعروضة في الفصل 9 حول ANCOVA العاملية).

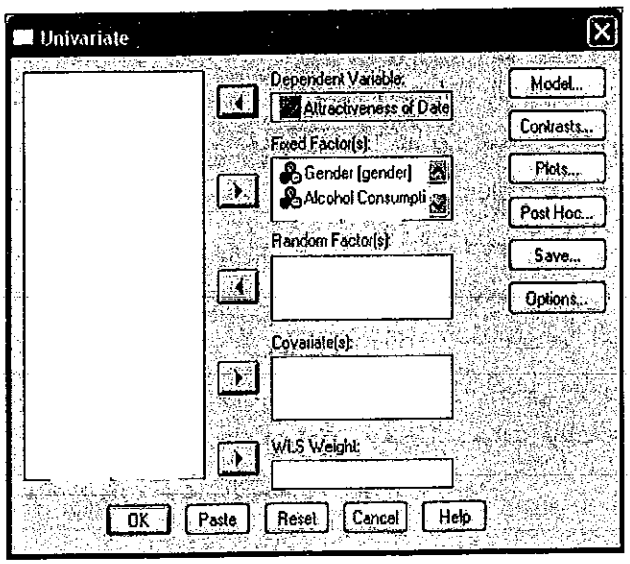

الشكل 1.10 مربع الحوار الرئيسي من أجل ANOVA وحيد المتغير

2.3.10 النماذج المخصصة

يقوم برنامج SPSS بشكل افتراضي بتنفيذ تحليل عاملي كامل (يتضمن الآثار الرئيسية والتفاعلات لجميع المتحولات المستقلة المحددة في مربع الحوار الرئيسي). ولكننا نرغب أحياناً بتخصيص النموذج الذي نريد استخدامه لاختبار أمور محددة. للوصول إلى مربع الحوار Model ننقر الزر Model... في مربع الحوار الرئيسي فنحصل على مربع الحوار المبين في الشكل 2.10. لاحظ أنه قد تم اختيار النموذج العاملي الكامل بشكل افتراضي. ومع هذا التحديد ما زال هناك خيار في القسم السفلي من مربع الحوار لتغيير نوع مجاميع المربعات التي نريد استخدامها في التحليل. ومع أننا تحدثنا سابقاً عن مجاميع المربعات وما يمثله كل منها، إلا أننا لم نتحدث عن الطرق المختلفة لحسابها. وليس من الضروري فهم طريقة حساب الأشكال المختلفة لمجاميع المربعات، ولكن من الضروري معرفة استخدام بعض هذه الأنواع المختلفة. يستخدم برنامج SPSS بشكل افتراضي مجاميع المربعات من النوع الثالث (Type III) التي تتميز بأنها لا تتأثر بتكرارات الخلايا. ولذلك يمكن استخدمها في التصاميم المتوازنة وغير المتوازنة (أعداد مختلفة من المشتركين في المجموعات المختلفة) وهذا ما يبرر أنها الخيار الافتراضي. أما مجاميع المربعات من النوع الرابع (Type IV) فهي شبيهة بالنوع الثالث ولكن يمكن استخدامها مع البيانات التي تحوي قيماً مفقودة. لذلك إذا كانت هناك قيم مفقودة في التصميم فعليك تغيير نوع مجموع المربعات ليصبح من النوع الرابع.

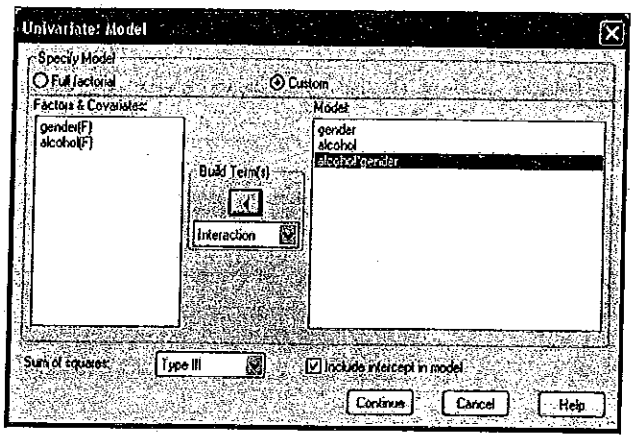

الشكل 2.10 النماذج المخصصة في ANOVA

لتخصيص نموذج ما، انقر الخيار Custom لتنشيط مربع الحوار. إن المتحولات المحددة في مربع الحوار الرئيسي تكون معروضة في القسم الأيسر من مربع الحوار، ويكون اسم المتحول متبوعاً بحرف يدل على نوعه (F=عامل ثابت (Fixed Factor)، R=عامل عشوائي (Random Factor)، C=متغير مشترك (Covariate)). يمكنك اختيار متحول واحد أو أكثر من هذه اللائحة ونقلها إلى الحيز المسمى Model كآثار رئيسية أو تفاعلات. ينقل برنامج SPSS المتحولات كتفاعل بشكل افتراضي، ولكن هناك عدة خيارات تسمح بإدخال الآثار الرئيسية أو تفاعلات ثنائية أو ثلاثية أو رباعية الاتجاه. وتحمي هذه الخيارات المستخدم من مشاكل اختيار عدد كبير من التراكيب للمتحولات (فعلى سبيل المثال، يمكنك اختيار ثلاثة متحولات ونقلها كتفاعلات ثنائية الاتجاه فيقوم البرنامج بإنشاء التراكيب الثلاثة المحتملة للمتحولات). ومع أن لاختيار النموذج عدة استخدامات هامة (انظر الفقرة 6.9) فمن المحتمل أنك لن تقوم بتنفيذ تحليل عاملي كامل في معظم الأحيان.

3.3.10 رسم التفاعلات

بعد الانتهاء من اختيار المتحولات المتعلقة بالتحليل، يجب عليك نقر الزر ...Plots للوصول إلى مربع الحوار المبين في الشكل 3.10. يسمح مربع الحوار Plots باختيار المخططات البيانية الخطية للبيانات، وهذه المخططات مفيدة جداً في تفسير آثار التفاعلات. لدينا متحولان مستقلان فقط، ولذلك يوجد مخطط بياني واحد يستحق أن ننظر إليه (وهو المخطط الذي يعرض مستويات أحد المتحولات المستقلة مع المتحول المستقل الآخر). نختار المتحول alcohol من لائحة المتحولات في القسم الأيسر من مربع الحوار وننقله إلى الحيز المسمى Horizontal Axis ليكون المحور الأفقي للمخطط. نضع في الحيز المسمى Separate Lines المتحول المستقل الآخر gender. بعد نقل المتحولين المستقلين إلى مكانهما المناسب ننقر الزر Add حيث تتم إضافة هذا المخطط إلى اللائحة في القسم السفلي من مربع الحوار. من الواضح أنه يمكننا رسم مجموعة متنوعة من المخططات، ولو

كان لدينا متحول مستقل ثالث لأصبح لدينا خيار لرسم مخططات مختلفة لكل مستوى من مستويات المتحول الثالث. يساعدنا المخطط الذي اخترناه في تفسير التفاعل بين الجنس واستهلاك الكحول. عند الانتهاء من تحديد المخططات ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

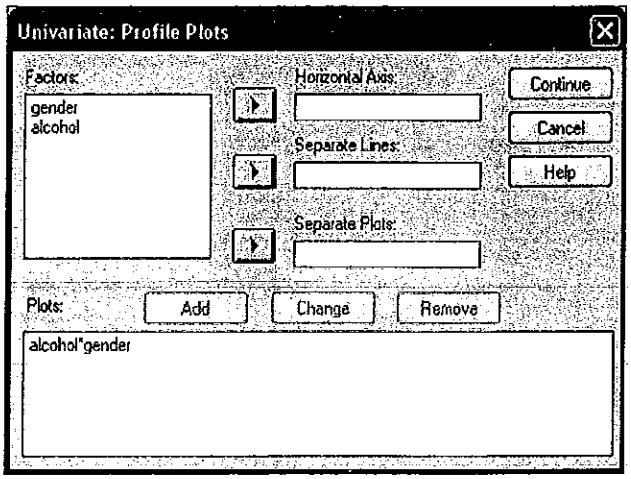

الشكل 3.10 مربع الحوار لرسم المخططات (Plots)

4.3.10 المقارنات

رأينا في الفصل 8 أنه من المفيد تنفيذ المقارنات بعد ANOVA لتقسيم الآثار الرئيسية ولمعرفة أماكن توضع الفروق بين المجموعات. في ANOVA وحيد الاتجاه يملك برنامج SPSS إجرائية لإدخال الرموز التي تحدد المقارنات التي نريد تنفيذها. أما في ANOVA ثنائي الاتجاه فلا تتوفر مثل تلك الإجرائية ويكون خيارنا محصوراً بتنفيذ إحدى المقارنات القياسية المتوفرة. يعرض الجدول 6.8 هذه المقارنات القياسية. ولكي نكون منصفين فإن هذه المقارنات تعطي ما تطلبه منها في عدد من الحالات المختلفة، ولكنها إذا لم تحقق المطلوب وأردت تعريف المقارنات الخاصة بك فإن عليك إنجاز ذلك باستخدام القواعد (Syntax). ويحوي الملف الملحق A.10 دليلاً مفصلاً لكيفية ذلك.

يمكننا استخدام المقارنات القياسية من أجل هذا المثال. يملك أثر الجنس مستويين فقط (ذكر وأنثى)، لذلك فإننا لا نحتاج فعلياً إلى المقارنات للأثر الرئيسي. أما أثر الكحول فيملك 3 مستويات (بدون كحول، قدحين، 4 أقداح). يمكننا اختيار مقارنة بسيطة لهذا المتحول ونستخدم الفئة الأولى كفئة مرجعية. ستتم مقارنة المجموعة التي تناولت قدحين من البيرة مع المجموعة التي تناولت شراباً تمويهياً (خالياً من الكحول)، ثم مقارنة المجموعة التي تناولت 4 أقداح من البيرة مع المجموعة التي تناولت شراباً خالياً من الكحول. وهكذا تتم مقارنة مجموعات الكحول مع مجموعة الشراب التمويهي. يمكننا أيضاً أن نختار مقارنة مكررة، حيث تتم مقارنة المجموعة التي تناولت قدحين مع مجموعة الشراب التمويهي، ثم مقارنة المجموعة التي تناولت 4 أقداح مع المجموعة التي تناولت قدحين

(إنها تتنقل بين المجموعات وذلك بمقارنة كل مجموعة مع المجموعة التي تسبقها). يمكننا أيضاً تنفيذ مقارنة Helmert التي تقارن كل فئة مع كل الفئات اللاحقة، وفي هذه الحالة تقوم بمقارنة مجموعة الشراب التمويهي مع جميع المجموعات التي تناولت كحولاً، ثم تنتقل إلى الفئة التي تناولت قدحين وتقوم بمقارنتها مع الفئة التي تناولت 4 أقداح. إن جميع هذه المقارنات جيدة ولكنها تعطينا المقارنات للآثار الرئيسية فقط. ولكننا في معظم الأحيان نريد المقارنة لحد التفاعل، ولا يمكن الحصول عليه إلا عن طريق القواعد (Syntax).

للحصول على المقارنات للأثر الرئيسي للكحول، انقر الزر ...Contrasts في مربع الحوار الرئيسي. لقد استخدمنا مربع الحوار Contrasts سابقاً في الفقرة 3.3.9، ويمكنك العودة لتلك الفقرة لاختيار مقارنة Helmert من أجل المتحول alcohol. بعد الانتهاء من اختيار المقارنات (كما في الشكل 4.10) انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

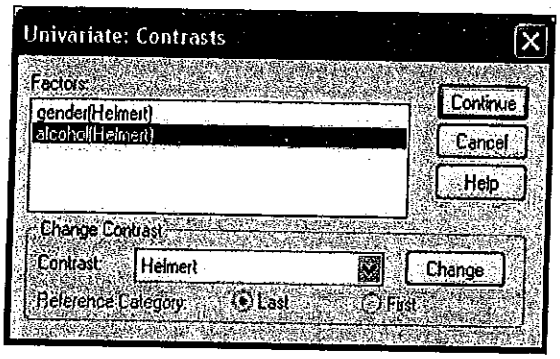

الشكل 4.10 مربع الحوار المقارنات Contrasts

5.3.10 اختبارات post hoc

للحصول على اختبارات post hoc انقر الزر ...Post Hoc في مربع الحوار الرئيسي فيتم فتح مربع الحوار المبين في (الشكل 5.10). للمتحول gender مستويان فقط ولذلك لا نحتاج لاختبارات post hoc لهذا المتحول (لأن الآثار ذات الدلالة تعكس الفروق بين الذكور والإناث فقط). أما المتحول alcohol فيملك 3 مستويات (خالي من الكحول، قدحين، 4 أقداح)، لذلك يكون من الضروري تنفيذ اختبارات post hoc. نختار المتحول alcohol من الحيز المسمى Factors وننقله إلى الحيز المسمى Post Hoc Tests for. وقد عرضنا في الفقرة 11.2.8 النصائح والتوجيهات لاختيار إجرائية post hoc التي نريد استخدامها. ولذلك نكتفي بالقول أننا سنختار الإجرائيات المبينة في الشكل 5.10. انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

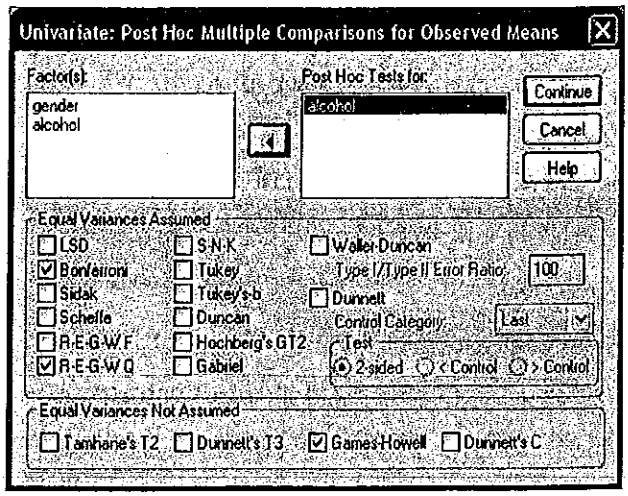

الشكل 5.10 مربع الحوار لاختبارات post hoc

6.3.10 الخيارات

انقر الزر ...Options لتفعيل مربع الحوار المبين في (الشكل 6.10). إن الخيارات من أجل ANOVA العاملي بسيطة نسبياً. يمكنك في البداية تحديد الإحصائيات الوصفية التي تعرض جدولاً لقيم المتوسط والانحراف المعياري والخطأ المعياري ومجال الثقة لقيم المتوسط لكل مجموعة. وهذا الخيار مفيد لأنه يساعد في تفسير النتائج النهائية. وهناك خيار حيوي آخر هو اختبار تجانس التباين. وكما في حالة الاختبار t فإن هناك فرضية تَساوي التباينات للمجموعات، لذلك فإن تحديد هذا الخيار يسمح باختبار تحقق هذه الفرضية. يستخدم برنامج SPSS اختبار Levene الذي يختبر فرضية أن التباينات للمجموعات هي متساوية. بعد الانتهاء من تحديد هذه الخيارات، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي ثم انقر الزر OK لتنفيذ التحليل.

4.10 الخرج من ANOVA العاملي

1.4.10 الخرج من التحليل التمهيدي

يعرض الخرج 1.10 الخرج الأولي من ANOVA العاملي. وقد تم عرض جدول الإحصائيات الوصفية لأننا حددنا هذا الخيار في مربع الحوار Options (الشكل 6.10)، وهو يعرض قيم المتوسط والانحراف المعياري وعدد المشتركين في جميع الحالات التجريبية. فعلى سبيل المثال يمكننا أن نرى أنه في حالة الشراب التمويهي (الخالي من الكحول) يتحدث الذكور مع أنثى ذات معدل 67% على مقياس الجاذبية، بينما تختار الإناث ذكراً معدله 61% على ذلك المقياس. وستكون قيم المتوسط مفيدة في تفسير اتجاه أي من الآثار التي تنتج عن هذا التحليل.

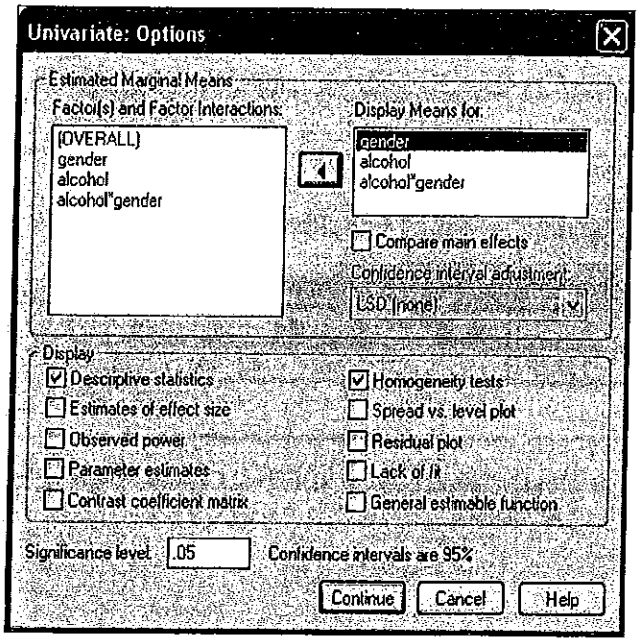

الشكل 6.10 مربع الحوار الخيارات Options

Descriptive Statistics

Dependent Variable: Attractiveness of Date

Gender	Alcohol Consumption	Mean	Std. Deviation	N
Male	None	66.8750	10.32940	8
	2 Pints	66.8750	12.51784	8
	4 Pints	35.6250	10.83562	8
	Total	56.4583	18.50259	24
Female	None	60.6250	4.95516	8
	2 Pints	62.5000	6.54654	8
	4 Pints	57.5000	7.07107	8
	Total	60.2083	6.33815	24
Total	None	63.7500	8.46562	16
	2 Pints	64.6875	9.91106	16
	4 Pints	46.5625	14.34326	16
	Total	58.3333	13.81232	48

الخرج 1.10

2.4.10 اختبار Levene

يعرض الخرج 2.10 نتائج اختبار Levene. وقد درسنا اختبار Levene في الفقرة 6.3 وغيرها. وللاختصار فإننا نستخدم اختبار Levene لتقييم تحقق فرضية تَساوي التباينات (تجانس التباين). ويبحث اختبار Levene فيما إذا كان هناك أي فروق مهمة بين تباينات المجموعات، ولذلك فإن

أي نتيجة بدون دلالة (كما هي الحال هنا) تعني أن الفرضية محققة. إذا كان اختبار Levene ذا دلالة فإنه يجب اتخاذ خطوات لموازنة التباينات عبر تحويل البيانات (يمكن تحقيق هذه الغاية بأخذ الجذر التربيعي لجميع قيم المتحول التابع. انظر الفصل 3).

Levene's Test of Equality of Error Variances[a]

Dependent Variable: Attractiveness of Date

F	df1	df2	Sig.
1.527	5	42	.202

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a. Design: Intercept+GENDER+ALCOHOL+GENDER * ALCOHOL

الخرج 2.10

3.4.10 جدول ANOVA الأساسي

يعتبر الجدول المبين في الخرج 3.10 الجزء الأكثر أهمية في الخرج وذلك لأنه يخبرنا فيما إذا كان لأي من المتحولات المستقلة أثر على المتحول التابع. والأشياء المهمة التي يجب أن ننظر إليها في الجدول هي قيم الدلالة للمتحولات المستقلة. وأول ما يجب ملاحظته وجود أثر ذو دلالة للكحول (لأن قيمة الدلالة أصغر من 0.05). إن النسبة F عالية الدلالة، مما يدل على أن مقدار الكحول المستهلك يؤثر بشكل كبير على اختيار المشترك للشخص الذي سيتحادث معه. وهذا يعني بشكل إجمالي، أنه عندما نهمل جنس المشترك فإن مقدار الكحول يؤثر على اختيار الشريك. يدعى الأثر لمتحول ما عندما نأخذه بشكل منعزل بالأثر الرئيسي (Main effect). وأفضل طريقة لمعرفة معنى ذلك هو النظر إلى مخطط الأعمدة لمتوسط الجاذبية عند كل مستوى من مستويات الكحول (بإهمال الجنس تماماً). يمكن رسم هذا المخطط باستخدام قيم المتوسط الموجودة في الخرج 1.10 والخيار ...Bar من القائمة Graphs.

يوضح الشكل 7.10 أنه عند إهمال الجنس فإن الجاذبية الكلية للشريك المختار عند عدم تناول الكحول مماثلة تماماً لحالة تناول قدحين من البيرة (قيم المتوسط لهاتين المجموعتين متساوية تقريباً). وهكذا فمن المحتمل أن يعكس هذا الأثر الرئيسي ذو الدلالة انخفاض الجاذبية للشريك المختار عند تناول 4 أقداح من البيرة. ويبدو أن هذه النتيجة تشير إلى أن الشخص يرحب بقبول شريك أقل جاذبية بعد تناوله 4 أكواب من البيرة.

Tests of Between-Subjects Effects

Dependent Variable: Attractiveness of Date

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	5479.167[a]	5	1095.833	13.197	.000
Intercept	163333.333	1	163333.333	1967.025	.000
GENDER	168.750	1	168.750	2.032	.161
ALCOHOL	3332.292	2	1666.146	20.065	.000
GENDER * ALCOHOL	1978.125	2	989.062	11.911	.000
Error	3487.500	42	83.036		
Total	172300.000	48			
Corrected Total	8966.667	47			

a. R Squared = .611 (Adjusted R Squared = .565)

الخرج 3.10

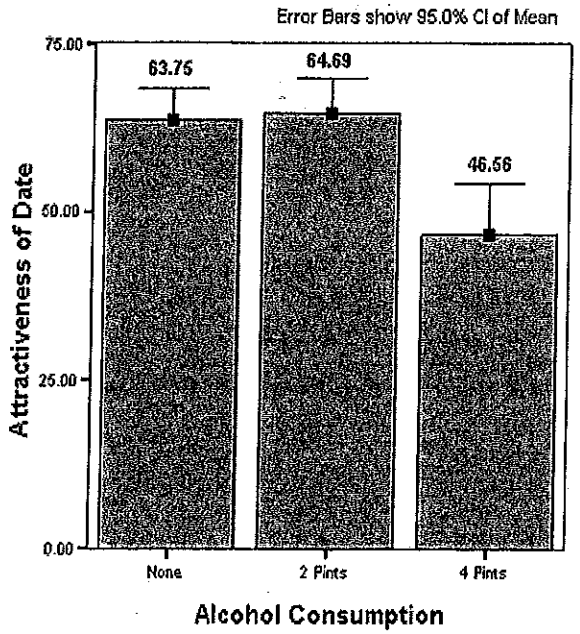

الشكل 7.10 مخطط يوضح الأثر الرئيسي للمتحول alcohol على اختيار الشريك

يدلنا القسم التالي من الخرج 3.10 على الأثر الرئيسي للجنس. في هذه المرة لم تكن النسبة F ذات دلالة (p=0.161>0.05). وهذا يعني بشكل إجمالي، أنه عندما نهمل كمية الكحول التي تناولها المشترك فإن جنس المشترك لا يؤثر على جاذبية الشريك الذي اختاره المشترك. وبعبارة أخرى، عند تساوي بقية العوامل فإن الذكور والإناث سيختارون شركاء ذوي جاذبية متساوية. برسم مخطط الأعمدة لمتوسط الجاذبية للذكور والإناث (وبإهمال مقدار الكحول المستهلك) فإننا نكتشف معنى

الأثر الرئيسي. يوضح الشكل 8.10 أن متوسط الجاذبية لشركاء المشتركين من الذكور والإناث متشابهة تقريباً (تختلف قيم المتوسط بمقدار 4% فقط). لذلك فإن عدم دلالة الأثر تعكس حقيقة أن متوسط الجاذبية متماثل. يمكننا أن نستنتج من ذلك أن الرجال والنساء اختاروا شركاء متماثلي الجاذبية.

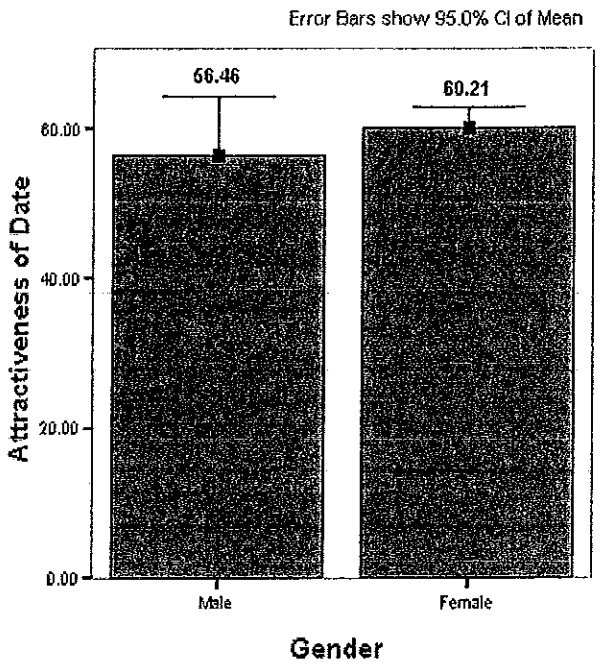

الشكل 8.10 مخطط يوضح الأثر الرئيسي للمتحول gender على اختيار الشريك

أخيراً، يدلنا الخرج 3.10 على التفاعل بين أثر الجنس وأثر الكحول. إن قيمة الدلالة للنسبة F عالية نوعاً ما (لأن $p<0.05$). ومعنى ذلك أن أثر الكحول على اختيار الشريك عند المشتركين الذكور مختلف عنه عند المشتركات الإناث. يتضمن الخرج المخطط الذي طلبنا رسمه في مربع الحوار المبين في الشكل 3.10. وهو يدلنا على طبيعة أثر التفاعل (انظر الشكل 9.10).

يوضح الشكل 9.10 أن للكحول أثراً صغيراً جداً على الإناث لأن جاذبية الشريك المختار بقيت شبه مستقرة من أجل حالات الكحول الثلاث (وهذا ما يوضحه الخط شبه الأفقي). أما من أجل الذكور فإن جاذبية الشريك المختارة بقيت مستقرة عند تَناوُل كمية قليلة من الكحول (قدحين فقط) ولكنها انحدرت بسرعة عند تناول المزيد من الكحول. تدل الخطوط عدم المتوازية على أثر مهم للتفاعل. وفي هذا المخطط تتقاطع تلك الخطوط مما يدل على تفاعل كبير بين المتحولات المستقلة. ويدلنا التفاعل على أن للكحول أثراً صغيراً على اختيار الشريك عند تناول 4 أقداح من البيرة وأن أثر الكحول هو الغالب عند المشتركين الذكور فقط. وباختصار، توضح هذه النتائج أن النساء تحافظ على معايير عالية في اختيار الشريك بغض النظر عن مقدار الكحول، بينما تختفي

المعايير عند الرجال بعد تناولهم عدداً من أقداح البيرة. توضح هذه البيانات أننا استنتجنا في وقت مبكر أن الكحول يؤثر بشكل كبير على مدى جاذبية الشريك المختار (الأثر الرئيسي للمتحول alcohol)، ولكن أثر التفاعل يدلنا على أن هذا الاستنتاج صحيح من أجل الذكور فقط. وهذا يبين مدى تضليل الآثار الرئيسية، ولذلك فإن التفاعل بين المتحولات يكون عادة هو الأكثر أهمية في التصميم العاملي.

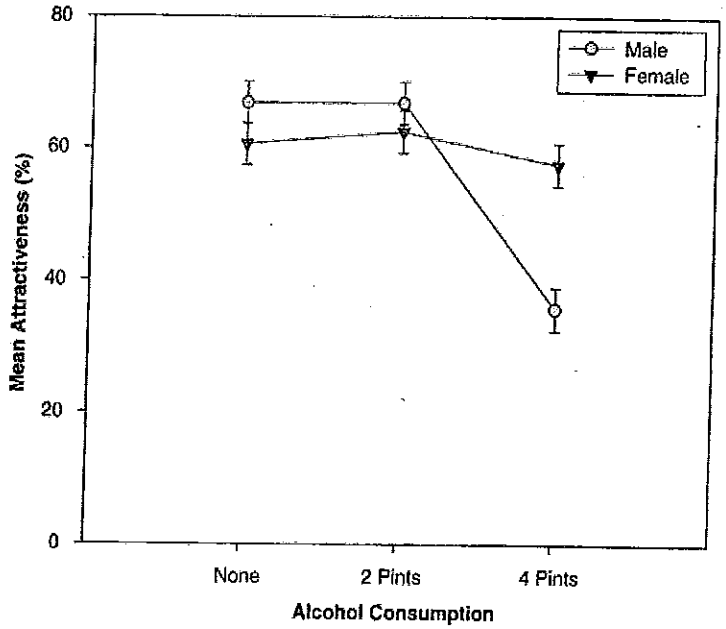

الشكل 9.10 مخطط يوضح أثر التفاعل بين الجنس واستهلاك الكحول على اختيار الشريك

4.4.10 المقارنات

يعرض الخرج 4.10 نتائج مقارنة Helmert على أثر الكحول. ويساعدنا ذلك في تقسيم أثر الكحول. يبين القسم العلوي من الجدول المقارنة بين المستوى الأول Level 1 وLater، وتعني في هذه الحالة مقارنة مجموعة الشراب التمويهي مع مجموعتي الكحول. وهي تختبر فيما إذا كان المتوسط لمجموعة الشراب التمويهي (63.75) مختلفاً عن المتوسط لمجموعتي الكحول معاً (64.69+46.56)/2=55.625). تبلغ قيمة الفرق بين هذين المتوسطين (63.75-55.625=8.125). وهي القيمة التي نراها في الجدول عند الصفين Difference و Contrast Estimate. والشيء المهم في هذا الجدول هو قيمة الدلالة .Sig التي تخبرنا فيما إذا كان هذا الفرق ذا دلالة أم لا. إن قيمة .Sig هي 0.006 (أصغر من 0.05) والآخر ذو دلالة. ويعطينا الجدول مجال الثقة لهذا الفرق، وبما أن هذا المجال لا يحوي القيمة 0 فإنه يمكننا أن نفترض أن هذه العينة هي واحدة من 95 عينة (من أصل 100) تعطي مجال ثقة يحوي القيمة الصحيحة للفرق، وبالتالي فإن القيمة الحقيقية للفرق هي

أكبر من 0 (وتقع بين 2.49 و13.76). وهكذا يمكننا أن نستنتج أن أثر الكحول (مهما كانت الكمية المستهلكة) هو تخفيض جاذبية الشريك الذي يتم اختياره مقارنة مع حالة عدم تناول الكحول. وهذا الاستنتاج مضلل لأن قيم المتوسط لمجموعة الشراب التمويهي والمجموعة التي تناولت قدحين من البيرة متماثلة تقريباً (64.69 و 63.75)، أي أن تناول قدحين من البيرة لا يخفض جاذبية الشريك المختار. والسبب وراء دلالة المقارنة أنها تختبر الأثر المركب لمجموعتي الكحول (قدحين و 4 أقداح) ولأن 4 أقداح تؤثر بشكل كبير على قيمة المتوسط. ويوضح هذا مدى الحذر الواجب اتخاذه عند تفسير هذه المقارنات، والنظر إلى المقارنات المتبقية أيضاً.

Contrast Results (K Matrix)

Alcohol Consumption Helmert Contrast			Dependent Variable: Attractiveness of Date
Level 1 vs. Later	Contrast Estimate		8.125
	Hypothesized Value		0
	Difference (Estimate - Hypothesized)		8.125
	Std. Error		2.790
	Sig.		.006
	95% Confidence Interval for Difference	Lower Bound	2.494
		Upper Bound	13.756
Level 2 vs. Level 3	Contrast Estimate		18.125
	Hypothesized Value		0
	Difference (Estimate - Hypothesized)		18.125
	Std. Error		3.222
	Sig.		.000
	95% Confidence Interval for Difference	Lower Bound	11.623
		Upper Bound	24.627

الخرج 4.10

يعرض القسم السفلي من الجدول المقارنة للمستوى الثاني Level 2 مع المستوى الثالث Level 3، وتعني في هذه الحالة مقارنة المجموعة التي تناولت قدحين مع المجموعة التي تناولت 4 أقداح. وهي تختبر فيما إذا كان المتوسط للمجموعة التي تناولت قدحين (64.69) مختلفاً عن المتوسط للمجموعة التي تناولت 4 أقداح (46.56). تبلغ قيمة الفرق بين هذين المتوسطين (64.69-46.56=18.13) وهي القيمة التي نراها في الجدول عند الصفين Difference و Contrast Estimate. ومرة أخرى، فإن الشيء المهم في هذا الجدول هو قيمة الدلالة .Sig التي تخبرنا فيما إذا كان هذا الفرق ذا دلالة أم لا. إن قيمة .Sig هي 0.000 (أصغر من 0.05) والأثر ذو دلالة. ويعطينا الجدول مجال الثقة لهذا الفرق، وبما أن هذا المجال لا يحوي القيمة 0 فإنه يمكننا أن نفترض أن هذه العينة هي واحدة من 95

عينة (من أصل 100) تعطي مجال ثقة يحوي القيمة الصحيحة للفرق، وبالتالي فإن القيمة الحقيقية للفرق هي أكبر من 0 (وتقع بين 24.63 و 11.62). ويدلنا ذلك على أن تناول 4 أقداح يخفض بشكل كبير جاذبية الشريك المختار مقارنة مع تناول قدحين فقط.

5.4.10 تحليل post hoc

تقسم اختبارات post hoc (الخرج 5.10) الأثر الرئيسي للكحول ويمكن تفسيرها كما لو تم تنفيذ ANOVA وحيد الاتجاه على المتحول alcohol. تعطي اختبارات Games-Howell وBonferroni نفس النمط من النتائج، فعندما يتناول المشتركون شراباً خالياً من الكحول أو قدحين من البيرة فإنهم يختارون شريكاً بنفس الجاذبية. ولكن بعد 4 أقداح يختار المشتركون شريكاً أقل جاذبية مما يختارونه عند تناول قدحين ($p<0.001$) أو شراباً خالياً من الكحول ($p<0.001$). من المهم ملاحظة أن قيم المتوسط لجاذبية الشريك بعد تناول شراب خال من الكحول أو قدحين من البيرة متشابهة بحيث أن الاحتمال للفرق الذي حصلنا عليه بين هذه المتوسطات هو 1 (محتمل تماماً). ويؤكد اختبار REGWQ أن قيم المتوسط لحالتي الشراب التمويهي وقدحي البيرة متساوية بينما المتوسط للمجموعة التي تناولت 4 أقداح مختلف. يجب ملاحظة أن اختبارات post hoc تهمل الأثر التفاعلي بين الجنس والكحول.

Multiple Comparisons

Dependent Variable: Attractiveness of Date

	(I) Alcohol Consumption	(J) Alcohol Consumption	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
Bonferroni	None	2 Pints	-.9375	3.22172	1.000	-8.9714	7.0964
		4 Pints	17.1875*	3.22172	.000	9.1536	25.2214
	2 Pints	None	.9375	3.22172	1.000	-7.0964	8.9714
		4 Pints	18.1250*	3.22172	.000	10.0911	26.1589
	4 Pints	None	-17.1875*	3.22172	.000	-25.2214	-9.1536
		2 Pints	-18.1250*	3.22172	.000	-26.1589	-10.0911
Games-Howell	None	2 Pints	-.9375	3.25860	.955	-8.9809	7.1059
		4 Pints	17.1875*	4.16380	.001	6.7981	27.5769
	2 Pints	None	.9375	3.25860	.955	-7.1059	8.9809
		4 Pints	18.1250*	4.35860	.001	7.3104	28.9396
	4 Pints	None	-17.1875*	4.16380	.001	-27.5769	-6.7981
		2 Pints	-18.1250*	4.35860	.001	-28.9396	-7.3104

Based on observed means.

*. The mean difference is significant at the .05 level.

Attractiveness of Date

	Alcohol Consumption	N	Subset 1	Subset 2
Ryan-Einot-Gabriel-Welsch Range[a]	4 Pints	16	46.5625	
	None	16		63.7500
	2 Pints	16		64.6875
	Sig.		1.000	.772

الخرج 5.10

والخلاصة، علينا أن نستنتج أن للكحول أثراً على جاذبية الشريك المختار. بشكل إجمالي، وبعد جرعة صغيرة نسبياً من الكحول (قدحين فقط) يبقى الإنسان محافظاً على قدراته بالحكم ومستويات الجاذبية للشريك المختار مقارنة مع مجموعة المراقبة (التي لم تتناول أية جرعة من الكحول). ولكن بعد جرعة كبيرة من الكحول، تنخفض جاذبية الشريك المختار بشكل كبير. وتدعى هذه الظاهرة بأثر beer-goggles. والأهم من ذلك هو أن التفاعل يبين تفاوت هذا الأثر حسب الجنس. إذ تنخفض مستويات الجاذبية للشريك الذي يختاره الرجل، بينما تحافظ المرأة على معاييرها رغم تناول الكحول. ولكن ما لا نعرفه حتى الآن هو هل ستتأثر المرأة بأثر beer-goggle عند الجرعات الأعلى من الكحول.

أفكار مهمة

- يقارن ANOVA ثنائي الاتجاه المستقل عدة قيم للمتوسط عند وجود متحولين اثنين، واستخدام مشتركين مختلفين في الحالات التجريبية المختلفة. فعلى سبيل المثال، عندما نريد معرفة فيما إذا كانت طرق التعليم المختلفة تتعامل بشكل أفضل مع المواضيع المختلفة. يمكنك اختيار طلاب يدرسون مواد مختلفة (علم نفس، جغرافيا، إدارة، إحصاء) وتدريسهم باعتماد المحاضرات أو المراجع.
- المتحولان المستقلان هما المادة وطريقة التدريس. والنتيجة يمكن أن تكون علامة الامتحان النهائي.
- اختبر تجانس التباين باستخدام اختبار Levene. اعثر على الجدول المسمى Levene's Test of Equality of Error Variances وابحث فيه عن قيمة الدلالة في العمود Sig. فإذا كانت القيمة أصغر من 0.05 فإن الفرضية قد تم خرقها.
- ابحث في الجدول المسمى Tests of Between- Subjects Effects عن قيمة الدلالة في العمود Sig. للآثار الثلاثة (هناك أثر رئيسي لكل من المتحولين المستقلين، والأثر للتفاعل بين هذين المتحولين) فإذا كانت القيمة أصغر من 0.05 فإن الأثر ذو دلالة. من أجل الآثار الرئيسية نستخدم اختبارات post hoc لمعرفة المجموعات المختلفة، أما من أجل أثر التفاعل فننظر إلى مخطط التفاعل أو ننفذ تحليل الآثار البسيطة (انظر المربع 2.10).
- من اختبارات post hoc، ابحث عن قيمة الدلالة في العمود Sig. لتعرف فيما إذا كانت المقارنات ذات دلالة أم لا (تكون المقارنات ذات دلالة إذا كانت قيمة الدلالة أصغر من 0.05).
- اختبر نفس الفرضيات كما في حالة ANOVA.

المربع 2.10 تحليل الآثار البسيطة

هناك طريقة شائعة لتقسيم حد التفاعل وتستخدم تقنية تدعى تحليل الآثار البسيطة (Simple effects analysis). وينظر هذا التحليل إلى أثر متحول مستقل معين عند المستويات المنفصلة للمتحول المستقل الآخر. فعلى سبيل المثال، ومن أجل بيانات beer-goggles يمكننا إجراء تحليل الآثار البسيطة بالنظر إلى أثر الجنس عند كل مستوى من مستويات الكحول. وهذا يعني أن نأخذ متوسط الجاذبية للشريك المختار من قبل الذكور ونقارنه مع متوسط الجاذبية للشريك المختار من قبل الإناث وذلك بعد تناول الشراب التمويهي، ونعيد المقارنة من أجل حالة تناول قدحين من البيرة، وأخيراً من أجل تناول أربعة أقداح من البيرة. هناك طريقة أخرى للنظر إلى ذلك وهي مقارنة كل مثلث في الشكل 9.10 مع الدائرة الموافقة له، ونتوقع أن لا نجد فرقاً من أجل حالة الشراب التمويهي وحالة القدحين (في كلتا الحالتين، يقع المثلث والدائرة في نفس الموضع تقريباً)، ونتوقع أن نجد فرقاً في حالة تناول 4 أقداح (لأن المسافة بين المثلث والدائرة كبيرة). الطريقة البديلة هي مقارنة الجاذبية في حالة الرجال بعد تناول الشراب التمويهي، وبعد تناول قدحين، وبعد تناول 4 أقداح، ثم تنفيذ نفس العملية في تحليل منفصل وذلك من أجل النساء (وهذا يشبه تنفيذ ANOVA وحيد الاتجاه على أثر الكحول في حالة النساء). لا يهمنا أن نعرف طريقة حساب الآثار البسيطة (ولكن إذا كنت مهتماً بذلك فيمكنك مراجعة الملف الملحق A6)، ولكن من المفيد معرفة كيفية تنفيذ ذلك في برنامج SPSS. لسوء الحظ لا يمكنك تنفيذ ذلك باستخدام مربعات الحوار وإنما باستخدام القواعد Syntax (انظر الفقرة 6.2 لتتذكر النافذة Syntax). إن البرنامج النصي الذي تحتاجه في هذا المثال هو التالي:

```
MANOVA
attract BY gender (0 1) alcohol (1 3)
```

يؤدي ذلك إلى بدء ANOVA بتحديد الخرج أو المتحول التابع (attract) يليه الأمر BY متبوعاً بالمتحولات المستقلة (alcohol, gender). تدل الأعداد بين القوسين على الحدود الدنيا والعظمى لرموز المجموعات التي استخدمناها لتعريف هذين المتحولين.

```
/DESIGN=gender WITHIN alcohol (1) gender WITHIN alcohol (2) gender WITHIN alcohol (3)
```

يحدد هذا السطر الآثار البسيطة. فعلى سبيل المثال، تطلب العبارة"gender WITHIN alcohol (1)" من برنامج SPSS أن يقوم بتحليل أثر المتحول gender عند المستوى (1) للمتحول alcohol (أي استخدام مجموعة الشراب التمويهي). يجب أن يرتبط الرقم بين القوسين مع مستوى المتحول الذي نريد النظر إليه (المستوى 1 هو المستوى الذي يملك أدنى رمز في محرر البيانات). إذا أردنا مقارنة المتحول alcohol عند المستويات المختلفة للمتحول gender فإن علينا كتابة السطر التالي:

```
/DESIGN= alcohol WITHIN gender (1) alcohol WITHIN gender (2)
/PRINT
CELLINFO
SIGNIF (UNIV MULT AVERF  HF GG).
```

تقوم الأسطر الأخيرة بطلب بعض الإحصائيات الوصفية لكل خلية من التحليل (CELLINFO) وطباعة ANOVA الأساسي (SIGNIF).

يحوي الملف GogglesSimpleEffects.sps هذا البرنامج النصي. بعد تحميل الملف goggles.sav افتح ملف البرنامج النصي وقم بتنفيذه. الخرج الذي نحصل عليه سيكون بشكل نصي (بدلاً من الجداول). وجزء منه هو تكرار لنتائج ANOVA الأساسي (الخرج 3.10). يتم عرض الآثار البسيطة كما يلي:

```
******Analysis of Variance -- design 1******

Tests of Significance for attract using UNIQUE sums of squares
Source of Variation                SS      DF       MS        F  Sig of F

WITHIN+RESIDUAL                6819.79      44   155.00
GENDER WITHIN ALCOHOL(1)        156.25       1   156.25     1.01      .321
GENDER WITHIN ALCOHOL(2)         76.56       1    76.56      .49      .486
GENDER WITHIN ALCOHOL(3)       1914.06       1  1914.06    12.35      .001

(Model)                        2146.88       3   715.63     4.62      .007
(Total)                        8966.67      47   190.78

R-Squared =            .239
Adjusted R-Squared =   .188
```

بالنظر إلى قيم الدلالة لكل من الآثار البسيطة يظهر عدم وجود فرق مهم بين الرجال والنساء عند المستوى 1 من المتحول alcohol (الشراب الخالي من الكحول) أو عند المستوى 2 (تناول قدحين من البيرة)، ولكن هناك فرق مهم عند المستوى 3 (وهو ما يمكننا الحكم عليه من المخطط البياني حيث يكون المتوسط للرجال أدنى بكثير من المتوسط للنساء).

هناك أمر مفيد آخر ينبغي تنفيذه بعد دراسة أثر التفاعل وهو تنفيذ المقارنات على حد التفاعل. ولكن لسوء الحظ، لا يمكن تنفيذ ذلك إلا باستخدام القواعد، ولذلك فقد تم تحضير الملف لمساعدتك في ذلك، حيث يحوي مثالاً عن تحديد المقارنات عبر التفاعل.

5.10 تفسير مخططات التفاعل

لقد ألقينا نظرة على مخطط التفاعل عندما قمنا بتفسير التحليل في هذا الفصل. إن التفاعلات هامة جداً والمفتاح لفهم التفاعلات هي المقدرة على تفسير مخططات التفاعل (Interaction graphs). لقد استخدمنا (في المثال المدروس في هذا الفصل) الشكل 9.10 لاستنتاج أن التفاعل قد يعكس حقيقة أن الرجال والنساء قد اختاروا شركاء متساوي الجاذبية بعد تناول شراب تمويهي أو قدحين من البيرة فقط، ولكن بعد تناول 4 أقداح من البيرة تنخفض معايير الرجال بشكل أكبر من معايير النساء. تخيل أننا حصلنا على النتائج الموضحة في الشكل 10.10، هل تعتقد أنه مازال هناك أثر مهم للتفاعل؟

قد يعطي هذا النمط من البيانات زيادة في حد التفاعل ليكون ذا دلالة لأنه وعلى الرغم من تشابه الجاذبية بين الذكور والإناث بعد تناول الشراب التمويهي و 4 أقداح من البيرة فإن هناك فرقاً كبيراً بينهما بعد تناول قدحين من البيرة. وهذا يعكس وضعاً يكون فيه أثر beer-goggles متساوياً في الكبر عند الرجال والنساء بعد تناول 4 أقداح من البيرة (وهو غير موجود بعد تناول الشراب الخالي من الكحول)، ولكن زيادته أسرع عند الرجال، إذ أن جاذبية الشريك الذي يختاره الرجل تنخفض بعد تناول قدحين من البيرة، بينما تحافظ المرأة على معاييرها حتى 4 أقداح.

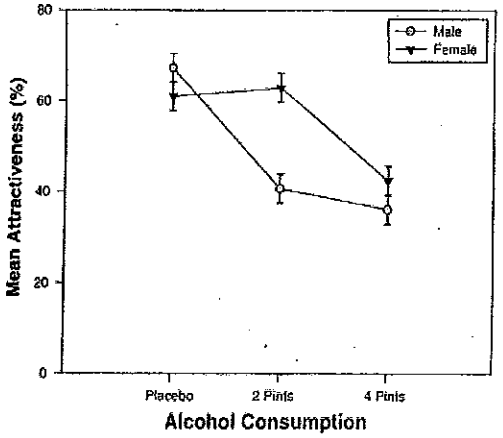

الشكل 10.10 مخطط آخر للتفاعل

لنأخذ مثالاً آخر، هل هناك تفاعل مهم في الشكل 11.10؟ من غير المحتمل أن يكون هناك تفاعل مهم لأن أثر الكحول هو ذاته للرجال والنساء. فمن أجل الرجال والنساء تكون جاذبية الشريك بعد تناول شراب خال من الكحول مرتفعة ولكنها تنخفض بعد تناول قدحين من البيرة بنفس المقدار (إن ميل الخط لكل من الذكر والأنثى هو ذاته تقريباً). وبعد تناول 4 أقداح هناك انخفاض إضافي، وهذا الانخفاض هو ذاته لكل من الرجل والمرأة (لأن ميل الخط لكل من الذكر والأنثى هو ذاته تقريباً). ويعكس وجود خط الذكر أسفل من خط الأنثى في جميع الحالات أن معايير الرجل أدنى من معايير المرأة، وهذا يعكس أثراً رئيسياً للجنس. ويمكن مما سبق أن نستنتج النقاط العامة التالية:

- تظهر التفاعلات ذات الدلالة من خلال الخطوط غير المتوازية على مخطط التفاعل. ولكن من المهم أن نتذكر أن عدم توازي الخطوط لا يعني بشكل تلقائي أن التفاعل ذو دلالة. وتعتمد دلالة التفاعل على درجة عدم توازي الخطوط.
- إذا تقاطعت الخطوط في مخطط التفاعل فهذا يعني بشكل بديهي أنها غير متوازية، ويمكن أن يكون ذلك مؤشراً على تفاعل ذو دلالة محتمل. ولكن بعكس المعتقد الشائع فإنها ليست الحالة دائماً أنه إذا كانت خطوط التفاعل متقاطعة فإن التفاعل ذو دلالة.

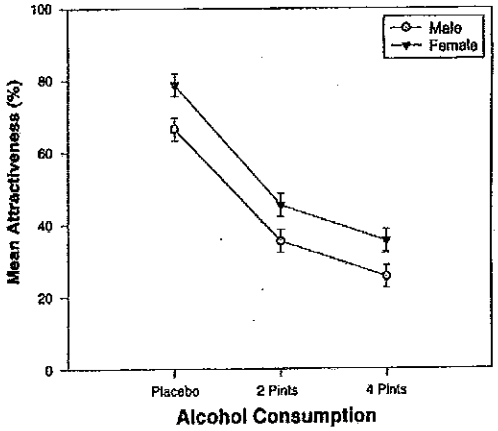

الشكل 11.10 مخطط فقدان التفاعل

وما يزيد الأمور تعقيداً أن يقوم الباحثون أحياناً برسم مخططات الأعمدة بدلاً من المخططات الخطية. يبين الشكل 12.10 بعض مخططات الأعمدة للتفاعلات بين متحولين مستقلين. يعرض المخطط (a) والمخطط (b) البيانات من المثال المستخدم في هذا الفصل. وكما ترى، هناك طريقتان لتقديم نفس البيانات، فالمخطط (a) يعرض البيانات عند وضع مستويات المتحول alcohol على المحور الأفقي وتبين الأعمدة الملونة المختلفة قيم المتوسط للذكور والإناث (المتحول gender)، بينما يعرض المخطط (b) الحالة المعاكسة حيث يتم وضع مستويات المتحول gender على المحور الأفقي وتستخدم الأعمدة الملونة المختلفة لتمثيل قيم المتوسط لجرعة الكحول (المتحول alcohol). ويبين هذان المخططان أثر التفاعل، وما نبحث عنه هو أن تكون الفروق بين الأعمدة الملونة مختلفة عند النقاط المختلفة على المحور الأفقي. لذلك فمن أجل المخطط (a) نحن ننظر إلى الفرق بين العمود الداكن والعمود الفاتح من أجل حالة الشراب الخالي من الكحول، ثم ننظر إلى حالة القدحين ونسأل "هل أن الفرق بين العمودين مختلف عما كان عليه من أجل حالة الشراب الخالي من الكحول؟". في هذه الحالة تبدو الأعمدة متماثلة في حالة الشراب الخالي من الكحول وحالة تناول قدحين من البيرة، لذلك لا يوجد تفاعل. ننتقل بعد ذلك لننظر إلى حالة 4 أقداح ونعيد طرح السؤال "هل الفرق بين الأعمدة مختلف عما كان عليه من أجل الحالتين الأخريين؟". في هذه الحالة يكون الجواب نعم، فمن أجل حالة الشراب الخالي من الكحول وحالة تناول قدحين كانت الأعمدة متقاربة في الارتفاع، ولكن من أجل الحالة 4 أقداح كان العمود الفاتح أطول من العمود الداكن. ويدل ذلك على تفاعل، إذ أن نمط الاستجابات قد تغير عند 4 أقداح. يعرض المخطط (b) نفس الشيء ولكنه مرسوم بطريقة ثانية. ننظر مرة أخرى إلى نمط الاستجابات. لذلك ننظر أولاً إلى حالة الرجال ونجد أن العمودين الأولين متساويا الارتفاع، ولكن العمود الأخير أقصر منهما. ويظهر أثر التفاعل من حقيقة أن للنساء نمطاً مختلفاً إذ أن الأعمدة الثلاثة متساوية الارتفاع تقريباً.

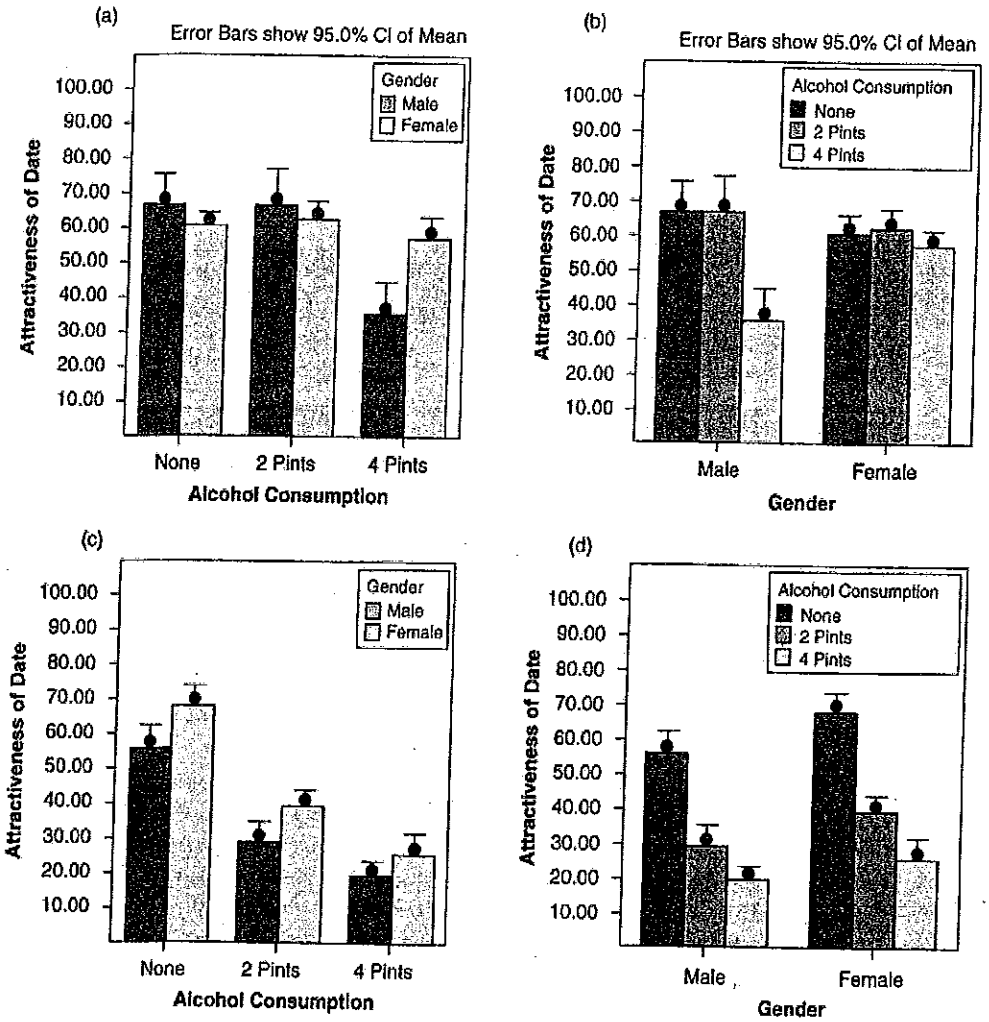

الشكل 12.10 توضح مخططات الأعمدة التفاعلات بين متحولين مستقلين

وماذا عن المخططين (c) و(d) هل تعتقد أن هناك تفاعلاً؟ يمثل هذان المخططان مجموعة من البيانات المختلفة عن التي استخدمناها في المثال الحالي ولكن بطريقتين مختلفتين. لننظر أولاً إلى المخطط (c)، فمن أجل بيانات الشراب الخالي من الكحول كان العمود الفاتح أطول من العمود الداكن، وعند الانتقال إلى بيانات القدحين نجد أن العمود الفاتح أطول قليلاً من العمود الداكن، وأخيراً من أجل بيانات 4 أقداح فإن العمود الفاتح أطول أيضاً من العمود الداكن. لقد وجدنا نفس النمط في جميع الحالات (العمود الفاتح أطول من العمود الداكن، أي أن النساء يحصلن على شركاء أكثر جاذبية من الرجال بغض النظر عن كمية الكحول المستهلك)، ولذلك لا يوجد أي تفاعل. لننظر الآن إلى المخطط (d) فنجد نتيجة مماثلة. فمن أجل الرجال ينخفض معدل الجاذبية

مع زيادة جرعة الكحول المستهلكة (ينخفض ارتفاع الأعمدة) ومن أجل النساء فإننا نرى نفس النمط إذ ينخفض معدل الجاذبية مع زيادة الجرعة. وهذا يدل على عدم وجود تفاعل إذ أن انخفاض الجاذبية الناتج عن استهلاك الكحول متماثل عند الرجال والنساء.

6.10 حساب حجم الأثر

كما رأينا في الفصول السابقة (الفقرة 5.8 و6.9) فإنه يمكننا أن نطلب من برنامج SPSS حساب إيتا مربع η^2. وقدمنا النصيحة باستخدام أوميغا مربع ω^2 بدلاً من إيتا مربع وذلك لأسباب وضحناها في تلك الفقرات. إن حساب أوميغا مربع يصبح أكثر تعقيداً في التصاميم العاملية. وقد قام Howell (2002) بعمل رائع في شرح تعقيدات ذلك (ووضع جدولاً يلخص المكونات المختلفة لعدد من الحالات المتنوعة). لذلك نكتفي بالقول أنه علينا أولاً حساب مكون التباين لكل من الآثار (الأثرين الرئيسيين وحد التفاعل) والخطأ، واستخدامها لحساب حجم الأثر لكل منها. إذا دعونا الأثر الرئيسي الأول A والأثر الرئيسي الثاني B وأثر التفاعل A×B فإن مكونات التباين لهذه الآثار اعتماداً على متوسط المربعات لكل أثر وحجم الأثر الذي تعتمد عليه تكون:

$$\hat{\sigma}_{\alpha}^2 = \frac{(a-1)(MS_A - MS_R)}{n.a.b}$$

$$\hat{\sigma}_{\beta}^2 = \frac{(b-1)(MS_B - MS_R)}{n.a.b}$$

$$\hat{\sigma}_{\alpha\beta}^2 = \frac{(a-1)(b-1)(MS_{A\times B} - MS_R)}{n.a.b}$$

وفي هذه المعادلات، a هو عدد المستويات للمتحول المستقل الأول، b عدد المستويات للمتحول المستقل الثاني، n عدد المشتركين في كل حالة تجريبية. لنحسب هذه القيم من أجل بيانات المثال الحالي. علينا أن ننظر إلى الخرج 3.10 لإيجاد متوسط المربعات لكل أثر وحد الخطأ. المتحول المستقل الأول هو alcohol وله ثلاث مستويات (إذاً a=3) ومتوسط المربعات له يبلغ 1666.146 وحدة. المتحول المستقل الثاني هو gender وله مستويان فقط (إذاً b=2) ومتوسط المربعات له يبلغ 168.75 وحدة. عدد المشتركين في كل حالة n=8، ويبلغ متوسط المربعات للبواقي 83.036 وحدة. لذلك تصبح المعادلات بالشكل:

$$\hat{\sigma}_{\alpha}^2 = \frac{(3-1)(1666.146 - 83.036)}{8\times 3\times 2} = 65.96$$

$$\hat{\sigma}_{\beta}^2 = \frac{(2-1)(168.75 - 83.036)}{8\times 3\times 2} = 1.79$$

$$\hat{\sigma}_{\alpha\beta}^2 = \frac{(3-1)(2-1)(989.062 - 83.036)}{8\times 3\times 2} = 37.75$$

علينا تقدير التغايرية الكلية، ويتم ذلك بحساب مجموع هذه المتحولات مع متوسط المربعات للبواقي:

$$\hat{\sigma}^2_{total} = \hat{\sigma}^2_{\alpha} + \hat{\sigma}^2_{\beta} + \hat{\sigma}^2_{\alpha\beta} + MS_R$$
$$= 65.96 + 1.79 + 37.75 + 83.036$$
$$= 188.54$$

يتم بعد ذلك حساب حجم الأثر بتقسيم تقدير التباين للأثر المرغوب على تقدير التباين الكلي، أي:

$$\omega^2_{effect} = \frac{\hat{\sigma}^2_{effect}}{\hat{\sigma}^2_{total}}$$

وهكذا فمن أجل الأثر الرئيسي للمتحول alcohol نجد:

$$\omega^2_{alcohol} = \frac{\hat{\sigma}^2_{alcohol}}{\hat{\sigma}^2_{total}} = \frac{65.96}{188.54} = 0.35$$

ومن أجل الأثر الرئيسي للمتحول gender نجد:

$$\omega^2_{gender} = \frac{\hat{\sigma}^2_{gender}}{\hat{\sigma}^2_{total}} = \frac{1.79}{188.54} = 0.009$$

ومن أجل أثر التفاعل بين المتحولين alcohol وgender نجد:

$$\omega^2_{alcohol\times gender} = \frac{\hat{\sigma}^2_{alcohol\times gender}}{\hat{\sigma}^2_{total}} = \frac{37.75}{188.54} = 0.20$$

لجعل هذه القيم قابلة للمقارنة مع r نأخذ الجذر التربيعي لكل منها، مما يعطي حجم الأثر 0.59 للمتحول alcohol و0.09 للمتحول gender، و0.45 لحد التفاعل. وهكذا يمكننا القول أن حجم الأثر للمتحول alcohol ولحد التفاعل كبيران نوعاً ما، بينما حجم الأثر للمتحول gender والذي لم يكن ذا دلالة في التحليل الرئيسي، هو صغير جداً (قريب من الصفر).

من الممكن أيضاً حساب حجم الأثر لتحليل الآثار البسيطة (إذا قرأت المربع 2.10). لهذه الآثار درجة حرية واحدة من أجل النموذج (وهذا يعني أنها تقارن عنصرين فقط)، ويمكن تحويل النسبة F في هذه الحالة إلى r باستخدام المعادلة التالية (التي تستخدم النسبة F وعدد درجات الحرية للبواقي فقط):

$$r = \sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}$$

لننظر إلى المربع 2.10 حيث يمكننا أن نحصل على قيمة النسبة F لكل من الآثار للمتحول gender عند المستويات المختلفة للمتحول alcohol وهي 1.01 من أجل حالة الشراب الخالي من الكحول، و 0.49 من أجل حالة القدحين، و12.35 من أجل حالة 4 أقداح. ومن أجل هذه الآثار كان عدد درجات الحرية هو 1 للنموذج و 44 للبواقي. وهكذا نحصل على حجم الأثر:

$$r_{gender\ (no\ alcohol)} = \sqrt{\frac{1.01}{1.01 + 44}} = 0.15$$

$$r_{gender\ (2\ pints)} = \sqrt{\frac{0.49}{0.49 + 44}} = 0.10$$

$$r_{gender\ (4\ pints)} = \sqrt{\frac{12.35}{12.35 + 44}} = 0.47$$

لذلك فإن أثر الجنس صغيرٌ جداً في حالتي الشراب الخالي من الكحول والقدحين، ولكنه يصبح كبيراً في حالة 4 أقداح من البيرة.

7.10 تقديم نتائج ANOVA ثنائي الاتجاه

كما في حالات ANOVA الأخرى التي صادفناها سابقاً فإنه ينبغي علينا تقديم تفاصيل النسبة F وعدد درجات الحرية التي تم عندها حساب هذه النسبة. ومن أجل الآثار المختلفة في هذا المثال، فإن النسب F ستعتمد على قيم مختلفة لعدد درجات الحرية، ويتم حسابها بتقسيم متوسط المربعات لكل أثر على متوسط المربعات للبواقي. إن عدد درجات الحرية للنموذج في حالتي الأثر للمتحول alcohol ولحد التفاعل gender×alcohol هو 2 (أي $df_M=2$)، ولكنه في حالة الأثر للمتحول gender يساوي 1 ($df_M=1$). أما عدد درجات الحرية للبواقي فيبلغ 42 ($df_R=42$) لجميع هذه الآثار. ولذلك يمكننا تقديم الآثار الثلاثة في هذا التحليل بالشكل التالي:

- ✓ هناك أثر رئيسي ذو دلالة لكمية الكحول المستهلكة في النادي الليلي على جاذبية الشريك الذي يختاره المشترك، $F(2,42)=20.07$, $p<0.001$, $\omega^2=0.35$. ويكشف اختبار Games-Howell أن جاذبية الشريك المختار في حالة تناول 4 أقداح من البيرة كانت أدنى بكثير منها في حالة تناول الشراب الخالي من الكحول أو تناول قدحين فقط من البيرة ($p<0.001$) ولم تكن جاذبية الشريك مختلفة بشكل كبير عند تناول قدحين من البيرة أو تناول الشراب الخالي من الكحول.
- ✓ هناك أثر رئيسي غير مهم للجنس على جاذبية الشريك المختار، $F(1,42)=2.03$, $p=0.161$, $\omega^2=0.009$.
- ✓ هناك أثر مهم للتفاعل بين كمية الكحول المستهلكة وجنس المشترك على جاذبية الشريك المختار، $F(2,42)=11.91$, $p<0.001$, $\omega^2=0.20$. ويدل ذلك على اختلاف تأثر الرجل والمرأة بالكحول. وبشكل أكثر تحديداً فإن جاذبية الشريك كانت متماثلة عند الذكور ($M=66.88$, $SD=10.33$) والإناث ($M=60.63$, $SD=4.96$) بعد تناول الشراب الخالي من الكحول، كما أنها كانت متماثلة عند الذكور ($M=66.88$, $SD=12.52$) والإناث ($M=62.50$, $SD=6.56$) بعد تناول قدحين من البيرة، إلا أنها اختلفت بشكل كبير بعد تناول 4 أقداح من البيرة، إذ أصبحت عند الرجال ($M=35.63$, $SD=10.84$) أدنى بكثير من النساء ($M=57.50$, $SD=7.07$).

8.10 ANOVA العاملي كتراجع

رأينا في الفقرة 2.2.8 أنه يمكن التعبير عن ANOVA وحيد الاتجاه كمعادلة تراجع (نموذج خطي عام GLM). وفي هذه الفقرة سنقوم بتوسيع النموذج الخطي ليشمل متحولين مستقلين. وللمحافظة على بساطة الأمور سنتخيل أن هناك مستويان فقط من المتحول alcohol في هذا المثال (بدون كحول و4 أقداح). وهكذا يصبح لدينا متحولان فقط لكل منهما مستويان فقط. والشكل العام لجميع النماذج الخطية العامة التي اعتبرناها في الكتاب هو:

$$Outcome_i = (Model_i) + error_i$$

فعلى سبيل المثال، عندما درسنا التراجع المتعدد في الفصل 5 رأينا أنه يمكن كتابة هذا النموذج (انظر المعادلة (9.5)) بالشكل:

$$Y_i = (b_0 + b_1X_1 + b_2X_2 + \cdots + b_nX_n) + \varepsilon_i$$

وعند دراسة ANOVA وحيد الاتجاه، قمنا بملاءمة هذا النموذج مع المثال Viagra (انظر المعادلة (2.8)):

$$Libido_i = (b_0 + b_2.High_i + b_1.Low_i) + \varepsilon_i$$

وفي هذا النموذج، كانت High وLow متحولات مزيفة (يمكنها أن تأخذ القيم 0 أو 1 فقط). وفي مثالنا الحالي، لدينا متحولان: gender (ذكر أو أنثى) وalcohol (بدون كحول و4 أقداح). يمكننا ترميز كل من هذين المتحولين بالقيم 0 أو 1. فعلى سبيل المثال يمكننا ترميز المتحول gender بحيث يكون 0=ذكر و1=أنثى، كما يمكننا ترميز المتحول alcohol بحيث يكون 0=بدون كحول و1=4 أقداح. يمكننا بعد ذلك نسخ النموذج المستخدم في ANOVA وحيد الاتجاه مباشرة:

$$Attractive_i = (b_0 + b_1.Gender_i + b_2.Alcohol_i) + \varepsilon_i$$

قد تتساءل الآن "أين اختفى حد التفاعل؟". حسناً، يجب علينا أن نضمّن هذا الحد أيضاً، وبذلك يتوسع النموذج ليصبح بالشكل التالي:

$$Outcome_i = (b_0 + b_1.A_i + b_2.B_i + b_3.AB_i) + \varepsilon_i$$

$$Attractive_i = (b_0 + b_1.Gender_i + b_2.Alcohol_i + b_3.Interaction_i) + \varepsilon_i$$

والسؤال الذي يطرح نفسه الآن هو "كيف نقوم بترميز حد التفاعل؟". يمثل حد التفاعل الأثر المركب للمتحولين gender وalcohol وللحصول على حد التفاعل في معادلة التراجع نقوم بضرب المتحولين المشمولين بحد التفاعل. ولهذا السبب نكتب حد التفاعل بالشكل alcohol×gender. يعرض الجدول 2.10 المتحولات الناتجة في حالة التراجع (لاحظ أن متحول التفاعل هو ببساطة قيمة المتحول المزيف gender مضروبة بقيمة المتحول المزيف alcohol). فعلى سبيل المثال تكون قيم المتحولات لرجل تناول 4 أقداح من البيرة هي: 0 للمتحول gender و1 للمتحول alcohol و0 لمتحول التفاعل. كما يحوي الجدول قيم المتوسط للمجموعات للتراكيب المختلفة للمتحولين alcohol وgender.

المتحول Gender	المتحول Alcohol	المتحول المزيف (Gender)	المتحول المزيف (Alcohol)	التفاعل	المتوسط
ذكر	دون كحول	0	0	0	66.875
ذكر	4 أقداح	0	1	0	35.625
أنثى	دون كحول	1	0	0	60.625
أنثى	4 أقداح	1	1	1	57.500

الجدول 2.10 مخطط الترميز لمثال ANOVA العاملي

لمعرفة ما تمثله قيم b في هذا النموذج يمكننا تنفيذ ما قمنا به سابقاً من أجل الاختبار t وANOVA وحيد الاتجاه، ولنراقب ما يحدث عند إدخال قيم المتحولات التنبؤية (gender وalcohol). لنبدأ أولاً بمراقبة ما يحدث عند النظر إلى حالة الرجل الذي تناول شراباً خالياً من الكحول. في هذه الحالة تكون قيمة المتحول gender هي 0، وقيمة المتحول alcohol هي 0، وقيمة حد التفاعل هي 0. والنتيجة التي نتوقعها (كما في ANOVA وحيد الاتجاه) هي قيمة المتوسط لهذه المجموعة (66.875)، لذلك يصبح النموذج بالشكل:

$$Attractive_i = b_0 + b_1.Gender_i + b_2.Alcohol_i + b_3.Interaction_i$$

$$\overline{X}_{Men,\,None} = b_0 + b_1 \times 0 + b_2 \times 0 + b_3 \times 0$$

$$b_0 = \overline{X}_{Men,\,None}$$

$$b_0 = 66.875$$

وهكذا فإن الحد الثابت b0 في النموذج يمثل متوسط المجموعة التي تكون فيها قيمة الرمز لجميع المتحولات هي 0. أي أنها قيمة المتوسط للفئة الأساسية (في هذه الحالة فئة الرجال دون كحول). لنراقب الآن ما يحدث عند النظر إلى حالة المرأة التي تناولت شراباً خالياً من الكحول. في هذه الحالة تكون قيمة المتحول gender هي 1، وقيمة المتحول alcohol هي 0، وقيمة حد التفاعل هي 0. والنتيجة التي نتوقعها هي قيمة المتوسط لهذه المجموعة (60.625)، لذلك يصبح النموذج بالشكل:

$$Attractive_i = b_0 + b_1.Gender_i + b_2.Alcohol_i + b_3.Interaction_i$$

$$\overline{X}_{Women,\,None} = b_0 + b_1 \times 1 + b_2 \times 0 + b_3 \times 0$$

$$\overline{X}_{Women,\,None} = \overline{X}_{Men,\,None} + b_1$$

$$b_1 = \overline{X}_{Women,\,None} - \overline{X}_{Men,\,None}$$

$$= 60.625 - 66.875$$

$$= -6.25$$

لذلك فإن الحد b_1 في النموذج يمثل الفرق بين قيم المتوسط للرجال والنساء الذين تناولوا شراباً خالياً من الكحول. ويمكن أن نعمم ذلك لنقول أنه أثر المتحول gender من أجل الفئة الأساسية للكحول (الفئة الأساسية هي الفئة التي تم ترميزها بالقيمة 0، وفي هذه الحالة هي الفئة دون

كحول). لننظر الآن إلى حالة الرجل الذي تناول 4 أقداح من البيرة. في هذه الحالة تكون قيمة المتحول gender هي 0، وقيمة المتحول alcohol هي 1، وقيمة حد التفاعل هي 0. ونستطيع أيضاً استبدال b_0 بقيمة المتوسط لمجموعة الرجال بدون كحول. والنتيجة التي نتوقعها هي قيمة المتوسط لمجموعة الرجال مع 4 أقداح بيرة (35.625) لذلك يصبح النموذج بالشكل:

$$\overline{X}_{Men,4\ pints} = b_0 + b_1 \times 0 + b_2 \times 1 + b_3 \times 0$$
$$\overline{X}_{Men,4\ pints} = b_0 + b_2$$
$$\overline{X}_{Men,4\ pints} = \overline{X}_{Men,None} + b_2$$
$$b_2 = \overline{X}_{Men,4\ pints} - \overline{X}_{Men,None}$$
$$= 35.625 - 66.875$$
$$= -31.25$$

لذلك فإن الحد b_2 في النموذج يمثل الفرق بين قيم المتوسط للرجال عند تناول شراب خالي من الكحول وعند تناول 4 أقداح من البيرة. ويمكن أن نعمم ذلك لنقول أنه أثر المتحول alcohol من أجل الفئة الأساسية للجنس (الفئة الأساسية هي الفئة التي تم ترميزها بالقيمة 0، وفي هذه الحالة هي فئة الرجال). وأخيراً ننظر إلى حالة المرأة التي تناولت 4 أقداح من البيرة. في هذه الحالة تكون قيمة المتحول gender هي 1، وقيمة المتحول alcohol هي 1، وقيمة حد التفاعل هي 1. ونستطيع أيضاً استبدال قيم b_0 وb_1 وb_2 بما تمثله. والنتيجة التي نتوقعها هي قيمة المتوسط لمجموعة النساء مع 4 أقداح بيرة (57.500). لذلك يصبح النموذج بالشكل:

$$\overline{X}_{Women,4\ pints} = b_0 + b_1 \times 1 + b_2 \times 1 + b_3 \times 1$$
$$\overline{X}_{Women,4\ pints} = b_0 + b_1 + b_2 + b_3$$
$$\overline{X}_{Women,4\ pints} = \overline{X}_{Men,None} + (\overline{X}_{Women,None} - \overline{X}_{Men,None}) + (\overline{X}_{Men,4\ pints} - \overline{X}_{Men,None}) + b_3$$
$$\overline{X}_{Women,4\ pints} = \overline{X}_{Women,None} + \overline{X}_{Men,4\ pints} - \overline{X}_{Men,None} + b_3$$
$$b_3 = (\overline{X}_{Men,None} - \overline{X}_{Women,None}) - (\overline{X}_{Men,4\ pints} - \overline{X}_{Women,4\ pints})$$
$$= (66.875 - 60.625) - (35.625 - 57.500)$$
$$= 28.125$$

لذلك فإن الحد b_3 في النموذج يقارن عملياً الفرق بين الرجال والنساء في حالة تناول الشراب الخالي من الكحول من جهة مع الفرق بين الرجال والنساء في حالة تناول 4 أقداح من البيرة من جهة أخرى. وبطريقة أخرى يمكن أن نقول أنه يقارن أثر المتحول gender في حالة الشراب الخالي من الكحول مع أثر المتحول gender في حالة تناول 4 أقداح من البيرة (وإذا أعدنا ترتيب حدود المعادلة فيمكننا أن نقول أيضاً أنه أثر المتحول alcohol على الرجال مقارنة مع النساء). إذا فكرنا بهذا الحد من خلال مخطط التفاعل يكون للعبارة السابقة معنى واضح. فعلى سبيل المثال، يعرض الجانب العلوي الأيسر من الشكل 13.10 مخطط التفاعل لهذا البيانات. تخيل الآن أننا حسبنا الفرق

بين الرجال والنساء من أجل حالة الشراب الخالي من الكحول. إنه الفرق بين الخطين على المخطط من أجل مجموعة الشراب الخالي من الكحول (الفرق بين قيم المتوسط للمجموعات أي 6.25). إذا قمنا بنفس العملية للمجموعة 4 أقداح فإننا نجد أن الفرق بين الرجال والنساء هو 21.875. إذا رسمنا هاتين القيمتين كمخطط جديد فإننا نحصل على خط يصل القيمة 6.25 بالقيمة 21.875 (انظر القسم السفلي الأيسر من الشكل 13.10). وهذا يعكس الفرق بين أثر المتحول gender عند تناول الشراب الخالي من الكحول مقارنة مع حالة تناول 4 أقداح. نعلم أن قيم بيتا تمثل انحدار الخطوط، وb_3 في النموذج الحالي تمثل انحدار هذا المستقيم. لنرَ ما يحدث إذا لم يكن هناك أثر للتفاعل. يبين القسم الأيمن من الشكل 13.10 نفس البيانات باستثناء أن قيمة المتوسط لمجموعة النساء اللواتي تناولن 4 أقداح من البيرة قد تغيرت إلى 30. إذا حسبنا الفرق بين الرجال والنساء للمجموعة التي تناولت شراباً خالياً من الكحول فإننا نحصل على نفس الفرق السابق 6.25. و إذا حسبنا الفرق بين الرجال والنساء للمجموعة التي تناولت 4 أقداح من البيرة فإننا نحصل على 5.625. إذا رسمنا هذين الفرقين على مخطط جديد فإننا نحصل على خط أفقي تقريباً. لذلك، عندما لا يكون هناك تفاعل فإن الخط الواصل بين أثر المتحول gender عند تناول الشراب الخالي من الكحول، وعند تناول 4 أقداح من البيرة هو أفقي وتكون قيمة b_3 في النموذج قريبة من الصفر (تذكر أن الانحدار 0 يعني خطاً أفقياً). وعملياً تكون هذه القيمة 0.625=6.25-5.625.

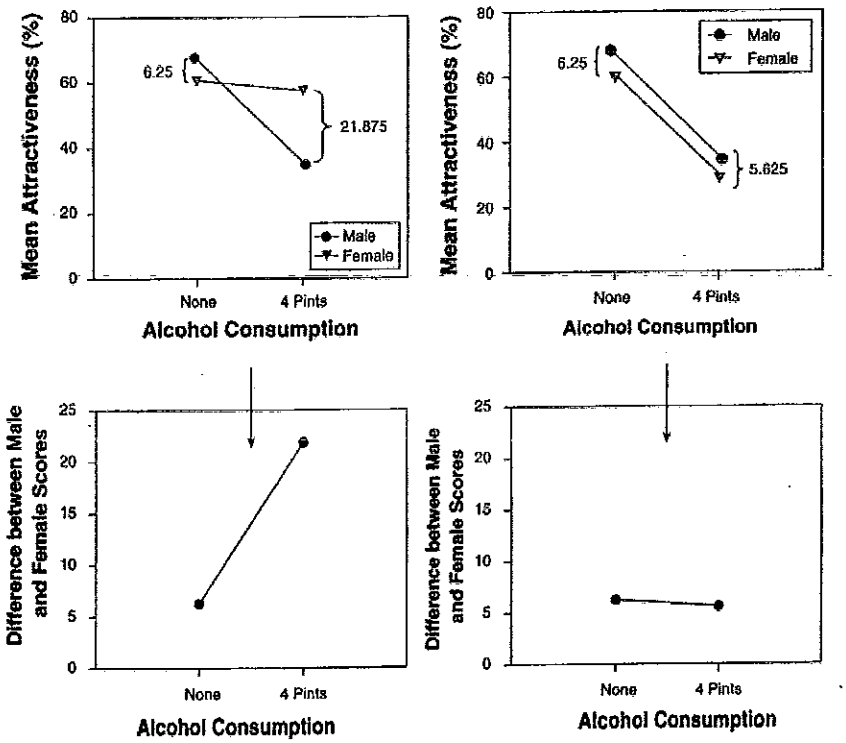

الشكل 13.10

يحوي الملف GogglesRegression.sav المتحولات المزيفة المستخدمة في هذا المثال. ويمكنك أن تتأكد من هذه النتائج بتنفيذ تراجع متعدد على البيانات في هذه الملف. يعرض الخرج 6.10 الجدول الناتج لمعاملات التراجع. وأهم ما يجب ملاحظته أن قيم بيتا هي نفس القيم التي حسبناها، وهذا سبب مقنع لاعتبار ANOVA العاملي كتراجع ولكن في حلةٍ جديدة.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	66.875	3.055		21.890	.000
	Gender	-6.250	4.320	-.219	-1.447	.159
	Alcohol Consumption	-31.250	4.320	-1.094	-7.233	.000
	Interaction	28.125	6.110	.863	4.603	.000

a. Dependent Variable: Attractiveness of Date

الخرج 6.10

نأمل أننا استطعنا في هذا المثال أن نوضح كيف أن ANOVA المعقدة هي من أشكال التراجع (GLM). لأنها المرة الأخيرة التي نقول فيها ذلك. ونأمل أن لديك القاعدة الكافية بحيث يمكنك الاستفادة من حقيقة أننا نستطيع إضافة المتحولات المستقلة إلى النموذج، وما يحدث هو أن هذه المتحولات الجديدة تدخل إلى معادلة التراجع المتعدد مع قيم بيتا المرتبطة بها، كما يمكن إضافة حدود التفاعل وذلك بضرب المتحولات المتفاعلة. ولهذه الحدود قيم بيتا المرتبطة بها أيضاً.

9.10 ما الذي اكتشفناه عن الإحصاء

احتوى هذا الفصل على جولة استكشافية لـــ ANOVA العاملي. وسنمر في الفصلين اللاحقين على مزيد من ANOVA العاملية، ولكننا في الوقت الحالي اكتفينا بالتعرف على الحالة التي تحوي متحولَين مستقلين اثنين، وتم فيها استخدام مشتركين مختلفين في الحالات التجريبية المختلفة. لقد بدأنا الفصل بالتعرف على كيفية حساب مجاميع المربعات المختلفة المستخدمة في هذا التحليل، وأهم من ذلك أننا رأينا كيفية الحصول على ثلاثة آثار: أثر رئيسي لكل من المتحولَين المستقلين، وأثر التفاعل بين هذين المتحولين. انتقلنا بعد ذلك إلى تنفيذ هذا التحليل في برنامج SPSS وتفسير الخرج. وكان الاختلاف الكبير بين ذلك وبين ما نفذناه في الفصول السابقة هو التعمق باستكشاف التفاعلات (وخاصة مخطط التفاعل) لمعرفة ملامح التفاعل وكيفية اكتشافه. كما عرضنا طريقة متابعة التفاعل باستخدام تحليل الآثار البسيطة واكتشفنا كيف يمكن اعتبار ANOVA المعقدة كتحليل تراجع متنكر. وأخيراً اكتشفنا مدى تعقيد حساب حجم الأثر.

10.10 المصطلحات الأساسية التي اكتشفناها

التحليل العاملي للتباين	(Factorial ANOVA)
العوامل	(Factors)
تصميم عاملي مستقل	(Independent factorial design)
أثر التفاعل	(Interaction effect)
مخططات التفاعل	(Interaction graphs)
الأثر الرئيسي	(Main effect)
تصميم مختلط	(Mixed design)
تصميم عاملي مرتبط	(Related factorial design)
تحليل الآثار الأساسية	(Simple effects analysis)

11.10 مهمات يجب تنفيذها

- **المهمة الأولى:** يتغير الذوق الموسيقي للناس عادة بعد تجاوزهم سناً معينة، ولذلك قام أحد الباحثين بدراسة هذه الظاهرة. واختار مجموعتين من الأشخاص تحوي كل منهما 45 شخصاً، تحوي المجموعة الأولى أشخاصاً تقل أعمارهم عن 40 سنة، بينما تحوي المجموعة الثانية أشخاصاً تتجاوز أعمارهم 40 سنة. وبذلك يكون المتحول المستقل الأول هو age، وله مستويان (أقل من 40 سنة وأكثر من 40 سنة). قام بعد ذلك بتقسيم كل مجموعة إلى 3 مجموعات تحوي كل منها 15 شخصاً وطلب منهم الاستماع إلى Fugazi أو ABBA أو Barf Grooks. وبذلك يكون المتحول المستقل الثاني هو music، وله ثلاثة مستويات (Barf Grooks, ABBA, Fugazi). كان هناك مشتركين مختلفين في الحالات التجريبية المختلفة، وهذا يعني أنه من بين الأشخاص الذين تقل أعمارهم عن 40 سنة، هناك 15 شخصاً استمعوا إلى Fugazi و15 شخصاً آخرين استمعوا إلى ABBA، و15 شخصاً آخرين استمعوا إلى Barf Grooks. ونفس الشيء مع مجموعة الأشخاص الذين تزيد أعمارهم عن 40 سنة. وبعد الاستماع إلى الموسيقى، طلب من كل شخص أن يضع علامة للموسيقى على مقياس يتدرج من 100- (أكره هذه الموسيقى) مروراً بالقيمة 0 (عدم الاكتراث أو الاهتمام) وصولاً إلى 100+ (أعشق هذه الموسيقى). يدعى هذا المتحول liking. يحوي الملف Fugazi.sav هذه البيانات، والمطلوب تنفيذ ANOVA ثنائي الاتجاه مستقل على هذه البيانات.
- **المهمة الثانية:** باستخدام المربع 2.10، استبدل الأسطر المناسبة في البرنامج النصي لتنفيذ تحليلٍ يبحث في أثر المتحول alcohol على المستويات المختلفة للمتحول gender.

يحوي الملف Answers(Chapter 10).pdf إجابات هذه المهمات.

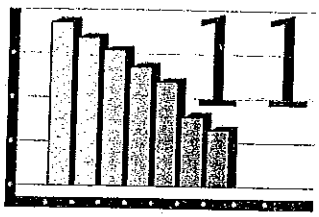

تصاميم القياسات المكررة (GLM4)

1.11 ماذا يخبرنا هذا الفصل؟

درسنا في الفصول الثلاثة السابقة إجرائية تدعى تحليل التباين (ANOVA) تُستخدم لاختبار الفروق بين عدة متوسطات. وركزنا دراستنا على حالات يساهم فيها أناس مختلفون في القيم المختلفة للمتوسط، وبعبارة أخرى يساهم أشخاص مختلفون في حالات تجريبية مختلفة. وعملياً ليس من الضرورة أن تكون عناصر التجارب هم أشخاص، إذ يمكن أن تكون نباتات مختلفة أو شركات مختلفة، أو مخططات مختلفة للأرض، أو أسلاك مختلفة من الفيروسات، أو أنواع مختلفة من الماعز أو غيرها. فالنقطة الأساسية هي أن نفس العناصر (أشخاص، نباتات، شركات، مخططات، أو غيرها) تساهم في القيم المختلفة للمتوسط. ونكتفي بذلك لننتقل إلى دراسة ANOVA في بيانات القياسات المكررة. حيث نبدأ بعرض تفصيلي للفرضية الإضافية التي نحتاجها عند استخدام تصاميم القياسات المكررة وهي فرضية الكروية أو التكور (Sphericity).

وننتقل بعد ذلك للمبادئ النظرية لتقنية ANOVA في القياسات المكررة عند استخدام متحول مستقل وحيد. ثم ندرس مثالاً في برنامج SPSS قبل توسيع المبادئ لتشمل الحالات التي يتم فيها قياس متحولين مستقلين. ومع نهاية الفصل نأمل أن تكون لديكم جميع المعلومات الضرورية حول ANOVA للقياسات المكررة.

2.11 مدخل إلى تصاميم القياسات المكررة

القياس المكرر (Repeated measure) هو الحالة التي يتم فيها استخدام نفس المشتركين في جميع الحالات التجريبية. فعلى سبيل المثال، قد نرغب بدراسة آثار الكحول على المتعة في حفلة ما. يشرب بعض الناس الكثير من الكحول قبل أن يشعروا بعواقبه، بينما يكفي تناول رشفة صغيرة من البيرة الخفيفة لكي يشعر بعض الناس بآثار الكحول. لذلك فمن الضروري مراقبة الفروق الفردية في مقدار الكحول المسموح به. ولمراقبة هذه الفروق الفردية يمكننا اختبار نفس الأشخاص في جميع الحالات التجريبية، حيث نختبر كل شخص بعد تناوله قدحاً أو قدحين أو ثلاثة أقدح أو أربعة أقداح من البيرة.

وبعد تناول كل جرعة نعطي المشترك استبياناً لتقييم متعته في الحفلة. وهكذا يعطى كل مشترك علامة تمثل المتعة قبل التلاعب التجريبي (قبل تناول الكحول)، وبعد تناول قدح واحد، وبعد تناول قدحين وهلم جرا. نقول عن هذا التصميم أنه يستخدم قياساً مكرراً.

ولهذا النوع من التصميم عدة مزايا. أهمها أنه يخفض التغايرية اللامنهجية في التصميم (انظر الفصل 7) وبذلك يوفر قدرة أكبر على اكتشاف الآثار. والقياسات المكررة أكثر اقتصادية أيضاً لأنها تتطلب عدداً أقل من المشتركين، وهناك مساوئ أيضاً لهذا التصميم. ففي تصميم ANOVA بين المجموعات تعتمد دقة اختبار F على فرضية أن العلامات في الحالات التجريبية المختلفة هي مستقلة (وقد وثّق Scania & Davenport 1987 بعض نتائج خرق هذه الفرضية). أما في حالة القياسات المكررة فإن هذه الفرضية تكون غير محققة، لأن العلامات المأخوذة في الحالات التجريبية المختلفة يمكن أن تكون مرتبطة لأنها تأتي من نفس المشتركين. ولذلك فإن اختبار F التقليدي يفتقد الدقة. وتعني العلاقة بين العلامات في الحالات المعالجة المختلفة أننا بحاجة لاعتماد فرضية إضافية، وببساطة نفترض أن العلاقة بين ثنائيات الحالات التجريبية هي متماثلة (أي أن مستوى التبعية بين الحالات التجريبية هو متساوي تقريباً). تدعى هذه الفرضية بفرضية الكروية (Sphericity).

1.2.11 فرضية الكروية

تعلمنا جميعاً (وخاصة الذين قرؤوا هذا الكتاب) أنه من الضروري أن تكون التباينات متجانسة بين الحالات التجريبية عند تحليل البيانات القادمة من مشتركين مختلفين، ولكننا نفترض أن هذه المشكلة تختفي في تصاميم القياسات المكررة.

ولكن ذلك غير صحيح تماماً، ويمكن تشبيه فرضية الكروية بفرضية تجانس التباين المعتمدة في ANOVA بين المجموعات. والكروية (التي نرمز لها بالرمز ε وندعوها أحياناً بالأسطوانية (Circularity)) هي شرط أكثر عمومية من التناظر المركب (Compound Symmetry). ويكون التناظر المركب صحيحاً عندما تكون كل من: التباينات بين الحالات المختلفة متساوية (وهذا يكافئ فرضية تجانس التباين المعتمدة في ANOVA بين المجموعات) والتباينات المشتركة بين الثنائيات من الحالات التجريبية متساوية. لذلك نفترض أن التغاير ضمن الحالات التجريبية متماثل وأنه لاتوجد ثنائية من الحالات التجريبية أكثر تبعية من أية ثنائية أخرى. ومع أن التناظر المركب يبدو شرطاً كافياً لتقنية ANOVA التي تستخدم القياسات المكررة فإنه ليس شرطاً لازماً. إن الكروية هي شكل أقل صرامة من التناظر المركب، وتعني تساوي التباينات للفروق بين مستويات المعالجة. لذلك إذا أخذت زوجاً من مستويات المعالجة، وحسبت الفروق بين كل زوج من العلامات فمن الضروري أن يكون لهذه الفروق تباينات متساوية. وهكذا فأنت بحاجة إلى ثلاث حالات تجريبية على الأقل لدراسة الكروية.

2.2.11 كيف نقيس الكروية؟

إن أسهل طريقة لمعرفة فيما إذا كانت فرضية الكروية محققة هي حساب الفروق بين أزواج العلامات في جميع التراكيب الممكنة لمستويات المعالجة. ثم حساب التباين لهذه الفروق. يعرض الجدول 1.11 البيانات لتجربة ذات ثلاث حالات. وتم حساب الفروق بين أزواج العلامات لكل مشترك، كما تم حساب التباين لكل مجموعة من الفروق. ورأينا سابقاً أن الكروية تتحقق عندما تكون هذه البيانات متساوية تقريباً. فمن أجل هذه البيانات، تكون الكروية محققة عندما يكون:

$$Variance_{A-B} \approx Variance_{A-C} \approx Variance_{B-C}$$

في هذه البيانات هناك بعض الانحراف عن الكروية لأن التباين للفروق بين الحالتين A وB (17.0) أكبر من التباين للفروق بين الحالتين C وB ومن التباين للفروق بين الحالتين A وC (10.3). على كل حال تتمتع هذه البيانات بأسطوانية موضعية (أو كروية موضعية) لأن اثنين من تباينات الفروق متساويان. لذلك فإن فرضية الكروية محققة في أية مقارنات تشمل هاتين الحالتين. ولا يبدو الانحراف عن الكروية للبيانات في الجدول 1.11 كبيراً (لأن التباينات متساوية تقريباً)، ولكن هل يمكننا تقييم مدى الانحراف الذي يمكن أن يسبب مشكلة؟

المجموعة A	المجموعة B	المجموعة C	الفرق A-B	الفرق A-C	الفرق B-C
9	12	7	-3	2	5
15	15	12	0	3	3
25	30	20	-5	5	10
35	30	28	5	7	2
30	27	20	3	10	7
التباين			17.0	10.3	10.3

الجدول 1.11 بيانات افتراضية لتوضيح حساب التباين للفروق بين الحالات المختلفة

3.2.11 تقييم حدة الانحراف عن الكروية

يعطي برنامج SPSS اختباراً يعرف باسم اختبار Mauchly، يختبر فرضية أن تباينات الفروق بين الحالات المختلفة متساوية. لذلك إذا كان اختبار Mauchly ذا دلالة (قيمة احتماله أقل من 0.05) فإننا نستنتج أن هناك فروقاً مهمة بين تباينات الفروق، وبالتالي فإن شرط الكروية غير محقق. أما إذا كان اختبار Mauchly دون دلالة (أي أن $p>0.05$) فمن المعقول عندئذ استنتاج أن تباينات الفروق غير مختلفة بشكل كبير (أي أنها متساوية تقريباً). وباختصار إذا كانَ اختبار Mauchly ذا دلالة فيجب علينا أن نحترس من النسب F التي يعطيها برنامج SPSS.

4.2.11 ما هو الأثر الناتج عن خرق فرضية الكروية؟

قدم Rouanet & Lépine (1970) دراسة تفصيلية عن صلاحية النسبة F عند خرق فرضية الكروية، وقدما حججاً عليه عند وجود نسبتي F مختلفتين يمكن استخدامهما لتقييم مقارنات المعالجة وهما F' و"F". وتشير F' إلى النسبة F المشتقة من متوسط المربعات ومن حد الخطأ النوعي للمقارنة موضوع الدراسة، وهي النسبة F المستخدمة عادة. أما "F فهي مشتقة من متوسط المربعات للخطأ الكلي لجميع مقارنات القياسات المكررة. إن F' أقل قدرة من "F ولذلك فقد لا تكتشف الآثار الحقيقة. ولكي تكون F' صالحة يجب المحافظة على الكروية من أجل المقارنة المحددة موضوع الدراسة، بينما تتطلب "F تحقق الأسطوانية الكلية فقط (أي تكون مجموعة البيانات الكلية أسطوانية)، ولكن بسبب الطبيعة غير التبادلية للأسطوانية والتناظر المركب، فإن "F لا تتطلب التناظر المركب بينما F' تتطلب ذلك. ولذلك بما أن F' هي الإحصائية المستخدمة بشكل عام، فإن الأثر الناتج عن خرق فرضية الكروية هو فقدان القدرة (مقارنة باستخدام "F)، والحصول على إحصائية اختبار (النسبة F) التي لايمكن مقارنتها مع القيم الجدولية للتوزيع F.

5.2.11 ماذا نفعل عند خرق فرضية الكروية؟

إذا خرقت البيانات فرضية الكروية فإن هناك عدة إجراءات تصحيحية يمكن تطبيقها للحصول على نسبة F صالحة. يعطي برنامج SPSS ثلاثة تصحيحات بناءً على تقديرات الكروية التي أوصى بها Greenhouse & Geisser و Huynh & Feldt وتزيد هذه التقديرات عامل التصحيح المطبق على عدد درجات الحرية المستخدم في تقييم النسبة F المراقبة. ويتجاوز حساب هذه التقديرات مجال هذا الكتاب، ونكتفي بمعرفة أن التقديرات الثلاثة مختلفة. تتغير قيمة تصحيح Greenhousw-Geisser (ويرمز له عادة بالرمز ε̂) بين 1/(k-1) (حيث k عدد حالات القياسات المكررة) و1.0 وكلما كانت قيمة ε̂ أقرب إلى القيمة 1.0 كانت تباينات الفروق أكثر تجانساً، وكانت البيانات أقرب إلى الكروية. فعلى سبيل المثال، في تجربة تحوي 5 حالات فإن الحد الأدنى لقيمة ε̂ هي 0.25=1/(5-1) وتدعى تقدير الحد الأدنى للكروية (lower-bound estimate of sphericity).

بيّن Huynh & Feldt (1976) أنه عندما يكون تصحيح Greenhousw-Geisser أكبر من 0.75 فإننا نفشل في رفض مجموعة كبيرة من فرضيات العدم الخاطئة (أي أن التصحيح صارم جداً)، كما بيّن Collier, Baker, Mandeville & Hayes (1967) أن ذلك صحيح أيضاً عندما يكون تصحيح الكروية مساوياً 0.90. لذلك يقترح Huynh & Feldt استخدام التصحيح الخاص بهما الأقل صرامة (والذي يرمز له عادة بالرمز ε̃). وقد بيّن Maxwell & Delaney (1990) أن ε̃ يبالغ بتقدير الكروية. ولذلك ينصح Stevens (1992) بأخذ المتوسط للقيمتين وتعديل df بهذه القيمة المتوسطة. ويوصي Griden (1992) باستخدام تصحيح Huynh-Feldt عندما يكون تقدير الكروية أكبر من 0.75، وباستخدام تصحيح Greenhousw-Geisser عندما تكون تقديرات الكروية أقل من 0.75 أو عند عدم معرفة أي شيء عن الكروية. وسنرى خلال هذا الفصل كيفية استخدام هذه القيم.

وهناك خيار أخير عندما تخرق البيانات فرضية الكروية، وهو استخدام إحصائيات الاختبار متعدد المتغيرات (MANOVA، انظر الفصل 14)، وذلك لأنها لا تعتمد على فرضية الكروية. تتجنب MANOVA فرضية الكروية (وجميع الاعتبارات المتعلقة بها حول النسب F والتصحيحات) باستخدام حد الخطأ النوعي للمقارنات مع درجة حرية واحدة، وبذلك فإن كل مقارنة تكون مرتبطة مع حد الخطأ النوعي لها (بدلاً من حدود الخطأ المجمعة المستخدمة في ANOVA). تعطي إجرائية القياسات المكررة في برنامج SPSS بشكل تلقائي إحصائيات الاختبار متعدد المتغيرات، وسندرس في الفصل 14 الإجرائية MANOVA بشكل معمّق.

هناك اختلاف في قدرة الاختبار بين الحل وحيد المتغير ومتعدد المتغيرات. وقد قارن Davidson (1972) قدرة التقنيات وحيدة المتغير المعدّلة مع Hotelling´s T2 (إحصائية اختبار MANOVA) ووجد أن تقنية المتغير الوحيد كانت عديمة القدرة نسبياً في اكتشاف التغيرات الموثوقة الصغيرة بين الحالات المرتبطة بشكل كبير عندما كانت الحالات الأخرى الأقل ارتباطاً موجودة. ونفذ Mendoza et al. (1974) دراسة مونت كارلو بمقارنة التقنيات وحيدة المتغير ومتعددة المتغيرات عند خرق فرضية التناظر المركب والطبيعية، ووجدوا أنه كلما ازدادت درجة خرق فرضية التناظر المركب فإن القدرة التجريبية للاختبارات متعددة المتغيرات تزداد أيضاً، بينما تنخفض قدرة الاختبارات وحيدة المتغير عموماً. ولاحظ Maxwell & Delaney (1990) أن الاختبار وحيد المتغير أكثر قدرة نسبياً من الاختبار متعدد المتغيرات وذلك عندما تنخفض n، واقترح عدم استخدام الاختبار متعدد المتغيرات عندما يكون n أقل من a+10 (حيث a هو عدد المستويات للقياسات المكررة). وكقاعدة يمكن أن نقول أنه عندما يكون خرق الكروية كبيراً (ε <0.7) وحجم العينة أكبر من (a+10) فإن الإجرائيات متعددة المتغيرات تكون أكثر قدرة، أما عندما يكون حجم العينة صغيراً أو عند المحافظة على الكروية (ε >0.7) فمن المفضل استخدام الإجرائيات وحيدة المتغير. ومن المفيد أن نذكر هنا أن قدرة MANOVA تزداد وتنخفض كتابع للارتباط بين المتحولات التابعة، ولذلك فإن العلاقة بين حالات المعالجة يجب أن تؤخذ بعين الاعتبار أيضاً.

3.11 نظرية ANOVA وحيد الاتجاه للقياسات المكررة

في ANOVA للقياسات المكررة يظهر أثر التجربة في التباين ضمن المشتركين (بدلاً من التباين بين المجموعات). تذكرّ أنه في ANOVA المستقل (الفقرة 2.8) فإن التباين ضمن المشتركين هو تباين البواقي(SS_R)، إنه التباين الناتج عن الفروق الفردية في الأداء. وهذا التباين غير متأثر بالأثر التجريبي مهما كان التلاعب المنفذ على المشتركين المختلفين. على كل حال، عندما نقوم بالتلاعب التجريبي على نفس المشتركين فإن التباين ضمن المشتركين سيتكوّن من جزئيين: أثر التلاعب التجريبي، والفروق الفردية في الأداء. ولذلك فإن بعض التغاير ضمن المشتركين يأتي من آثار التلاعب التجريبي، فنحن نطبق أشياء مختلفة على المشتركين في كل حالة تجريبية ويكون التغاير في علامات

المشتركين ناتجاً جزئياً عن هذا التلاعب. فعلى سبيل المثال، إذا كانت علامات كل مشترك في حالة تجريبية معينة أعلى من حالة تجريبية أخرى، فيمكن أن نفترض أن ذلك لم يحدث بمحض الصدفة، ولكن لأننا طبقنا على المشتركين شيئاً في حالة معينة مختلفاً عن الحالة الأخرى. ولأننا أجرينا نفس الشيء على كل مشترك ضمن حالة تجريبية معينة، فإن أي تغاير لا يمكن تبريره بالتلاعب الذي قمنا به سيكون ناتجاً عن عوامل عشوائية خارج السيطرة، وغير مرتبطة بالتلاعب التجريبي (ويمكن أن ندعو ذلك "خطأ"). وكما في حالة ANOVA المستقل فإننا نستخدم نسبة F التي تقارن حجم التغاير الناتج عن التلاعب التجريبي مع حجم التغاير الناتج عن العوامل العشوائية، والفرق الوحيد هو كيفية حساب هذه التباينات. إذا كان التباين العائد للتلاعب التجريبي كبيراً مقارنة مع التغاير العائد للعوامل العشوائية فإننا نحصل على قيمة كبيرة للنسبة F ويمكننا أن نستنتج أن النتائج المراقبة لا يمكن أن تنتج عن الصدفة.

يبين (الشكل 1.11) كيفية تقسيم التباين في ANOVA للقياسات المكررة. إن أهم ما يجب ملاحظته أن لدينا نفس أنواع التباين الموجودة في ANOVA المستقل وهي: مجموع المربعات الكلي (SS_T)، مجموع المربعات للنموذج (SS_M)، مجموع المربعات للبواقي (SS_R). والفرق الوحيد هو مصدر مجاميع المربعات، ففي ANOVA للقياسات المكررة يعتبر كلٌ من مجموع المربعات للنموذج وللبواقي جزءاً من التباين ضمن المشتركين.

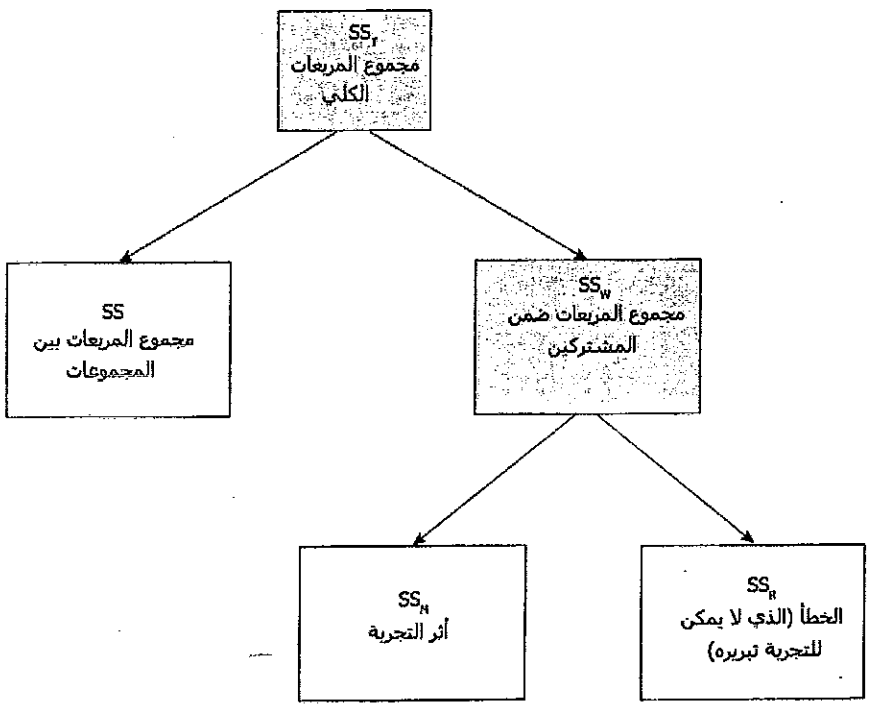

الشكل 1.11 تقسيم التباين في ANOVA للقياسات المكررة

لنأخذ مثالاً توضيحياً. هناك اهتمام لدى الطلاب حول إتباع طريقة واحدة بين المحاضرين في إعطاء العلامات. ولذلك قامت مجموعة من الطلاب بدراسة الثبات على مبدأ واحد في إعطاء العلامات وذلك بعرض نفس المقالات على 4 محاضرين مختلفين، وتم تسجيل العلامة التي أعطاها كل محاضر لكل من المقالات الثماني. من المهم عرض نفس المقالات على جميع المحاضرين لأن ذلك يلغي الفروق الفردية في معيار العمل لكل محاضر. هذا المثال هو تصميم ذو قياسات مكررة لأن كل محاضر أعطى علامة لكل مقالة. المتحول المستقل في هذا المثال هو المحاضر الذي أعطى العلامة، والمتحول التابع هو العلامة التي أعطاها المحاضر.

يبين (الجدول 2.11) البيانات لهذا المثال. هناك 8 مقالات تم تقييمها من قبل المحاضرين الأربعة. ويعرض هذا الجدول العلامات التي حصلت عليها المقالات. إضافة لذلك، يعرض الجدول العلامة المتوسطة التي أعطاها كل محاضر، وكذلك العلامة المتوسطة التي حصلت عليها كل مقالة، والتباين للعلامات التي حصلت عليها كل مقالة. إن التباين الكلي ضمن المقالات سيحوي جزءاً ناتجاً عن الاختلاف بين المحاضرين في إعطاء العلامات (التلاعب)، وجزءاً ناتجاً عن أن المقالات ذاتها مختلفة من حيث الجودة (الفروق الفردية).

المقالة	المحاضر 1	المحاضر 2	المحاضر 3	المحاضر 4	المتوسط	التباين s^2
1	62	58	63	64	61.75	6.92
2	63	60	68	65	64.00	11.33
3	65	61	72	65	65.75	20.92
4	68	64	58	61	62.75	18.25
5	69	65	54	59	61.75	43.58
6	71	67	65	50	63.25	84.25
7	78	66	67	50	65.25	132.92
8	75	73	75	45	67.00	216.00
المتوسط	**68.875**	**64.25**	**65.25**	**57.375**		

الجدول 2.11 البيانات لمثال علامات المقالات

1.3.11 المجموع الكلي للمربعات (SS_T)

تذكر أنه قد تم حساب SS_T في ANOVA وحيد الاتجاه المستقل باستخدام المعادلة التالية (انظر المعادلة (4.8)):

$$SS_T = s^2_{grand}(N - 1)$$

نستخدم نفس المعادلة في تصاميم القياسات المكررة لحساب المجموع الكلي للمربعات. التباين الكلي في المعادلة هو ببساطة التباين لكل العلامات عندما نهمل المجموعات التي تنتمي إليها. لذلك إذا عالجنا البيانات كمجموعة كبيرة واحدة فإنها تبدو بالشكل التالي:

64	63	58	62
65	68	60	63
65	72	61	65
61	58	64	68
59	54	65	69
50	65	67	71
50	67	66	78
45	75	73	75
المتوسط الكلي=63.9375			

التباين لهذه العلامات هو 55.028. لقد استخدمنا 32 علامة للحصول على هذه القيمة، ولذلك فإن N=32. وهكذا تصبح المعادلة بالشكل:

$$SS_T = s^2_{grand}(N - 1)$$

$$SS_T = 55.028 \times (32 - 1)$$

$$SS_T = 1705.868$$

إن عدد درجات الحرية لمجموع المربعات الكلي سيكون N-1 كما في حالة ANOVA المستقل ويساوي $df_T=31$.

2.3.11 مجموع المربعات ضمن المشترك (SSw)

إن التغاير الحاسم في هذا التصميم هو وجود تباين يدعى التباين ضمن المشترك (Within-Participant Variance) (ويظهر لأننا نتلاعب بالمتحول المستقل ضمن كل مشترك). عند حساب مجموع المربعات فإننا ننظر إلى مربع الفرق بين علامة المشترك والمتوسط. ويمكن التعبير عن ذلك بدلالة التباين عبر عدد من العلامات وعدد العلامات التي يعتمد التباين عليها. فعلى سبيل المثال، عند حساب مجموع المربعات للبواقي في ANOVA المستقل، استخدمنا المعادلة التالية (انظر المعادلة (7-8)).

$$SS_R = \Sigma(x_{ik} - \bar{x}_k)^2$$

$$SS_R = \Sigma s^2_k(n_k - 1)$$

تعطي هذه المعادلة التباين بين الأفراد ضمن مجموعة معينة، أي أنها تقدير للفروق الفردية ضمن مجموعة معينة. لذلك إذا أردنا حساب القيمة الكلية للفروق الفردية فإنه يتوجب علينا حساب مجموع المربعات ضمن كل مجموعة ثم جمع هذه المجاميع معاً:

$$SS_R = s^2_{group1}(n_1 - 1) + s^2_{group2}(n_2 - 1) + s^2_{group3}(n_3 - 1)$$

كل ذلك جيد ورائع عند وجود أشخاص مختلفين في كل مجموعة، ولكننا في تصاميم القياسات المكررة أخضعنا المشتركين لأكثر من حالة تجريبية، ولهذا فإن ما يهمنا هو التغاير ضمن مشترك

محدد وليس التغاير ضمن مجموعة من المشتركين (كما في ANOVA المستقل). ما هو مقدار التغايرية ضمن فرد معين؟ لإيجاد ذلك، نطرح نفس السؤال عملياً لكننا نلائمه للبحث ضمن الأشخاص بدلاً من المجموعات. لذلك إذا دعونا مجموع المربعات هذا (SS_W) (مجموعات المربعات ضمن المشترك) فإننا نستطيع أن نكتب:

$$SS_W = s^2_{Person1}(n_1 - 1) + s^2_{Person2}(n_2 - 1) + \cdots + s^2_{Personn}(n_n - 1)$$

وتعني هذه المعادلة ببساطة أننا ننظر إلى التغايرية في علامات فرد معين ثم نجمع هذه التباينات لجميع الأفراد في الدراسة. ربما لاحظ بعض القراء أننا نستخدم المقالات بدلاً من الأشخاص في مثالنا، ولذلك نكتب:

$$SS_W = s^2_{essay1}(n_1 - 1) + s^2_{essay2}(n_2 - 1) + \cdots + s^2_{essay8}(n_8 - 1)$$

يمثل ns عدد العلامات التي يعتمد عليها حساب التباينات (أي عدد الحالات التجريبية، وفي مثالنا عدد المحاضرين). يحوي الجدول 2.11 جميع قيم التباين، لذلك نحسب SS_W كما يلي:

$$SS_W = (6.92)(4 - 1) + (11.33)(4 - 1) + (20.92)(4 - 1) + (18.25)(4 - 1)$$
$$+ (43.58)(4 - 1) + (84.25)(4 - 1) + (132.92)(4 - 1) + (216)(4 - 1)$$
$$SS_W = 1602.5$$

ويبلغ عدد درجات الحرية لكل شخص (n-1) حيث n عدد الحالات التجريبية. للحصول على عدد درجات الحرية الكلي نقوم بجمع عدد درجات الحرية لجميع المشتركين. في مثالنا n=4 وعدد المشتركين في كل مجموعة هو 8 (مقالات) لذلك يكون عدد درجات الحرية $df_W=8\times3=24$.

3.3.11 مجموع المربعات للنموذج (SS_M)

حسبنا سابقاً المجموع الكلي للتغاير ضمن البيانات ($SS_T=1705.868$) ونعلم أن 1602.5 وحدة من هذا التغاير يمكن تبريره بالتباين الناتج عن أداء الأفراد (المقالات) في الحالات التجريبية المختلفة، والذي ينقسم إلى قسمين أحدهما ناتج عن التلاعب التجريبي والآخر ناتج عن التذبذبات العشوائية. الخطوة التالية هي إيجاد مقدار التباين الذي يبرره التلاعب التجريبي.

في ANOVA المستقل، أوجدنا مقدار التباين الذي يمكن للنموذج تبريره (SS_M) بالنظر إلى قيم المتوسط في كل مجموعة ومقارنتها مع المتوسط الكلي. ولذلك قمنا بقياس التباين الناتج عن الفروق بين قيم المتوسط للمجموعات المختلفة والمتوسط الكلي (انظر المعادلة (8-5)). ونقوم بنفس العمل في تصميم القياسات المكررة. نحسب أولاً قيمة المتوسط الكلي لكل مستوى من مستويات المتحول المستقل (وفي هذه الحالة العلامة المتوسطة التي أعطاها كل محاضر)، ونقارن هذه القيم مع المتوسط الكلي لجميع العلامات. ولذلك نحسب مجموع المربعات بنفس الطريقة التي اتبعناها في ANOVA المستقل:

1. نحسب الفرق بين المتوسط لكل مجموعة والمتوسط الكلي.
2. نقوم بتربيع كل من هذه الفروق.
3. نضرب كل نتيجة حصلنا عليها بعدد العناصر ضمن المجموعة (n_i).
4. نجمع القيم الناتجة معاً.

$$SS_M = \Sigma n_k(\overline{X}_k - \overline{X}_{grand})^2$$

باستخدام قيم المتوسط من بيانات المثال (الجدول 2.11) نحسب (SS_M) كما يلي:

$$SS_M = 8(68.875 - 63.9375)^2 + 8(64.25 - 63.9375)^2$$
$$+ 8(65.25 - 63.9375)^2 + 8(57.375 - 63.9375)^2$$
$$SS_M = 554.125$$

ويبلغ عدد درجات الحرية لهذا المجموع (k-1) حيث k عدد العناصر المستخدمة لحساب هذا المجموع. من أجل مجموع المربعات للنموذج حسبنا مجموع مربعات الأخطاء بين 4 قيم للمتوسط والمتوسط الكلي. وبما أننا استخدمنا 4 عناصر لحساب هذا المجموع فإن $df_M=k-1=3$. أي أن عدد درجات الحرية للنموذج هو أقل بواحد من عدد الحالات التجريبية.

4.3.11 مجموع المربعات للبواقي (SS_R)

يدلنا مجموع المربعات للبواقي (SS_R) على مقدار التغاير الذي لا يمكن للنموذج تبريره. وهو ناتج عن العوامل الخارجية التي لا يمكن للتجربة التحكم بها (كالاختلاف الطبيعي في جودة المقالات). وبمعرفة (SS_W) و(SS_M) يمكننا حساب (SS_R) ببساطة من العلاقة التالية:

$$SS_W = SS_M + SS_R$$
$$SS_R = SS_W - SS_M$$
$$= 1602.5 - 554.125$$
$$= 1048.375$$

ويكون عدد درجات الحرية لهذا المجموع df_R:

$$df_R = df_W - df_M$$
$$= 24 - 3$$
$$= 21$$

5.3.11 متوسط المربعات

يدلنا (SS_M) على مقدار التغاير الذي يمكن للنموذج تبريره (التلاعب التجريبي) ويدلنا (SS_R) على مقدار التغاير العائد للعوامل الخارجية. وبما أن كل من هاتين القيمتين هي مجموع مربعات فإن عدد

العلامات المستخدمة في الجمع تؤثر على هاتين القيمتين. وكما في حالة ANOVA فإننا نحذف هذا الانحياز بحساب متوسط المربعات (MS)، ويتم ذلك بتقسيم مجموع المربعات على عدد درجات الحرية:

$$MS_M = \frac{SS_M}{df_M} = \frac{554.125}{3} = 184.708$$

$$MS_R = \frac{SS_R}{df_R} = \frac{1048.375}{21} = 49.923$$

يمثل MS_M المقدار المتوسط للتغاير الذي يبرره النموذج (التغاير المنهجي)، بينما يمثل MS_R المقدار المتوسط للتغاير الذي تبرره العوامل الخارجية (التغاير اللامنهجي).

6.3.11 النسبة F

النسبة F هي مقياس لنسبة التغاير الذي يبرره النموذج إلى التغاير الذي تبرره العوامل اللامنهجية. ويمكن حسابها بتقسيم متوسط المربعات للنموذج على متوسط المربعات للبواقي. وهي تماثل تماماً النسبة F في حالة ANOVA المستقل:

$$F = \frac{MS_M}{MS_R}$$

لذلك تبقى النسبة F هي نسب التغاير المنهجي إلى التغاير اللامنهجي، وهي تساوي في هذا المثال:

$$F = \frac{MS_M}{MS_R} = \frac{184.708}{49.923} = 3.70$$

وهذه القيمة أكبر من 1 مما يدل على أن للتلاعب التجريبي أثراً يتجاوز أثر العوامل الخارجية. وكما في حالة ANOVA المستقل فإنه يمكن مقارنة هذه القيمة مع القيم الحرجة اعتماداً على درجات الحرية المستخدمة في حسابها (df_M و df_R وهي 3 و21 في هذا المثال).

4.11 استخدام برنامج SPSS لتنفيذ ANOVA وحيد الاتجاه للقياسات المكررة

1.4.11 التحليل الأساسي

نبقى مع مثال علامات المقالات، ونتذكر القاعدة الذهبية التي ذكرناها في الفصل 2 بخصوص محرر البيانات: كل صف البيانات لمشترك واحد، بينما يمثل كل عمود مستوى من مستويات متحول معين. لذلك تمثل الأعمدة المنفصلة المستويات لمتحول القياسات المكررة. أي أننا لسنا بحاجة لمتحول ترميز (كما في حالة التصاميم بين المجموعات). يمكن إدخال البيانات الموجودة في الجدول 2.11 إلى محرر البيانات في برنامج SPSS بنفس التنسيق كما في الجدول (دون إدخال تسميات الأعمدة). ونبدأ بإنشاء متحول يدعى tutor1 ونستخدم مربع الحوار Labels لإعطاء تسمية معبرة

لهذا المتحول (Dr. Field مثلاً). ثم نعيد نفس الخطوات لإنشاء المتحولات tutor2 و tutor3 و tutor4. يحوي الملف TutorMarks.sav البيانات لهذا المثال.

لتنفيذ ANOVA الذي يستخدم تصميم القياسات المكررة، نختار أمر القائمة Analyze ⇒ General Linear Model ⇒ Repeated Measures... لفتح مربع الحوار Define Factor(s) المبين في الشكل 2.11. نحدد اسم المتحول ضمن المشترك (للقياسات المكررة) وهو المحاضر الذي أعطى العلامة للمقالة في هذا المثال، لذلك نستبدل الكلمة factor1 بالكلمة tutor. إن الاسم المعطى لمتحول القياسات المكررة محدود بثمانية أحرف أو رموز. وعندما نعطي عامل القياسات المكررة اسماً علينا أن نخبر البرنامج بعدد المستويات لذلك العامل (عدد الحالات التجريبية). في هذا المثال لدينا 4 محاضرين، لذلك ندخل الرقم 4 في الحيز المسمى Number of Levels (عدد المستويات). انقر الزر Add لإضافة هذا المتحول إلى قائمة متحولات القياسات المكررة. يظهر هذا المتحول في الحيز السفلي من مربع الحوار بالشكل tutor(4). إذا كان التصميم يحوي عدة متحولات للقياسات المكررة فإنه يمكنك إضافة المزيد من العوامل إلى تلك القائمة. بعد الانتهاء من إدخال متحولات القياسات المكررة المقاسة ننقر الزر Define للانتقال إلى مربع الحوار الرئيسي.

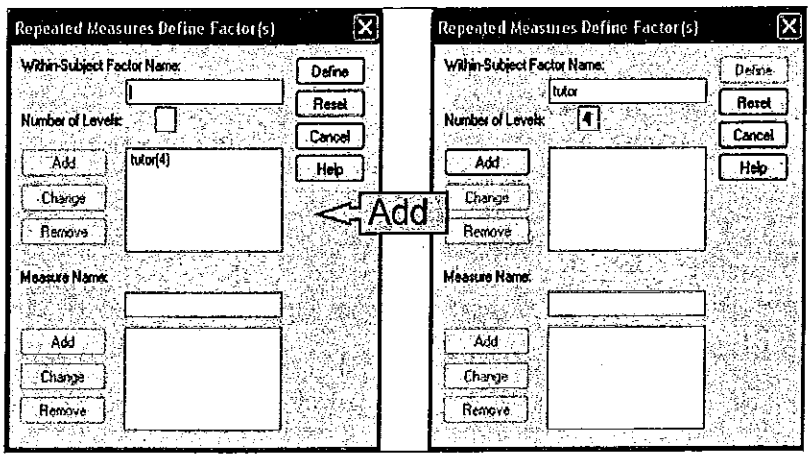

الشكل 2.11 مربع الحوار Define Factor(s) من أجل ANOVA للقياسات المكررة

يحوي مربع الحوار الرئيسي المبين في الشكل 3.11 حيزاً يدعى Within-Subjects Variables ويضم لائحة من 4 علامات استفهام متبوعة برقم. وعلامات الاستفهام هي للمتحولات التي تمثل 4 مستويات للمتحول المستقل. يجب اختيار المتحولات الموافقة لهذه المستويات ووضعها في مكانها المناسب. لدينا 4 متحولات فقط في محرر البيانات، لذلك يمكننا اختيار جميع هذه المتحولات دفعة واحدة ونقلها بنقر زر السهم بين القسمين. بعد نقل جميع المتحولات يمكننا تحديد الخيارات المختلفة للتحليل. هناك عدة خيارات يمكن الوصول إليها عن طريق الأزرار الموجودة في القسم السفلي من مربع الحوار الرئيسي. وهذه الخيارات مشابهة للخيارات التي صادفناها سابقاً.

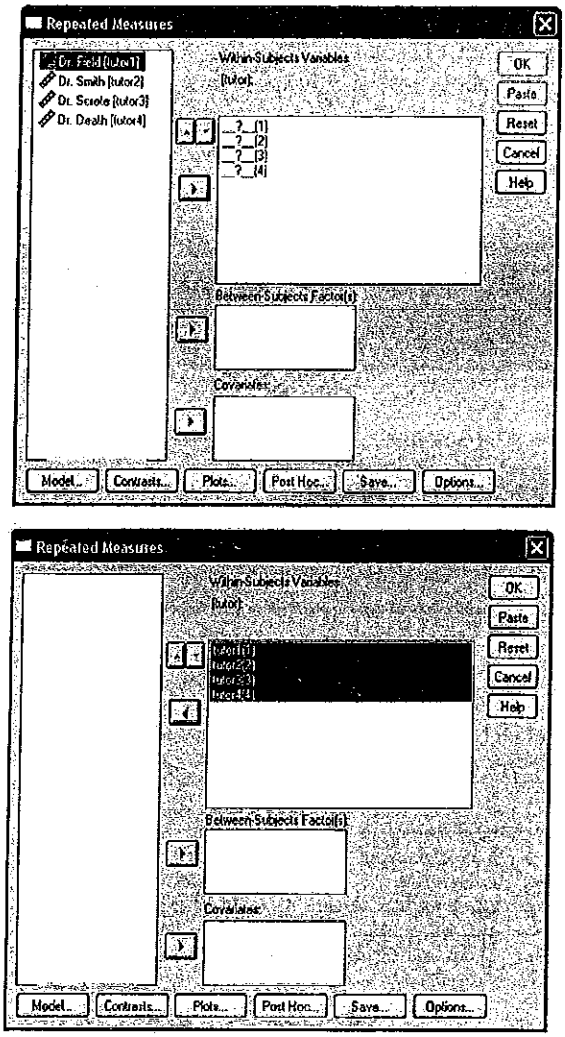

الشكل 3.11 مربع الحوار الرئيسي من أجل ANOVA للقياسات المكررة

2.4.11 تعريف التباينات للقياسات المكررة

في برنامج SPSS من غير الممكن تحديد مقارنات منظمة معرفة من قبل المستخدم في حالة القياسات المكررة (ولكن يمكنك إنجاز ذلك باستخدام القواعد في SPSS). على كل حال، هناك خيار لتنفيذ واحدة من المقارنات القياسية العديدة التي رأيناها سابقاً (انظر الفقرة 3.3.9 لمزيد من التفاصيل حول تغيير المقارنات). إذا نقرت الزر...Contrasts في مربع الحوار الرئيسي فإنه يمكنك الوصول إلى مربع الحوار Contrasts المبين في الشكل 4.11. المقارنة الافتراضية هي المقارنة ذات كثير الحدود، ولكي يمكنك تغيير الخيار الافتراضي عليك اختيار متحول من المتحولات في الحيز المسمى Factors ونقر زر السهم بجانب القائمة المسماة Contrast ثم اختيار المقارنة من القائمة ونقر الزر Change. إذا اخترت المقارنة البسيطة فيمكنك تحديد فيما إذا كنت تريد مقارنة المجموعات مع الفئة الأولى أو

الأخيرة. ستكون الفئة الأولى هي الفئة التي تم إدخالها مع الرقم (1) في مربع الحوار الرئيسي، ومن أجل المثال الحالي، تكون الفئة الأخيرة هي الفئة التي تم إدخالها مع الرقم (4). لذلك فإن الترتيب الذي تم وفقه إدخال البيانات في مربع الحوار الرئيسي هام جداً من أجل المقارنات التي يتم اختيارها.

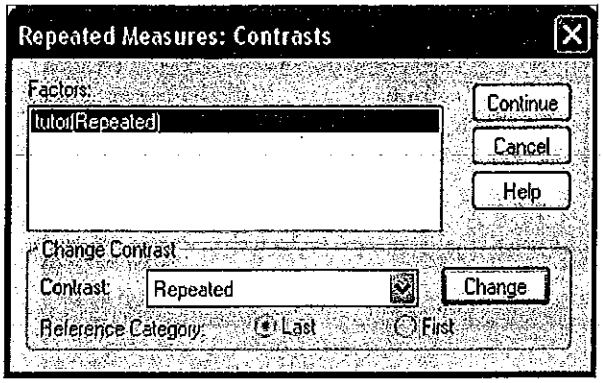

الشكل 4.11 المقارنات للقياسات المكررة

ليست هناك مقارنة مفضّلة للبيانات في المثال الحالي (المقارنة البسيطة غير مفيدة لعدم وجود مجموعة مراقبة) لذلك نقترح استخدام المقارنة المكررة (Repeated) التي تقارن كل محاضر مع المحاضر السابق. يمكن أن تكون هذه المقارنة مفيدة في تصاميم القياسات المكررة حيث لمستويات المتحول المستقل ترتيب ذو معنى، كقياس المتحول التابع في نقاط متتابعة زمنياً، أو الإشراف على جرعات دوائية متزايدة. بعد اختيار هذه المقارنة، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

3.4.11 الاختبارات post hoc والخيارات الإضافية

هناك اعتبارات هامة يجب الانتباه إليها عند التفكير باختبار post hoc الذي تريد استخدامه. إن لخرق فرضية الكروية آثاراً على المقارنات المتعددة. وقد وفر Boik (1981) دراسة قيمة عن آثار عدم الكروية على اختبارات post hoc في تصاميم القياسات المكررة، واستنتج أن انحرافاً صغيراً جداً عن الكروية يعطي انحيازاً كبيراً لاختبار F. لذلك نصح بعدم استخدام هذه الاختبارات في المقارنات للقياسات المكررة. عندما يكون الخطأ التجريبي صغيراً فإن القدرة على اكتشاف الآثار القوية نسبياً يمكن أن يكون منخفضاً لحد 0.05 (عندما تكون الكروية=0.80). وقدم Boik الحجة على أنه لا يمكن تحسين الوضع من أجل المقارنات المتعددة واستنتج التوصية بالتشابه متعدد المتغيرات. وقد وجد Mitzel & Games (1981) أنه عند عدم المحافظة على الكروية ($\varepsilon<1$) فإن حد الخطأ المجمّع المستخدم في المقارنات الثنائية يعطي فروقاً غير مهمة بين متوسطين عندما يكون ذا دلالة (أي أن معدل الخطأ من النوع الأول متساهل) أو فروقاً غير مكتشفة (أي أن معدل الخطأ من

النوع الأول صارم). ولذلك نصح Mitzel & Games باستخدام حدود الخطأ منفصلة لكل مقارنة من المقارنات. اختبر Maxwell (1980) بشكل منهجي مستويات القدرة وalpha من أجل 5 من اختبارات post hoc في حالات القياسات المكررة. والاختبارات التي تم تقييمها هي اختبار Tukey's WSDR الذي يستخدم حد الخطأ المجمع، وإجرائية Tukey ولكن مع حد خطأ منفصل مع عدد درجات حرية يساوي (n-1) ويدعى SEP1، أو (k-1)(n-1) ويدعى SEP2، وإجرائية Bonferroni التي تدعى BON، والحل متعدد المتغيرات المسمى بحال الثقة المتزامن SCI. اختبر Maxwell هذه الإجرائيات بتغيير حجم العينة وعدد مستويات العامل المكرر والانحراف عن الكروية. ووجد أن الحل متعدد المتغيرات كان دائماً "صارماً جداً في الاستخدام العملي" وكان في حده الأقصى عندما كان n (عدد المشتركين) صغيراً مقارنة مع k (عدد الحالات التجريبية). عند ازدياد الانحراف عن الكروية، يضخّم اختبار Tukey معدل alpha بشكل غير مقبول وذلك مهما كان حد الخطأ المستخدم (SEP1 أو SEP2). أما طريقة Bonferroni فكانت متماسكة جداً (وصارمة نوعاً ما) وتتحكم بمستويات alpha بغض النظر عن التلاعب. ولذلك ومن ناحية معدل الخطأ من النوع الأول فإن طريقة Bonferroni هي الأفضل.

ومن حيث قدرة الاختبار (معدل الخطأ من النوع الثاني) لعينة صغيرة (n=8) فقد وجد Maxwell أن إجرائية WSD أكثر فعالية في حالات عدم الكروية، ولكن هذه الميزة تنخفض كثيراً عندما تصبح (n=15). وقد وسع Keselman & Keselmanl (1988) هذا العمل ضمن التصاميم غير المتوازنة. واستخداما أيضاً Tukey's WSD المعدّلة (باستخدام تباين خطأ غير مجمع)، وإحصائية t لـــ Bonferroni والحل متعدد المتغيرات، ووجدا أنه عند استخدام قيم المتوسط غير المثقّلة (مع التصاميم غير المتوازنة) فإن جميع هذه الاختبارات غير قادرة على التحكم بمعدل الخطأ من النوع الأول. وعند استخدام قيم المتوسط المثقّلة فإن الاختبارات متعددة المتغيرات هي الوحيدة القادرة على الحدّ من معدلات alpha، على الرغم من أن إحصائية t لـــ Bonferroni كانت أفضل بكثير من طريقتي Tukey. وفيما يتعلق بالقدرة فقد استنتج Bonferroni & Keselman أنه كلما ازداد عدد مستويات المعالجة المكررة كانت BON أكثر قدرة من SCI.

والخلاصة أنه عند خرق فرضية الكروية تبدو طريقة Bonferroni بشكل عام أكثر تماسكاً من التقنيات متعددة المتغيرات وخاصة فيما يتعلق بالقدرة والتحكم بمعدل الخطأ من النوع الأول. أما عندما لا يتم خرق فرضية الكروية أبداً فإنه يمكن استخدام اختبار Tukey. وفي أي من الحالتين فإن إجرائية Games-Howell التي تستخدم حد الخطأ المجمع هي المفضلة على اختبار Tukey.

يمكن تطبيق مقارنات Bonferroni باستخدام إجرائية اختبار t الثنائي. حيث يتم تنفيذ اختبار t على جميع الثنائيات من مستويات المتحول المستقل ثم تطبيق تصحيح Bonferroni على الاحتمال الذي نقبل عنده هذه الاختبارات. ونحصل على هذا التصحيح بتقسيم قيمة الاحتمال (0.05) على عدد اختبارات t المنفذة. ويجب استخدام قيمة الاحتمال الناتجة كمعيار للدلالة الإحصائية. فعلى سبيل

المثال، إذا قارنا جميع مستويات المتحول المستقل في مثالنا الحالي فإن علينا تنفيذ 6 مقارنات وتكون قيمة الدلالة المناسبة هي 0.05/6=0.0083. لذلك فإننا سنقبل اختبارات t التي لها قيمة دلالة أصغر من 0.0083. ولإنقاذ ما تبقى من قدرة هذه الإجرائية فإننا نقارن فقط المجموعات التي نتوقع ظهور فروق بينها (بدلاً من مقارنة جميع الثنائيات من مستويات المعالجة). فكلما انخفض عدد الاختبارات انخفض مقدار التصحيح على مستوى الدلالة، وتمت المحافظة على قدرة أعلى.

تتوفر بعض إجرائيات post hoc للقياسات المكررة في برنامج SPSS (الإصدار 7.5 وما يليه)، ولكن لا يتم الوصول إليها عبر مربع الحوار post hoc المعروف، إذ أنها جزء من الخيارات الإضافية. يمكن الوصول إلى الخيارات الإضافية بنقر الزر Options... في مربع الحوار الرئيسي حيث يتم فتح مربع الحوار Repeated Measures: Options المبين في الشكل 5.11. لتحديد اختبارات post hoc اختر متحول القياسات المكررة (Tutor في هذا المثال) من الحيز المسمى Factor(s) and Factor Interaction في القسم المسمى Estimated Marginal Means (المتوسطات الهامشية المقدّرة) وانقله إلى الحيز المسمى Display Means for (إظهار المتوسطات من أجل) بنقر زر السهم الموجود بين القسمين. بعد نقل المتحول يتم تفعيل الخيار Compare main effects (مقارنة الآثار الرئيسية)، انقر هذا الخيار لتحديده. بعد تحديد هذا الخيار يتم تفعيل هذه القائمة المنسدلة Confidence interval adjustment (تعديل مجال الثقة) حيث يمكنك فتح القائمة لتحديد الخيار المرغوب من بين خيارات التعديل المتوفرة وعددها 3. الخيار الافتراضي هو عدم القيام بعملية تعديل والاكتفاء بتنفيذ اختبار LSD وهو خيار غير مرغوب. الخيار الثاني هو تطبيق تصحيح Bonferroni (المفضل للأسباب التي ذكرناها سابقاً). أما الخيار الأخير فهو تصحيح Sidak الذي يجب اختياره عند الاهتمام بفقدان القدرة المرتبط بقيم Bonferroni المصححة.

يحوي مربع الحوار Options (الشكل 5.11) خيارات مفيدة أخرى. يمكنك أن تطلب الإحصائيات الوصفية التي تعطي قيم المتوسط والانحراف المعياري وعدد المشتركين في كل مستوى من مستويات المتحول المستقل. يمكنك أن تطلب أيضاً مصفوفة التحويل التي تعطي قيم الترميز لأي من المقارنات المحددة في مربع الحوار Contrasts (المبين في الشكل 4.11)، وهي مفيدة جداً في تفسير المقارنات في التصاميم الأكثر تعقيداً. يمكنك أن تطلب أيضاً طباعة الفرضيات والخطأ ومجموع المربعات للبواقي ومصفوفات الجداء المتصالب (SSCPs)، وسنتعرف على أهمية هذه المصفوفات في الفصل 14. وعندما يكون هناك عامل بين المجموعات (التصاميم المختلطة، انظر الفصل 12) فإن الخيار لاختبار تجانس التباينات يصبح نشطاً. يمكنك أيضاً تغيير مستوى الدلالة الذي يتم عنده اختبار الاختبارات post hoc وبشكل عام فإن القيمة 0.05 تعتبر مقبولة. بعد الانتهاء من تحديد الخيارات المرغوبة، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي. انقر الزر OK لتنفيذ عملية التحليل.

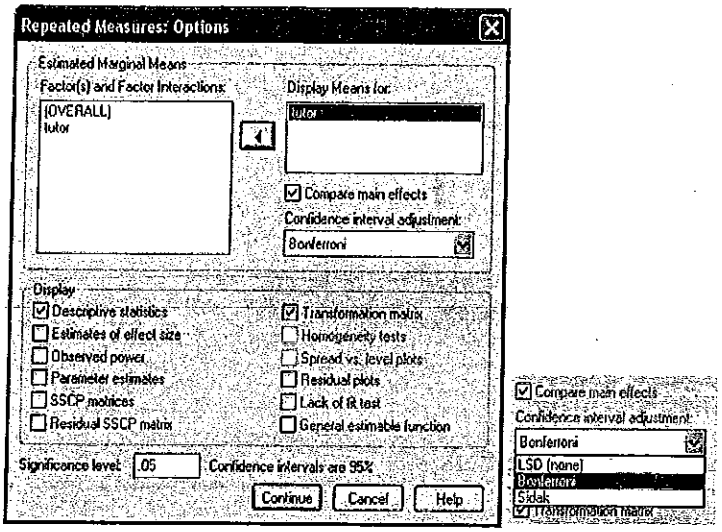

الشكل 5.11 مربع الحوار الخيارات Options

5.11 الخرج من ANOVA وحيد الاتجاه للقياسات المكررة

1.5.11 الإحصائيات الوصفية

يعرض الخرج 1.11 إحصائيات التشخيص الأولية. ونتعرف أولاً على المتحولات التي تمثل كل مستوى من المتحول المستقل وهذا الجدول مفيد للتحقق من إدخال المتحولات بترتيبها الصحيح. يوفر الجدول الثاني الإحصائيات الوصفية الأساسية من أجل المستويات الأربعة للمتحول المستقل. وفي هذا الجدول نرى أن Dr. Field أعطى أعلى العلامات لأن قيمة المتوسط هي الأعلى مقارنة مع المحاضرين الآخرين. وتفيد قيم المتوسط تلك في تفسير أي آثار يمكن أن تنتج عن التحليل الأساسي.

Within-Sbjects Factors

Measure: MEASURE_1

tutor	Dependent Variable
1	tutor1
2	tutor2
3	tutor3
4	tutor4

Descriptive Statistics

	Mean	Std. Deviation	N
Dr. Field	68.8750	5.84263	8
Dr. Smith	64.2500	4.71320	8
Dr. Scrote	65.2500	6.92305	8
Dr. Death	57.3750	7.90908	8

الخرج 1.11

2.5.11 تقييم الكروية وتصحيحها

قلنا في الفقرة 3.2.11 أن برنامج SPSS يعطي اختباراً يبين فيما إذا كانت البيانات قد خرقت فرضية الكروية أم لا. يحوي القسم التالي من الخرج المعلومات عن هذا الاختبار. إذا أردنا أن

نفترض أن شرط الكروية محقق فإن اختبار Mauchly يجب أن يكون بدون دلالة. يعرض الخرج 2.11 اختبار Mauchly لبيانات المثال الحالي، والعمود الأهم في هذا الجدول هو العمود .Sig الذي يحوي قيم الدلالة. تبلغ قيمة الدلالة (0.043) وهي أقل من القيمة الحرجة (0.05) لذلك نقبل أن التباينات للفروق بين المستويات مختلفة بشكل كبير. وبعبارة أخرى تم خرق فرضية الكروية. وبمعرفة ذلك يطرح السؤال التالي نفسه: كيف سنتصرف؟

Mauchly's Test of Sphericity[b]

Measure: MEASURE_1

Within Subjects Effect	Mauchly's W	Approx. Chi-Square	df	Sig.	Epsilon[a]		
					Greenhouse-Geisser	Huynh-Feldt	Lower-bound
tutor	.131	11.628	5	.043	.558	.712	.333

Tests the null hypothesis that the error covariance matrix of the orthonormalized transformed dependent variables is proportional to an identity matrix.

a. May be used to adjust the degrees of freedom for the averaged tests of significance. Corrected tests are displayed in the Tests of Within-Subjects Effects table.

b. Design: Intercept Within Subjects Design: tutor

الخرج 2.11

اكتشفنا في الفقرة 5.2.11 أن برنامج SPSS يعطي ثلاثة تصحيحات بناءً على تقديرات الكروية التي أوصى بها كل من Greenhouse & Geisser (1959) و(1976) Huynh & Feldt. وتزيد هذه التقديرات من عامل التصحيح المطبق على عدد درجات الحرية المستخدم لتقييم النسبة F المراقبة. تتغير قيمة تصحيح Greenhouse- Geisser بين 1/(k-1) (حيث k عدد حالات القياسات المكررة) والقيمة 1.00. وكلما كانت القيمة ε أقرب إلى 1.00 كانت تباينات الفروق أكثر تجانساً، وبالتالي كانت البيانات أقرب إلى الكروية. في مثالنا الحالي هناك 4 حالات وبالتالي فإن الحد الأدنى لقيمة ε سيكون 0.33=1/(4-1) ويعرف بتقدير الحد الأدنى للكروية. يبين الخرج 2.11 أن قيمة ε المحسوبة هي 0.588 وهي قريبة من الحد الأدنى للكروية أكثر من قربها من الحد الأعلى 1.00، وهي تمثل بذلك انحرافاً كبيراً عن الكروية. وسنرى في الفقرة التالية كيفية استخدام هذه القيم.

3.5.11 ANOVA الأساسي

يعرض الخرج 3.11 نتائج ANOVA للمتحول ضمن المشترك. يمكن قراءة هذا الجدول بنفس طريقة ANOVA وحيد الاتجاه بين المجموعات (انظر الفصل 8). هناك مجموع المربعات لأثر القياسات المكررة للمتحول tutor، والذي يدلنا على مقدار التغايرية الذي يبرره الأثر التجريبي. لاحظ أن قيمته هي 554.125 وتساوي مجموع المربعات للنموذج (SS_M) الذي حسبناه في الفقرة 3.3.11. هناك أيضاً حد الخطأ، وهو مقدار التغايرية غير المبررة بين الحالات لمتحول القياسات المكررة. وهذا

الحد هو مجموع المربعات للبواقي (SS_R) الذي تم حسابه في الفقرة 4.3.11 وتبلغ قيمته 1048.375. وكما شرحنا سابقاً فإنه يتم تحويل مجاميع المربعات تلك إلى متوسطات المربعات وذلك بتقسيمها على عدد درجات الحرية. وكما رأينا سابقاً فإن عدد درجات الحرية لأثر tutor هو (k-1) حيث k عدد مستويات المتحول المستقل. أما عدد درجات الحرية لحد الخطأ فهو (k-1)(n-1) حيث n عدد المشتركين (وفي هذه الحالة عدد المقالات) وk عدد مستويات المتحول المستقل. ونحصل على النسبة F بتقسيم متوسط المربعات للأثر التجريبي (184.708) على متوسط المربعات للخطأ (49.923). وكما في ANOVA بين المجموعات فإن إحصائية الاختبار تمثل نسبة التباين المنهجي إلى التباين اللامنهجي. وقيمة F هي 184.708/49.923=3.70 التي تتم مقارنتها مع القيمة الحرجة من أجل درجات الحرية 3 و21. يعرض برنامج SPSS مستوى الدلالة الفعلي للنسبة F وهي F=0.028<0.05. ولذلك نستنتج أن هناك فرقاً مهماً بين العلامات الممنوحة من قبل المحاضرين الأربعة. على كل حال، لا يدلنا هذا الاختبار الأساسي على المحاضرين المختلفين عن البقية في منح العلامات.

مع أن هذه النتيجة تبدو مقبولة ظاهرياً، فقد تعلمنا أن خرق فرضية الكروية يجعل اختبار F غير دقيق. وقد علمنا من الخرج 2.11 أن هذه البيانات غير كروية ولذلك علينا أن نراعي هذا الخرق. يعرض الجدول في الخرج 3.11 النسبة F ودرجات الحرية المرتبطة بها عند افتراض الكروية والإحصائية F ذات الدلالة التي تدل على الفرق بين متوسط العلامات التي يعطيها كل من المحاضرين الأربعة. كما يحوي الجدول عدة أسطر إضافية تعطي القيم المصححة للنسبة F من أجل الأنواع الثلاثة المختلفة للتعديل المطبق (الحد الأدنى و Greenhouse-Geisser و Huynh & Feldt).

Tests of Within-Subjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
tutor	Sphericity Assumed	554.125	3	184.708	3.700	.028
	Greenhouse-Geisser	554.125	1.673	331.245	3.700	.063
	Huynh-Feldt	554.125	2.137	259.329	3.700	.047
	Lower-bound	554.125	1.000	554.125	3.700	.096
Error(tutor)	Sphericity Assumed	1048.375	21	49.923		
	Greenhouse-Geisser	1048.375	11.710	89.528		
	Huynh-Feldt	1048.375	14.957	70.091		
	Lower-bound	1048.375	7.000	149.768		

الخرج 3.11

يعرض الخرج 4.11 جدول ANOVA الموسع مع القيم المصححة لكل من التقديرات الثلاثة للكروية. لاحظ أن قيم النسبة F تبقى ذاتها في جميع الحالات، وما يتغير هو عدد درجات الحرية (وبالتالي القيمة الحرجة التي تتم مقارنة النسبة F معها). تم تعديل عدد درجات الحرية باستخدام تقديرات الكروية المحسوبة في الخرج 2.11. يتم التعديل بضرب عدد درجات الحرية بقيمة تقدير الكروية،

ثم يتم استخدام قيم درجات الحرية الجديدة للتحقق من دلالة النسبة F. ومن أجل المثال الحالي تؤدي التصحيحات إلى جعل F بدون دلالة عند استخدام تصحيح Greenhouse- Geisser لأن (p>0.05). على كل حال، لاحظنا أن هذا التصحيح صارم، ولذلك يمكن أن نفقد الآثار الموجودة فعلياً. لذلك فمن المفيد الاستعانة بإحصائية F المصححة بتصحيح Huynh-Feldt. باستخدام هذا التصحيح تبقى قيمة F ذات دلالة (لأن p<0.05). لذلك وباستخدام هذا التصحيح فإننا نقبل فرضية أن المحاضرين يختلفون في منحهم العلامات. لقد لاحظنا سابقاً أن هذا التصحيح متسامح ولذلك نميل لقبول القيم كذات دلالة بينما هي في الواقع ليست كذلك.

Tests of Within-Subjects Effects

Measure		Source	Type III Sum of Squares	df	Mean Square	F	Sig.
MEASURE_1	Sphericity Assumed	TUTOR	554.125	3	184.708	3.700	.028
		Error(TUTOR)	1048.375	21	49.923		
	Greenhouse-Geisser	TUTOR	554.125	1.673	331.245	3.700	.063
		Error(TUTOR)	1048.375	11.710	89.528		
	Huynh-Feldt	TUTOR	554.125	2.137	259.329	3.700	.047
		Error(TUTOR)	1048.375	14.957	70.091		
	Lower-bound	TUTOR	554.125	1.000	554.125	3.700	.096
		Error(TUTOR)	1048.375	7.000	149.768		

a Computed using alpha = .05

الخرج 4.11

وهذا يتركنا في حيرة، هل نقبل أم نرفض الإحصائية F كذات دلالة. لقد ذكرنا سابقاً أن Stevens (1992) نصح بأخذ المتوسط للتقديرين، وهذه النصيحة تكون ذات فائدة كبيرة عندما يعطي التصحيحان نتائج مختلفة (كما هي الحال في هذا المثال). إذا أدى التصحيحان لنفس النتيجة فيمكنك تقديم أي منهما لأن الفرق سيكون ضئيلاً جداً (فإذا قبلنا الإحصائية F كذات دلالة فمن الأفضل تقديم تقدير Greenhouse-Geisser الصارم لتجنب النقد!). ومع أن حساب متوسط عاملَي التصحيح وتصحيح عدد درجات الحرية وفقاً له يتم بسهولة، فإنه ليس من السهل حساب الاحتمال الدقيق لدرجات الحرية تلك. لذلك وبما أنك ستواجه هذا الوضع المحرج دائماً فإننا ننصح بحساب المتوسط لقيمتي الدلالة للحصول على فكرة عامة عن عامل التصحيح الذي يعطي الجواب الأدق. وفي هذه الحالة، فإن متوسط قيمتي الاحتمال هو 0.055=0.063+0.047)/2). لذلك فمن المرجح اعتماد تصحيح Greenhouse-Geisser واستنتاج أن النسبة F بدون دلالة.

توضح هذه البيانات مدى أهمية استخدام قيمة حرجة صالحة للنسبة F، وقد تعني الفرق بين نتيجة ذات دلالة إحصائية ونتيجة غير ذات دلالة إحصائية. والأهم من ذلك أنها قد تعني الفرق بين ارتكاب الخطأ من النوع الأول أو عدم ارتكابه. إذا لم نستخدم التصحيحات للكروية فإننا نستنتج

بشكل خاطئ أن المحاضرين يمنحون العلامات بطرق مختلفة تماماً. على كل حال، علينا تحديد هذه العبارة بالقول أن هذا المثال يلقي الضوء على مدى الاعتباطية في استخدام المستوى 0.05 للدلالة. يعطي هذان التصحيحان قيم دلالة أصغر أو أكبر بقليل من القيمة 0.05 ويقودان إلى استنتاجات متعاكسة تماماً. لذلك علينا أن ننظر إلى حجم الأثر لمعرفة فيما إذا كان الأثر حقيقياً بغض النظر عن قيمة دلالته.

رأينا سابقاً أن الخيار الأخير المتوفر عندما تخرق البيانات فرضية الكروية هو استخدام إحصائيات الاختبار متعددة المتغيرات لأنها لا تعتمد هذه الفرضية. يعرض الخرج 5.11 إحصائيات الاختبار متعددة المتغيرات لهذا المثال (يمكنك إيجاد التفاصيل حول هذه الإحصائيات في الفقرة 4.3.14). يبين العمود Sig. الذي يعرض قيم الدلالة أن الاختبارات متعددة المتغيرات بدون دلالة (لأن p=0.063>0.05). لنتذكر دائماً فقدان القدرة في هذه الاختبارات (انظر الفقرة 5.2.11) وبالتالي فإن هذه النتيجة تدعم القرار بقبول فرضية العدم واستنتاج عدم وجود فروق مهمة في العلامات التي منحها المحاضرون الأربعة. يجب أن يتوقف الآن تفسير هذه النتائج لأن الأثر الرئيسي بدون دلالة. على كل حال، سننظر إلى الخرج الخاص بالمقارنات لتوضيح كيفية عرض هذه الاختبارات في صفحة العارض لبرنامج SPSS.

Multivariate Tests

	Value	F	Hypothesis df	Error df	Sig.
Pillai's trace	.741	4.760[a]	3.000	5.000	.063
Wilks' lambda	.259	4.760[a]	3.000	5.000	.063
Hotelling's trace	2.856	4.760[a]	3.000	5.000	.063
Roy's largest root	2.856	4.760[a]	3.000	5.000	.063

Each F tests the multivariate effect of tutor. These tests are based on the linearly independent pairwise comparisons among the estimated marginal means.

a. Exact statistic

الخرج 5.11

4.5.11 المقارنات

يعرض الخرج 6.11 مصفوفة التحويل التي طلبناها أثناء تحديد الخيارات، وعلينا أن نستفيد من معرفتنا بترميز المقارنة (انظر الفصل 8) لتفسير هذا الجدول. إن أول ما يجب أن نتذكره هو أن الرمز 0 يعني أن المجموعة غير مشمولة بالمقارنة. لذلك فالمقارنة الأولى (التي تحمل التسمية Level 1 vs. Level 2 في هذا الجدول) تهمل Dr. Scrote و Dr. Death. والشيء الثاني الذي يجب أن نتذكره هو أن المجموعات ذات التثقيل السالب تتم مقارنتها مع المجموعات ذات التثقيل الموجب. وفي هذه الحالة فإن ذلك يعني أن المقارنة أولى تقارن Dr. Field مع Dr. Smith. وباستخدام نفس المنطق،

فإن المقارنة الثانية (التي تحمل التسمية Level 2 vs. Level 3) تهمل Dr. Field و Dr. Death وتقارن Dr. Smith مع Dr. Scrote. وأخيراً فإن المقارنة الثالثة (التي تحمل التسمية Level 3 vs. Level 4) تقارن Dr. Death مع Dr. Scrote. إن هذا النمط من المقارنات منسجم مع ما نتوقع الحصول عليه من مقارنة مكررة (أي أن كل مجموعة باستثناء الأولى تتم مقارنتهما مع المجموعة السابقة). أما مصفوفة المقارنة التي تظهر في القسم السفلي من الخرج فيتم استخدامها بشكل أساسي لتأكيد ما تمثله كل واحدة من المقارنات المذكورة.

tutor[a]

Measure: MEASURE_1

Dependent Variable	tutor		
	Level 1 vs. Level 2	Level 2 vs. Level 3	Level 3 vs. Level 4
Dr. Field	1	0	0
Dr. Smith	-1	1	0
Dr. Scrote	0	-1	1
Dr. Death	0	0	-1

a. The contrasts for the within subjects factors are:
tutor: Repeated contrast

الخرج 6.11

ونجد فوق مصفوفة التحويل جدولاً يلخص المقارنات (الخرج 7.11). يتم عرض كل مقارنة بدورها، وكما في حالة المقارنات بين المجموعات، فإنه يتم تنفيذ اختبار F لمقارنة قسمين من التغاير. لذلك إذا نظرنا إلى قيم الدلالة في الجدول، يمكننا القول أن Dr. Field يمنح علامات أعلى بكثير مما يمنحه Dr. Smith (Level 1 vs. Level 2)، ولكن Dr. Smith يعطي علامات مساوية تقريباً لما يعطيه Dr. Scrote (Level 2 vs. Level 3)، وكذلك Dr. Scrote يعطي علامات مساوية تقريباً لما يعطيه Dr. Death (Level 3 vs. Level 4). على كل حال، يجب إهمال المقارنة ذات الدلالة لأن الأثر الرئيسي بدون دلالة (تذكر أن البيانات لا تخضع لشرط الكروية). النقطة الهامة التي يجب ملاحظتها هي أن الكروية في البيانات قد قادت إلى ظهور بعض المسائل الهامة حول عوامل التصحيح، وحول اعتماد الحذر والتحفظ في التعامل مع هذه البيانات. في هذا المثال، علينا أن نستنتج عدم وجود فروق هامة بين العلامات التي منحها مختلف المحاضرين. على كل حال، إن غموض البيانات يفرض علينا إجراء دراسة مماثلة لعدد أكبر من المقالات التي تم تصحيحها ومنحها علامات.

Tests of Within-Subjects Contrasts

Measure: MEASURE_1

Source	tutor	Type III Sum of Squares	df	Mean Square	F	Sig.
tutor	Level 1 vs. Level 2	171.125	1	171.125	18.184	.004
	Level 2 vs. Level 3	8.000	1	8.000	.152	.708
	Level 3 vs. Level 4	496.125	1	496.125	3.436	.106
Error(tutor)	Level 1 vs. Level 2	65.875	7	9.411		
	Level 2 vs. Level 3	368.000	7	52.571		
	Level 3 vs. Level 4	1010.875	7	144.411		

الخرج 7.11

5.5.11 اختبارات post hoc

إذا حددنا اختبارات post hoc لمتحول القياسات المكررة في مربع الحوار Options (انظر الفقرة 3.4.11) فإن برنامج SPSS يعطي الجدول المبين في الخرج 8.11.

يعرض الجدول في الخرج 8.11 الفرق بين متوسطات المجموعات، والخطأ المعياري، وقيمة الدلالة، ومجال الثقة للفرق بين المتوسطات. بالنظر إلى قيم الدلالة فإننا نرى أن الفرق الوحيد بين متوسطات المجموعات هو بين Dr. Field و Dr. Smith. بالنظر إلى المتوسطات لهذه المجموعات (الخرج 1.11) فإننا نجد أن Dr. Field أعطى علامات أعلى بكثير مما أعطاه Dr. Smith. على كل حال، هناك نتيجة شاذة وهي عدم وجود فرق مهم بين العلامات التي أعطاها Dr. Field و Dr. Death على الرغم من أن متوسط الفرق بين العلامات مرتفع (11.5) وأعلى من متوسط الفرق بين العلامات التي أعطاها Dr. Field و Dr. Smith (4.6). والسبب في هذه النتيجة هو الكروية في البيانات. ربما عليك تنفيذ تحليل الارتباط بين العلامات التي منحها المحاضرون الأربعة. وستجد أن هناك ارتباطاً طردياً قوياً جداً بين العلامات التي أعطاها Dr. Field و Dr. Smith (مما يدل على مستوى منخفض من التغايرية في البيانات). على كل حال، هناك ارتباط ضعيف جداً بين العلامات التي أعطاها Dr. Field و Dr. Death (مما يدل على مستوى مرتفع من التغايرية بين علاماتهما). وهذه التغايرية الكبيرة بين علامات Dr. Field و Dr. Death هي التي أعطت نتيجة غير مهمة على الرغم من أن متوسط العلامات كان مختلفاً جداً (وهذه الملاحظة بديهية من خلال الخطأ المعياري).

Pairwise Comparisons

Measure: MEASURE_1

(I) tutor	(J) tutor	Mean Difference (I-J)	Std. Error	Sig.[a]	95% Confidence Interval for Difference[a]	
					Lower Bound	Upper Bound
1	2	4.625*	1.085	.022	.682	8.568
	3	3.625	2.841	1.000	-6.703	13.953
	4	11.500	4.675	.261	-5.498	28.498
2	1	-4.625*	1.085	.022	-8.568	-.682
	3	-1.000	2.563	1.000	-10.320	8.320
	4	6.875	4.377	.961	-9.039	22.789
3	1	-3.625	2.841	1.000	-13.953	6.703
	2	1.000	2.563	1.000	-8.320	10.320
	4	7.875	4.249	.637	-7.572	23.322
4	1	-11.500	4.675	.261	-28.498	5.498
	2	-6.875	4.377	.961	-22.789	9.039
	3	-7.875	4.249	.637	-23.322	7.572

Based on estimated marginal means

*. The mean difference is significant at the .05 level.

a. Adjustment for multiple comparisons: Bonferroni.

الخرج 8.11

أفكار مفيدة

- يقارن ANOVA وحيد الاتجاه للقياسات المكررة عدة قيم للمتوسط قادمة من نفس المشتركين.
- في ANOVA للقياسات المكررة هناك فرضية إضافية هي الكروية (Sphericity). وهي مطلوبة عندما يكون عدد حالات القياسات المكررة ثلاث أو أكثر. يتم اختبار الكروية باستخدام اختبار Mauchly. ابحث عن هذا الجدول، فإذا كانت قيمة الدلالة في العمود Sig. أصغر من 0.05 فإن الفرضية غير محققة. أما إذا كانت قيمة الدلالة لاختبار Mauchly أكبر من 0.05 فإن فرضية الكروية محققة.
- يعرض الجدول المسمى Test of within-Subjects Effects الأثر الأساسي لـ ANOVA . إذا كانت فرضية الكروية محققة فانظر إلى الصف المسمى Sphericity Assumed. إذا تم خرق فرضية فانظر إلى الصف المسمى Greenhouse-Geisser (يمكنك أن تنظر أيضاً إلى Huynh-Feldt ولكن عليك قراءة هذا الفصل لإيجاد الميزات النسبية لكل من الإجرائيتين). بعد اختيار الصف المناسب ابحث عن قيمة الدلالة في العمود المسمى Sig. فإذا كانت القيمة أصغر من 0.05 فإن قيم المتوسط للمجموعات مختلفة بشكل كبير.
- من أجل المقارنات واختبارات post hoc، ابحث عن قيمة الدلالة في العمود المسمى Sig. لاكتشاف فيما إذا كانت المقارنات ذات دلالة أم لا (ستكون ذات دلالة إذا كانت القيمة أصغر من 0.05).

6.11 حجم الأثر لـ ANOVA للقياسات المكررة

إن أفضل قياس لحجم الأثر الكلي هو أوميغا مربع ω^2 كما في حالة ANOVA المستقل. ولكننا لا نستطيع استخدام نفس المعادلات في حالة ANOVA للقياسات المكررة، لأنها تعطي تقديراً للأثر أكبر من حجمه الفعلي.

ومعادلة أوميغا مربع في حالة ANOVA للقياسات المكررة هي:

$$\omega^2 = \frac{\left[\frac{k-1}{n.k}(MS_M - MS_R)\right]}{MS_R + \frac{MS_{BG} - MS_R}{k} + \left[\frac{k-1}{n.k}(MS_M - MS_R)\right]} \qquad (1.11)$$

وتحوي هذه المعادلة متوسط المربعات للنموذج (MS_M) ومتوسط المربعات للبواقي (MS_R) ويمكن الحصول عليهما من جدول ANOVA الذي يعطيه برنامج SPSS (الخرج 3.11). كما تحوي k عدد الحالات التجريبية (k=4 عدد المحاضرين)، وn عدد المشتركين (n=8 عدد المقالات). المشكلة الرئيسية هي الحد MS_{BG}. إذا عدنا لبداية الفقرة 3.11 (الشكل 1.11) فإننا نجد أنه يمكن تقسيم التغاير الكلي إلى قسمين: التغاير ضمن المشترك والتغاير بين المجموعات. وفي جميع الحسابات اللاحقة بدا أننا نسينا التغاير بين المجموعات (لأنه غير ضروري لحساب النسبة F). ولكنه ظهر مجدداً في معادلة ω^2. إن أسهل طريقة لحساب هذا الحد هي استخدام المعادلة التالية (المستنتجة من الشكل 1.11):

$$SS_T = SS_{BG} + SS_W$$

لا يعطي برنامج SPSS قيمة SS_W في الخرج، ولكننا نعلم أنه مكون من SS_M وSS_R، لذلك تأخذ المعادلة السابقة الشكل التالي:

$$SS_T = SS_{BG} + SS_M + SS_R$$

$$SS_{BG} = SS_T - SS_M - SS_R$$

المشكلة الثانية هي أن برنامج SPSS لا يعطي قيمة SS_T، ولكننا حسبنا هذه القيمة يدوياً في الفقرة 1.3.11. بتعويض القيم في المعادلة السابقة نحصل على:

$$SS_{BG} = 1705.868 - 554.125 - 1048.375$$

$$= 103.37$$

الخطوة التالية هي تحويل هذا التغاير إلى متوسط مربعات وذلك بتقسيمه على عدد درجات الحرية الموافق (n-1):

$$MS_{BG} = \frac{SS_{BG}}{df_{BG}} = \frac{SS_{BG}}{n-1}$$

$$MS_{BG} = \frac{103.37}{8-1} = 14.77$$

نعوض القيم في معادلة ω^2 لنحصل على حجم الأثر:

$$\omega^2 = \frac{\left[\frac{4}{8\times 4}(184.71 - 49.92)\right]}{49.92 + \frac{14.77 - 49.92}{4} + \left[\frac{4}{8\times 4}(184.71 - 49.92)\right]} = 0.24$$

إذا حسبنا ω^2 من أجل ANOVA المستقل (انظر الفقرة 5.8) فإننا نحصل على $\omega^2=0.25$ وهي قيمة أعلى بقليل مما حصلنا عليه هنا.

لقد ذكرنا في نقاط مختلفة أنه من المفيد حساب حجم الأثر من أجل مقارنات مركّزة (بدلاً من ANOVA الأساسي). والطريقة الأبسط لحساب حجم الأثر هي حساب من أجل المقارنات التي قمنا بتنفيذها (انظر الخرج 7.11) وذلك باستخدام المعادلة التي استخدمناها سابقاً لتحويل قيم F إلى r (لأنها تملك درجة حرية واحدة للنموذج):

$$r = \sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}$$

ومن أجل المقارنات التي لدينا فإننا نحصل على:

$$r_{Field\ vs.\ Smith} = \sqrt{\frac{18.18}{18.18 + 7}} = 0.85$$

$$r_{Smith\ vs.\ Scorte} = \sqrt{\frac{0.15}{0.15 + 7}} = 0.14$$

$$r_{Scorte\ vs.\ Death} = \sqrt{\frac{3.44}{3.44 + 7}} = 0.57$$

لذلك فالفرق بين (Dr. Field وDr. Smith) و(Dr. Scorte وDr. Death) هي آثار كبيرة، بينما الفروق بين Dr. Smith وDr. Scorte هي صغيرة.

7.11 تقديم ANOVA وحيد الاتجاه للقياسات المكررة

عند تقديم ANOVA للقياسات المكررة فإننا نعطي نفس التفاصيل التي نعطيها عند تقديم ANOVA المستقل. والإضافة الوحيدة التي يجب أن نهتم بها هي تقديم عدد درجات الحرية إذا تم خرق فرضيّة الكروية. كما يمكن تقديم نتائج اختبارات الكروية. ودرجات الحرية المستخدمة لتقييم النسبة F هي عدد درجات الحرية من أجل أثر النموذج (df_M=1.67) وعدد درجات الحرية من أجل بواقي

النموذج (df_R=11.71). تذكر أننا قمنا بتصحيح درجات الحرية في هذا المثال باستخدام تقديرات Greenhouse- Geisser المصححة للكروية. ولذلك يمكننا تقديم النتيجة الأساسية بالشكل التالي:

- ✓ تُظهر النتائج أن علامة المقالة غير متأثرة بشكل كبير بالمحاضر الذي يمنح العلامة، $F(1.67,11.71)=3.70, p>0.05$.

إذا أردت تقديم اختبار الكروية فإن عليك عرض تقريب كاي مربع، وعدد درجات الحرية وقيمة الدلالة. ومن المفيد أيضاً ذكر درجة الكروية بتقديم قيمة ε. ونقدم أيضاً حجم الأثر في هذه النسخة المحسنة:

- ✓ يدل اختبار Mauchly على أنه تم خرق فرضية الكروية ($\chi_2(5)=11.63, p<0.05$)، لذلك تم تصحيح عدد درجات الحرية باستخدام تقدير Greenhouse-Geisser للكروية (ε=0.56). وتظهر النتائج أن علامة المقالة لم تتأثر بالمحاضر الذي يمنح العلامة، ω^2, $F(1.67,11.71)=3.70, p>0.05$.

تذكر أنه طالما كان ANOVA الأساسي بدون دلالة فلا يمكنك تقديم أي تحليل آخر.

8.11 القياسات المكررة مع عدة متحولات مستقلة

رأينا سابقاً أنه يمكن توسيع التصميم بين المجموعات البسيط ليضم متحولاً مستقلاً ثانياً (أو ثالثاً). ويمكن بنفس السهولة تضمين متحول مستقل ثان أو ثالث أو رابع في تحليل القياسات المكررة. وكمثال يبحث بعض علماء الاجتماع في إمكانيةً تأثير الصور على موقف الناس من الكحول. ويهتم هؤلاء الباحثون في الإجابة على سؤالين. فمن جهة قدمت الحكومة تمويلاً لدراسة إمكانية استخدام الصور السلبية في الإعلانات لتغيير موقف الناس من الكحول. ومن جهة أخرى قدمت إحدى شركات الكحول تمويلاً لمعرفة فيما إذا كان ممكناً استخدام الصور الإيجابية لتحسين موقف الناس من الكحول. وقد صمم الباحثون دراسةً للتعامل مع هاتين المسألتين. يوضح الجدول 3.11 التصميم التجريبي ويحوي البيانات لهذا المثال (يمثل كل صف مشتركاً وحيداً).

يشاهد المشتركون 9 إعلانات خلال 3 جلسات. في الجلسة الأولى يشاهدون 3 إعلانات: (1) تقديم ماركة بيرة بصورة سلبية (جثة مع شعار "إن شرب هذه البيرة يجعل كبدك ينفجر"). (2) تقديم ماركة نبيذ بصورة إيجابية (شخص جذاب مع شعار مناسب). (3) تقديم ماركة مياه بصورة حيادية (شخص يشاهد التلفزيون مع شعار "إنّ شُربَ هذا الماء يجعلك تتصرف بشكل طبيعي تماماً"). في الجلسة الثانية (بعد أسبوع) يشاهد المشتركون الماركات الثلاث ولكن في هذه المرة تم عرض ماركة البيرة مع الصورة الإيجابية، وماركة النبيذ مع الصورة الحيادية، وماركة المياه مع الصورة السلبية. وفي الجلسة الثالثة، شاهد المشتركون ماركة البيرة مع الصورة الحيادية، وماركة النبيذ مع الصورة السلبية وماركة المياه مع الصورة الإيجابية. وبعد كل إعلان كان المشتركون يضعون تقييماً للمشروب على مقياس يتراوح بين 100- (لا يحبه أبداً) مروراً بالصفر (حيادي) وصولاً إلى 100+ (يحبه جداً). وكان ترتيب عرض الإعلانات عشوائياً وكذلك ترتيب مشاركة

الأشخاص في الجلسات الثلاث. إن هذه التصميم معقد جداً. وهناك متحولان مستقلان: نوع المشروب (بيرة، نبيذ، ماء) ونوع الصورة المستخدمة (إيجابية، سلبية، حيادية). ويتقاطع هذان المتحولان بشكل كامل مما يعطي 9 حالات تجريبية.

المشروب	البيرة			النبيذ			الماء		
الصورة	إيجابية	سلبية	حيادية	إيجابية	سلبية	حيادية	إيجابية	سلبية	حيادية
ذكر	1	6	5	38	-5	4	10	-14	-2
	43	30	8	20	-12	4	9	-10	-13
	15	15	12	20	-15	6	6	-16	1
	40	30	19	28	-4	0	20	-10	2
	8	12	8	11	-2	6	27	5	-5
	17	17	15	17	-6	6	10	-6	-13
	30	21	21	15	-2	16	10	-20	3
	34	23	28	27	-7	7	10	-12	2
	34	20	26	24	-10	12	10	-9	4
	26	27	27	23	-15	14	10	-6	0
أنثى	1	-19	-10	28	-13	13	10	-2	9
	7	-18	6	26	-16	19	10	-17	5
	22	-8	4	34	-23	14	10	-19	0
	30	-6	3	32	-22	21	10	-11	4
	40	-6	0	24	-9	19	10	-10	2
	15	-9	4	29	-18	7	10	-17	8
	20	-17	9	30	-17	12	10	-4	10
	9	-12	-5	24	-15	18	10	-4	8
	14	-11	7	34	-14	20	10	-1	12
	15	-6	13	23	-15	15	10	-1	10

الجدول 3.11 البيانات من الملف Attitude.sav

1.8.11 التحليل الأساسي

لإدخال هذه البيانات علينا أن نتذكر القاعدة الذهبية لمحرر البيانات، والتي تنص على أن كل سطر يمثل البيانات لمشترك واحد. إذا شارك شخص في جميع الحالات التجريبية (وهذا يعني بالنسبة للمثال الحالي أنه شاهد جميع أنواع المشروب المقدمة مع جميع أنواع الصور) فإنه يتم تمثيل كل حالة تجريبية بعمود واحد في محرر البيانات. في هذه التجربة هناك 9 حالات تجريبية لذلك يجب إدخال البيانات في 9 أعمدة (التنسيق مماثل للجدول 3.11). يجب عليك إنشاء 9 متحولات في محرر البيانات لها الأسماء المعطاة والتسمية الكاملة التوضيحية (انظر الفقرة 2.4.2).

اسم المتحول	التسمية التوضيحية	ملاحظة
beerpos	Beer + Sexy person	إعلان البيرة بصورة إيجابية
beerneg	Beer + Corpse	إعلان البيرة بصورة سلبية
beerneut	Beer + person in Armchair	إعلان البيرة بصورة حيادية
winepos	Wine + Sexy person	إعلان النبيذ بصورة إيجابية
wineneg	Wine + Corpse	إعلان النبيذ بصورة سلبية
wineneut	Wine + person in Armchair	إعلان النبيذ بصورة حيادية
waterpos	Water + Sexy person	إعلان الماء بصورة إيجابية
waterneg	Water + Corpse	إعلان الماء بصورة سلبية
waterneu	Water + person in Armchair	إعلان الماء بصورة حيادية

بعد إنشاء هذه المتحولات، عليك إدخال البيانات من الجدول 3.11. إذا لم ترغب بإدخال البيانات فيمكنك استخدام الملف Attitude.sav. للوصول إلى مربع الحوار الخاص بتعريف العوامل Define Factor(s) استخدم أمر القائمة Analyze ⇒ General linear Model ⇒ Repeated Measures... لدينا عاملان ضمن المشترك هما drink (بيرة، نبيذ، ماء) و imagery (إيجابية، سلبية، حيادية). استبدل الكلمة factor1 بالكلمة drink، وحدد عدد المستويات لهذا العامل وذلك بكتابة الرقم 3 في الحيز المسمى Number of Levels. انقر الزر Add لإضافة هذا المتحول إلى لائحة متحولات القياسات المكررة. يظهر هذا المتحول في الحيز الموجود في القسم السفلي من مربع الحوار بالشكل drink(3) نكرر هذه الخطوات من أجل المتحول الثاني imagery حيث نحصل على imagery(3). يعرض (الشكل 6.11) الحالة النهائية لمربع الحوار. عند الانتهاء من إدخال المتحولين ننقر الزر Define للانتقال إلى مربع الحوار الرئيسي.

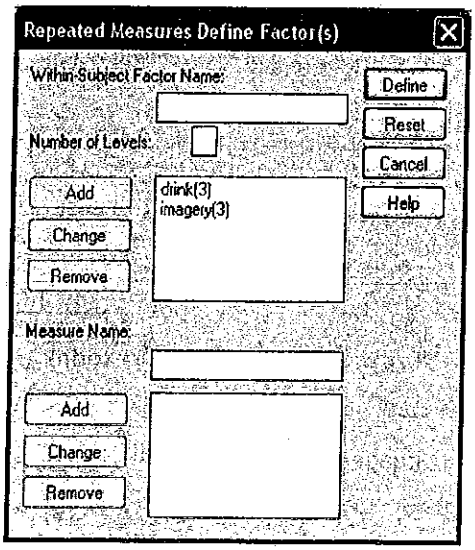

الشكل 6.11 مربع الحوار تعريف العوامل Define Factor(s) من أجل ANOVA العاملي للقياسات المكررة

إن مربع الحوار الرئيسي مماثل لحالة متحول مستقل واحد باستثناء أن هناك 9 علامات استفهام حالياً (الشكل 7.11). يوضح برنامج SPSS في القسم العلوي من مربع الحوار وجود عاملين اثنين هما: imagery وdrink. وفي الحيز تحت تلك العبارة هناك سلسلة من علامات الاستفهام تليها أرقام بين قوسين. تمثل هذه الأرقام مستويات العاملين (المتحولين المستقلين).

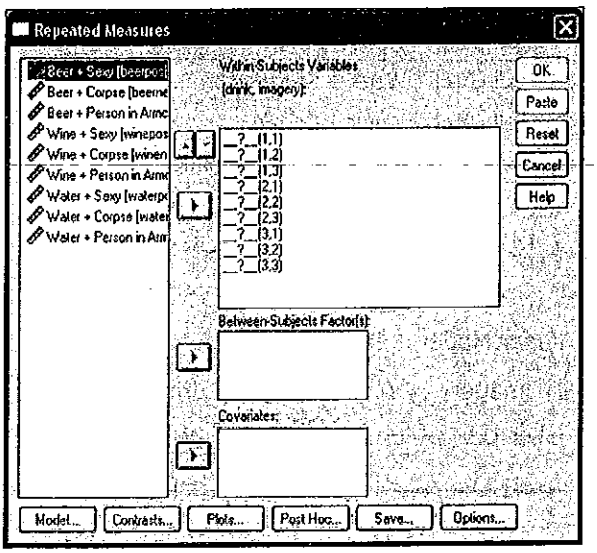

الشكل 7.11 مربع الحوار الرئيسي من أجل ANOVA للقياسات المكررة

في هذا المثال، هناك متحولان مستقلان ولذلك هناك رقمان بين القوسين. يمثل الرقم الأول مستويات العامل الأول المذكور في القسم العلوي من مربع الحوار (وهو drink في هذا المثال)، أما الرقم الثاني فيمثل مستويات العامل الثاني (وهو imagery). وكما في حالة ANOVA وحيد الاتجاه للقياسات المكررة فإن المطلوب هو استبدال علامات الاستفهام بأسماء المتحولات الموجودة في القسم الأيسر من مربع الحوار. في التصميم بين المجموعات حيث نستخدم متحولات الترميز، تكون المستويات لعامل معين محددة بالرموز المعينة لها في محرر البيانات. أما في تصميم القياسات المكررة فليس هناك وجود لمخطط ترميز ولذلك نحدد الحالة التي نريد تعيينها لمستوى ما في هذه المرحلة. فعلى سبيل المثال، إذا أدخلنا المتحول beerpos إلى اللائحة أولاً فإن برنامج SPSS يعالج البيرة كالمستوى الأول من المتحول drink، والصورة الإيجابية كالمستوى الأول من المتحول imagery. أما إذا أدخلنا wineneg إلى اللائحة أولاً فإن برنامج SPSS يعتبر النبيذ هو المستوى الأول من المتحول drink، والصورة السلبية هي المستوى الأول من المتحول imagery. ولهذا السبب، فمن الضروري أن نفكر ملياً بنوع المقارنات التي قد نرغب بتنفيذها وذلك قبل إدخال المتحولات في مربع الحوار. في هذا التصميم، إذا نظرنا إلى المتحول الأول drink فإنه يملك 3 حالات، اثنتان منها تشملان مشروباً كحولياً، أي أن حالة الماء تعمل كحالة مراقبة لمعرفة فيما إذا كانت آثار الصورة خاصة

بالكحول. لذلك ومن أجل هذا المتحول فإننا قد نرغب بمقارنة حالتي البيرة والنبيذ من جهة مع حالة الماء من جهة أخرى. ويمكن تنفيذ هذه المقارنة إما بتحديد مقارنة بسيطة (انظر الجدول 6.8) حيث تتم مقارنة حالتي البيرة والنبيذ مع حالة الماء، أو باستخدام مقارنة فرق حيث تتم مقارنة كلتا حالتي الكحول مع حالة الماء قبل أن تتم مقارنتهما مع بعضهما البعض. وفي كلتا الحالتين يجب إدخال حالة الماء كمستوى أول أو أخير للمتحول المستقل drink (لأنه لا يمكننا تحديد المستوى الأوسط كفئة مرجعية في المقارنة البسيطة). لنفكر الآن بالعامل الثاني imagery. يملك هذا العامل فئة مراقبة أيضاً ولا نتوقع منها التأثير على الموقف (الصورة الحيادية). وكما في الحالة السابقة، فقد نهتم باستخدام هذه الفئة كفئة مرجعية في مقارنة بسيطة ولذلك فمن الضروري أن يتم إدخال الفئة الحيادية في المستوى الأول والأخير.

اعتماداً على ما تمت مناقشته في استخدام المقارنات، يمكننا اعتماد حالة الماء في المستوى الثالث للمتحول drink والحالة الحيادية في المستوى الثالث للمتحول imagery. أما بقية المستويات فيمكن تحديدها بشكل اختياري. لقد اخترنا حالة البيرة لتكون المستوى الأول وحالة النبيذ لتكون المستوى الثاني للمتحول drink. واخترنا حالة الصورة الإيجابية لتكون المستوى الأول وحالة الصورة السلبية لتكون المستوى الثاني للمتحول imagery وتعني هذه القرارات أنه يجب إدخال المتحولات كما يلي:

beerpos	_?_(1,1)
beerneg	_?_(1,2)
beerneut	_?_(1,3)
winepos	_?_(2,1)
wineneg	_?_(2,2)
wineneut	_?_(2,3)
waterpos	_?_(3,1)
waterneg	_?_(3,2)
waterneu	_?_(3,3)

وهذا الترتيب هو نفس الترتيب الذي يتم به عرض المتحولات في محرر البيانات، وقد حدثت هذه المصادفة لأننا نعرف مسبقاً المقارنات التي سنقوم بتنفيذها، ولذلك قمنا بإدخال المتحولات بالترتيب المناسب. بعد نقل هذه المتحولات، يأخذ مربع الحوار الرئيسي الشكل النهائي المبين في الشكل 8.11. لقد تم وصف الأزرار الموجودة في القسم السفلي من مربع الحوار سابقاً ولذلك نكتفي بوصف أكثرها ارتباطاً بحالتنا.

2.8.11 المقارنات

بعد التحليل الأساسي، من المهم مقارنة مستويات المتحولات المستقلة لمعرفة أي منها هو المختلف. وكما رأينا سابقاً فإنه لا توجد أدوات مساعدة لإدخال رموز المقارنة (ما لم يتم استخدام القواعد) ولذلك علينا الاعتماد على المقارنات القياسية المتوفرة (انظر الجدول 6.8).

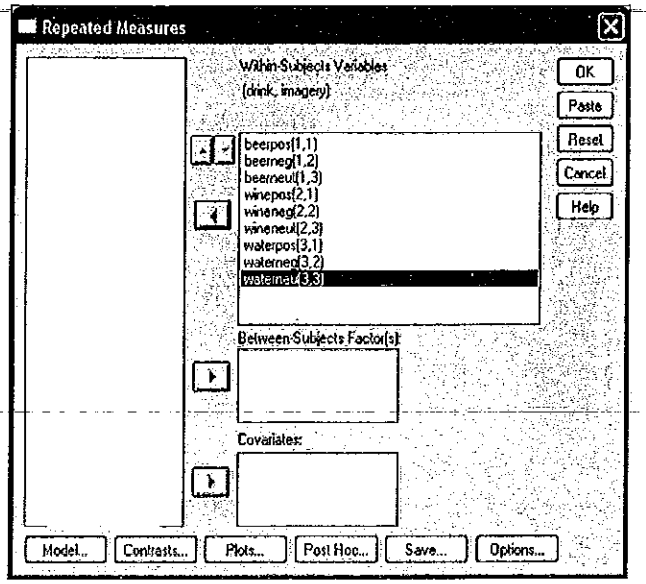

الشكل 8.11 الشكل النهائي لمربع الحوار الرئيسي

يعرض الشكل 9.11 مربع الحوار الخاص بتنفيذ المقارنات ويتم الوصول إليه بنقر الزر ...Contrasts في مربع الحوار الرئيسي. لقد وضحنا في الفقرة السابقة أهمية استخدام حالتي الماء والحيادية كفئات مرجعية للعاملَين drink وimagery. لقد استخدمنا مربع الحوار Contrasts سابقاً في الفقرتين 3.3.9

و2.4.11 وكل ما نقوله هو أن نختار المقارنة البسيطة (Simple) لكل من المتحولين المستقلين. ومن أجل كلا المتحولين المستقلين، قمنا بإدخال المتحولات بحيث تكون فئة المراقبة هي الأخيرة، لذلك ليست هناك حاجة لتغيير الفئة المرجعية من أجل المقارنة البسيطة. بعد تحديد المقارنات، ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي. هناك طريقة بديلة للمقارنات المتوفرة وهي تحليل الآثار البسيطة (انظر المربع 1.11).

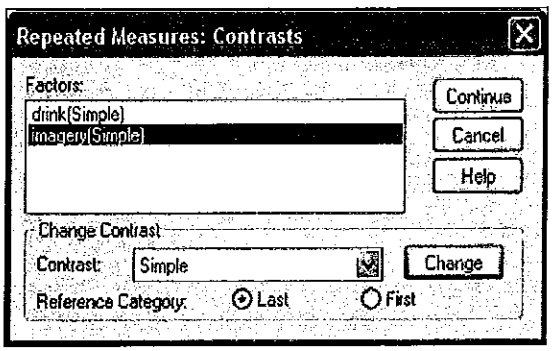

الشكل 9.11 مربع الحوار Contrasts

المربع 1.11 تحليل الآثار البسيطة

رأينا في الفصل السابق أن هناك طريقة أخرى لتقسيم حد التفاعل وهي استخدام تقنية تدعى تحليل "الآثار البسيطة". وينظر هذا التحليل إلى أثر متحول مستقل واحد عند مستويات منفصلة للمتحول المستقل الآخر. ومن أجل المثال الحالي، يمكننا أن ننظر إلى أثر المتحول drink من أجل الصورة الإيجابية، ثم من أجل الصورة السلبية، ثم من أجل الصورة الحيادية. أو يمكننا أن نقوم بتحليل أثر المتحول imagery بشكل منفصل من أجل البيرة، ثم من أجل النبيذ، ثم من أجل الماء. وفي تصميم القياسات المكررة فإنه يمكننا إجراء تحليل الآثار البسيطة من خلال قواعد SPSS، ولكن البرنامج النصي مختلف قليلاً. ونستخدم في هذا المثال البرنامج النصي التالي:

```
MANOVA
beerpos beerneg beerneut winepos wineneg wineneut waterpos waterneg waterneu
/WSFACTORS drink(3) imagery(3)
```

تقوم هذه الأسطر ببدء ANOVA وذلك بتحديد المتحولات (في محرر البيانات) التي تربط مستويات متحولات القياسات المكررة. تقوم بعد ذلك تعليمة /WSFACTORS بتعريف متحولي القياسات المكررة. إن ترتيب عرض المتحولات من محرر البيانات هام جداً. لذلك وبما أننا قمنا بتعريف drink(3) imagery(3) فإن برنامج SPSS يبدأ عند المستوى الأول من المتحول drink، وبما أننا حددنا 3 مستويات للمتحول imagery فإن البرنامج يستخدم المتحولات الثلاثة الأولى الموجودة في السطر الثاني لمستويات المتحول imagery عند المستوى الأول من المتحول drink. ينتقل بعد ذلك إلى المستوى الثاني للمتحول drink ويستخدم المتحولات الثلاثة التالية في السطر الثاني لتكون مستويات المتحول imagery ذات الصلة. وينتقل أخيراً إلى المستوى الثالث للمتحول drink ويستخدم المتحولات الثلاثة الأخيرة لتكون مستويات المتحول imagery. لننظر إلى ترتيب المتحولات في السطر الثاني فنجد أن المتحولات الثلاثة الأولى تتعلق بالبيرة (وتختلف تبعاً لنوع الصورة)، وأن المتحولات الثلاثة التالية تتعلق بالنبيذ وتختلف بمستويات الصورة، وأن المتحولات الثلاثة الأخيرة تتعلق بالماء وتختلف بمستويات الصورة. وبما أننا وضعنا المتحولات بهذا الترتيب فقد توجب علينا تعريف المتحول drink(3) أولاً ثم المتحول imagery(3) (من الممكن أيضاً كتابة السطر الثالث بالشكل:

```
/WSFACTORS imagery(3) drink(3)
```

ولكن في هذه الحالة علينا ترتيب المتحولات في السطر الثاني بالشكل:

```
beerpos winepos waterpos beerneg wineneg waterneg beerneut wineneut waterneu
/WSDESIGN=MWITHIN drink(1) MWITHIN drink(2) MWITHIN drink(3)
```

يحدد هذا السطر الآثار البسيطة. فعلى سبيل المثال تطلب التعليمة MWITHIN drink(1) أن يقوم برنامج SPSS بتحليل أثر imagery عند المستوى الأول للمتحول drink (أي عند استخدام البيرة). أما إذا أردنا مقارنة المتحول drink عند المستويات المختلفة للمتحول imagery فعلينا أن نكتب السطر السابق بالشكل التالي:

```
/WSDESIGN=MWITHIN imagery(1) MWITHIN imagery(2) MWITHIN imagery(3)
/PRINT
SIGNIF(UNIV MULT AVERF HF GG).
```

يقوم السطران الأخيران بطلب طباعة ANOVA الأساسي (SIGNIF).

يحوي الملف SimpleEffectsAttitude.sps هذا البرنامج النصي الذي يقوم بتحليل أثر الصورة عند المستويات المختلفة للمتحول drink. بعد تحميل الملف Attitude.sav في محرر البيانات يمكنك فتح ملف البرنامج النصي وتنفيذه. إن تنسيق الخرج الذي نحصل عليه هو نصي (بدلاً من الجداول الجميلة). ويكرر جزء منه نتائج ANOVA الأساسي. يتم تقديم الآثار البسيطة بالشكل التالي:

```
* * * * * * Analysis of Variance -- design 1 * * * * * *

Tests involving 'MWITHIN DRINK(1)' Within-Subject Effect.

 Tests of Significance for T1 using UNIQUE sums of squares
 Source of Variation          SS      DF        MS          F  Sig of F

 WITHIN+RESIDUAL         7829.67      19    412.09
 MWITHIN DRINK(1)        8401.67       1   8401.67      20.39       .000


* * * * * * Analysis of Variance -- design 1 * * * * * *

Tests involving 'MWITHIN DRINK(2)' Within-Subject Effect.

 Tests of Significance for T2 using UNIQUE sums of squares
 Source of Variation          SS      DF        MS          F  Sig of F

 WITHIN+RESIDUAL          376.00      19     19.79
 MWITHIN DRINK(2)        4166.67       1   4166.67     210.55       .000


* * * * * * Analysis of Variance -- design 1 * * * * * *

Tests involving 'MWITHIN DRINK(3)' Within-Subject Effect.

 Tests of Significance for T3 using UNIQUE sums of squares
 Source of Variation          SS      DF        MS          F  Sig of F

 WITHIN+RESIDUAL         1500.32      19     78.96
 MWITHIN DRINK(3)         742.02       1    742.02       9.40       .006
```

يعطي الجدول المسمى MWITHIN drink(1) تحليل التباين لأثر المتحول imagery من أجل البيرة (المستوى الأول من المتحول drink)، وتعطي الجداول التالية تحليل التباين لأثر المتحول imagery من أجل النبيذ والماء. عند النظر إلى قيم الدلالة لكل أثر بسيط تظهر الآثار ذات الدلالة للمتحول imagery على جميع مستويات المتحول drink. يمكننا أن نقوم أيضاً بتحليل آثار التفاعل باستخدام مقارنات معرفة خصيصاً من أجل حد التفاعل. ولسوء الحظ لا يمكن القيام بذلك إلا باستخدام القواعد وهي عملية معقدة نوعاً ما. يمكن الاستعانة بالملف بالملحق A.10 لمعرفة المزيد عن هذه العملية.

3.8.11 رسم التفاعلات

عندما كان لدينا متحول مستقل وحيد، لم نستخدم مربع الحوار plots، ولكن عند وجود عاملين أو أكثر يصبح مربع الحوار plots وسيلة ملائمة لرسم المتوسطات لكل مستوى من مستويات هذه العوامل. انقر الزر ...plots في مربع الحوار الرئيسي للوصول إلى مربع الحوار plots. اختر المتحول drink من لائحة المتحولات في القسم الأيسر من مربع الحوار وانقله إلى الحيز المسمى

Horizontal Axis (المحور الأفقي). ونضع المتحول المستقل المتبقي imagery في الحيز المسمى Separate Lines. انقر الزر Add لتتم إضافة مخطط التفاعل إلى الحيز السفلي في مربع الحوار الذي يحوي المخططات المطلوبة (انظر الشكل 10.11). عند الانتهاء من تحديد المخططات، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

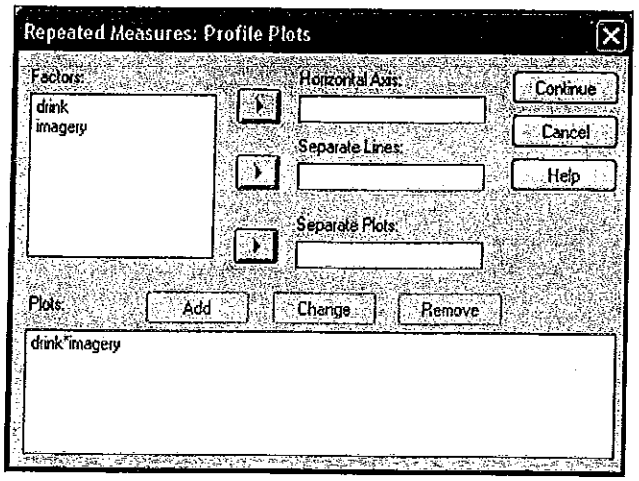

الشكل 10.11 مربع الحوار لرسم المخططات Plots

4.8.11 الخيارات الأخرى

إن اختبارات post hoc تكون غير نشطة في تصاميم القياسات المكررة. لذلك فإن الخيارات الأخرى المتبقية هي في مربع الحوار Options الذي يتم الوصول إليه بنقر الزر ...Options في مربع الحوار الرئيسي. والخيارات المتوفرة هنا هي نفس الخيارات في حالة ANOVA وحيد الاتجاه. وننصح هنا باختيار بعض الإحصائيات الوصفية والمقارنات المتعددة وذلك بتحديد جميع العوامل في الحيز المسمى Factor(s) and Factors Interactions ونقلها إلى الحيز المسمى Display Means for (انظر الشكل 11.11). بعد اختيار هذه المتحولات نحدد الخيار Compare main effects لمقارنة الآثار الرئيسية، ونختار التصحيح المناسب. والخيار الوحيد المتبقي الذي يتمتع بأهمية خاصة هو خيار مصفوفة التحويل Transformation matrix. يعطي هذا الخيار خرجاً إضافياً مهماً لتفسير نتائج المقارنات.

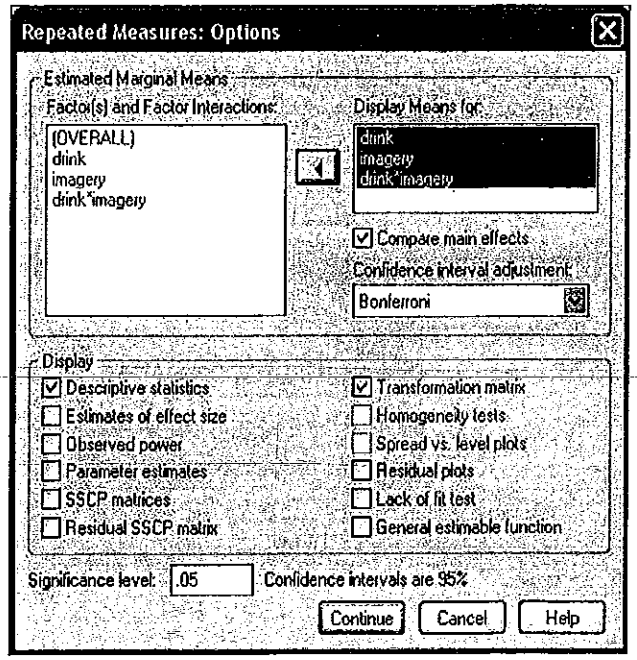

الشكل 11.11 مربع الحوار Options

9.11 الخرج من ANOVA العاملي للقياسات المكررة

1.9.11 الإحصائيات الوصفية والتحليل الأساسي

يعرض الخرج 9.11 الخرج الأولي من ANOVA. ويعرض الجدول الأول المتحولات المتضمَّنة من محرر البيانات والمستوى الذي تمثله لكل متحول مستقل. ويتمتع هذا الجدول بأهمية أكبر مما يبدو عليه لأنه يسمح بالتحقق من إدخال المتحولات بالترتيب الصحيح من أجل المقارنات التي سيتم تنفيذها. أما الجدول الثاني فيعرض الإحصائيات الوصفية ويوفر قيم المتوسط والانحراف المعياري لكل من الحالات التسع. والأسماء في هذا الجدول هي التسميات التي تم إعطاؤها للمتحولات في محرر البيانات.

إن الإحصائيات الوصفية مفيدة في دلالتها على أن التغايرية بين العلامات كانت أكبر عند استخدام البيرة كمنتج (قارن الانحرافات المعيارية لمتحولات البيرة مع المتحولات الأخرى). وعند استخدام صورة الجثة (الصورة السلبية) فإن العلامات التي تم منحها للمنتج كانت سالبة (كما هو متوقع) من أجل النبيذ والماء ولكن ليس من أجل البيرة (لذلك ولسبب ما فإن الصورة السلبية لا تعمل كما هو متوقع مع البيرة). تساعدنا القيم الموجودة في هذا الجدول على تفسير الآثار الرئيسية لهذا التحليل لاحقاً.

Within-Sbjects Factors

Measure: MEASURE_1

drink	imagery	Dependent Variable
1	1	beerpos
	2	beerneg
	3	beerneut
2	1	winepos
	2	wineneg
	3	wineneut
3	1	waterpos
	2	waterneg
	3	waterneu

Descriptive Statistics

	Mean	Std. Deviation	N
Beer + Sexy	21.0500	13.00799	20
Beer + Corpse	4.4500	17.30371	20
Beer + Person in Armchair	10.0000	10.29563	20
Wine + Sexy	25.3500	6.73778	20
Wine + Corpse	-12.0000	6.18147	20
Wine + Person in Armchair	11.6500	6.24310	20
Water + Sexy	17.4000	7.07404	20
Water + Corpse	-9.2000	6.80248	20
Water + Person in Armchair	2.3500	6.83855	20

الخرج 9.11

يعرض الخرج 10.11 نتائج اختبار Mauchly للكروية (انظر الفقرة 3.2.11) لكل من الآثار الثلاثة في النموذج (الأثران الرئيسيان وأثر التفاعل). تشير قيم الدلالة لهذه الاختبارات إلى أن الآثار الرئيسية لكل من المتحولين drink وimagery قد خرقت فرضية الكروية ولذلك يجب تصحيح قيم F (انظر الفقرة 2.5.11). أما من أجل التفاعل فإن فرضية الكروية محققة (لأن $p>0.05$) ولا نحتاج بالتالي لأي تصحيح للنسبة F لهذا الأثر.

Mauchly's Test of Sphericity[b]

Measure: MEASURE_1

Within Subjects Effect	Mauchly's W	Approx. Chi-Square	df	Sig.	Epsilon[a]		
					Greenhouse-Geisser	Huynh-Feldt	Lower-bound
drink	.267	23.753	2	.000	.577	.591	.500
imagery	.662	7.422	2	.024	.747	.797	.500
drink * imagery	.595	9.041	9	.436	.798	.979	.250

Tests the null hypothesis that the error covariance matrix of the orthonormalized transformed dependent variables is proportional to an identity matrix.

a. May be used to adjust the degrees of freedom for the averaged tests of significance. Corrected tests are displayed in the Tests of Within-Subjects Effects table.

b. Design: Intercept Within Subjects Design: drink+imagery+drink*imagery

الخرج 10.11

يعرض الخرج 11.11 نتائج ANOVA (مع قيم F المصححة). وقد تم تقسيم هذا الخرج لعدة أقسام تدل على كل من الآثار في النموذج وحدود الخطأ المرتبطة بهذه الآثار. وبالنظر إلى قيم الدلالة نجد بوضوح أن هناك أثراً مهماً لنوع المشروب المستخدم، وأثراً رئيسياً مهماً لنوع الصورة المستخدمة، وتفاعلاً مهماً بين هذين المتحولين. وسنشرح كل أثر من هذه الآثار بدوره.

2.9.11 أثر المتحول Drink

يدلنا القسم الأول من الخرج 11.11 على أثر نوع المشروب المستخدم في الإعلان. ومن أجل هذا الأثر علينا أن ننظر إلى واحدة من قيم الدلالة المصححة لأن فرضية الكروية غير محققة. إن جميع

القيم المصححة ذات دلالة ولذلك علينا تقديم قيم Greenhouse-Geisser المصححة لدرجات الحرية. ويدلنا هذا الأثر على أنه إذا أهملنا نوع الصورة المستخدمة فإن المشتركين يستمرون بتقييم أنواع المشروب بشكل مختلف تماماً.

Tests of Within-Sbjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
drink	Sphericity Assumed	2092.344	2	1046.172	5.106	.011
	Greenhouse-Geisser	2092.344	**1.154**	1812.764	**5.106**	**.030**
	Huynh-Feldt	2092.344	1.181	1770.939	5.106	.029
	Lower-bound	2092.344	1.000	2092.344	5.106	.036
Error(drink)	Sphericity Assumed	7785.878	38	204.892		
	Greenhouse-Geisser	7785.878	**21.930**	355.028		
	Huynh-Feldt	7785.878	22.448	346.836		
	Lower-bound	7785.878	19.000	409.783		
imagery	Sphericity Assumed	21628.678	2	10814.339	122.565	.000
	Greenhouse-Geisser	21628.678	**1.495**	14468.490	**122.565**	**.000**
	Huynh-Feldt	21628.678	1.594	13571.496	122.565	.000
	Lower-bound	21628.678	1.000	21628.678	122.565	.000
Error(imagery)	Sphericity Assumed	3352.878	38	88.234		
	Greenhouse-Geisser	3352.878	**28.403**	118.048		
	Huynh-Feldt	3352.878	30.280	110.729		
	Lower-bound	3352.878	19.000	176.467		
drink * imagery	Sphericity Assumed	2624.422	4	656.106	**17.455**	.000
	Greenhouse-Geisser	2624.422	3.194	821.778	17.155	.000
	Huynh-Feldt	2624.422	3.914	670.462	17.155	.000
	Lower-bound	2624.422	1.000	2624.422	17.155	.001
Error(drink*imagery)	Sphericity Assumed	2906.689	76	38.246		
	Greenhouse-Geisser	2906.689	60.678	47.903		
	Huynh-Feldt	2906.689	74.373	39.083		
	Lower-bound	2906.689	19.000	152.984		

الخرج 11.11

طلبنا في الفقرة 4.8.11 أن يقوم برنامج SPSS بعرض قيم المتوسط لجميع الآثار في النموذج (قبل القيام باختبارات post hoc) وإذا بحثنا في الخرج فإننا نجد في القسم المسمى Estimated Marginal Means الجدول المبين في الخرج 12.11. وهو عبارة عن جدول لقيم المتوسط للأثر الرئيسي للمتحول drink مع الأخطاء المعيارية المرتبطة بها. وتم ترقيم مستويات هذا المتحول بالأرقام 1 و 2 و 3، وبالعودة إلى طريقة إدخال هذه المتحولات فإننا نعرف الحالة التجريبية التي يمثلها كل سطر في الجدول. لقد أدخلنا حالة البيرة أولاً ثم النبيذ ثم الماء.

Estimates

Measure: MEASURE_1

drink	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
1	11.833	2.621	6.348	17.319
2	8.333	.574	7.131	9.535
3	3.517	1.147	1.116	5.918

الخرج 12.11

يستخدم الشكل 12.11 المعلومات السابقة لإظهار قيم المتوسط لكل حالة تجريبية. من الواضح أنه قد تم تقييم البيرة والنبيذ بعلامات أعلى من الماء (ونالت البيرة أعلى العلامات). لمعرفة طبيعة هذا الأثر يمكننا أن ننظر إلى اختبارات post hoc والمقارنات (انظر الفقرة 5.9.11).

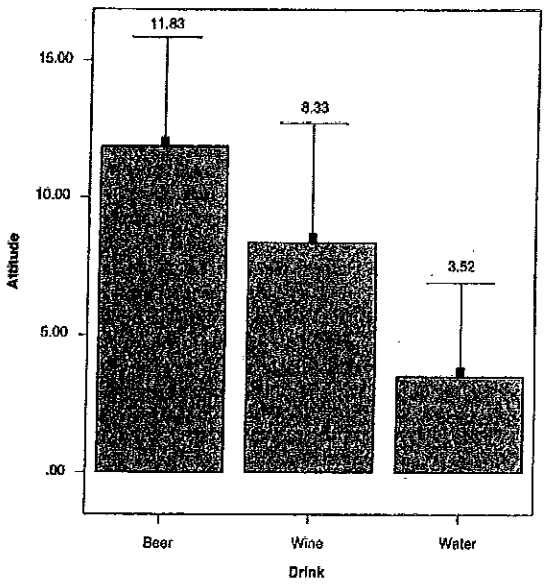

الشكل 12.11 مخطط القيم المتوسطة لمستويات المتحول drink

يعرض الخرج 13.11 المقارنات الثنائية للأثر الرئيسي للمتحول drink مصححاً باستخدام تعديل Bonferroni. يدل هذا الجدول على أن الأثر الرئيسي ذا الدلالة يعكس فرقاً مهماً ($p<0.01$) بين المستوى الثاني (النبيذ) والمستوى الثالث (الماء). وما يثير الفضول أن الفرق بين حالتي البيرة والماء أكبر من الفرق بين حالتي النبيذ والماء مع أن ذلك الأثر غير مهم ($p>0.05$). يمكن تفسير هذا التضارب بالنظر إلى الخطأ المعياري في حالة البيرة ومقارنته مع حالة النبيذ. إن الخطأ المعياري في حالة النبيذ صغير جداً ولذلك فإن الفرق بين قيم المتوسط كبير نسبياً (انظر الفصل 6). لنحاول

إعادة تنفيذ اختبارات post hoc ولكن نختار القيم غير المصححة (LSD) في مربع الحوار Options (انظر الفقرة 4.8.11). ستجد أن الفرق بين حالتي البيرة والماء أصبح ذا دلالة (p=0.02). توضح هذه النتيجة أهمية التحكم بمعدل الخطأ وذلك باستخدام تصحيح Bonferroni. لو لم نستخدم هذا التصحيح لاستنتجنا بشكل خاطئ أن علامات البيرة كانت أعلى بكثير من علامات الماء.

Pairwise Comparisons

Measure: MEASURE_1

(I) drink	(J) drink	Mean Difference (I-J)	Std. Error	Sig.[a]	95% Confidence Interval for Difference[a]	
					Lower Bound	Upper Bound
1	2	3.500	2.849	.703	-3.980	10.980
	3	8.317	3.335	.066	-.438	17.072
2	1	-3.500	2.849	.703	-10.980	3.980
	3	4.817*	1.116	.001	1.886	7.747
3	1	-8.317	3.335	.066	-17.072	.438
	2	-4.817*	1.116	.001	-7.747	-1.886

Based on estimated marginal means

*. The mean difference is significant at the .05 level.

a. Adjustment for multiple comparisons: Bonferroni.

الخرج 13.11

3.9.11 أثر المتحول imagery

يبين الخرج 11.11 أن الأثر لنوع الصورة المستخدمة في الإعلان يؤثر بشكل كبير على تقييم المشاركين للمشروب المستخدم. ومرة أخرى، علينا أن ننظر إلى إحدى القيم المصححة لأن فرضية الكروية غير محققة. إن جميع القيم المصححة عالية الدلالة ولذلك نقدم قيم Greenhouse-Geisser المصححة لدرجات الحرية. يدلنا هذا الأثر على أنه إذا أهملنا نوع المشروب المستخدم فإن تقييم المشتركين للمشروب سيختلف تبعاً لنوع الصورة المستخدمة. لقد طلبنا في الفقرة 4.8.11 قيم المتوسط لجميع الآثار في النموذج، وإذا بحثنا في الخرج فإننا نعثر على الجدول المبين في الخرج 14.11 (بعد المقارنات الثنائية للأثر الرئيسي للمتحول drink). ويعرض هذا الجدول قيم المتوسط للمتحول imagery مع الأخطاء المعيارية المرتبطة بها. تم ترقيم مستويات هذا المتحول بالأرقام 1 و2 و3، وبالعودة إلى طريقة إدخال هذه المتحولات فإننا نعرف الحالة التجريبية التي يمثلها كل سطر في الجدول. لقد أدخلنا حالة الصورة الإيجابية أولاً ثم الصورة السلبية ثم الحيادية.

يستخدم الشكل 13.11 المعلومات السابقة لإظهار قيم المتوسط لكل حالة تجريبية. من الواضح أن الصورة الإيجابية أدت إلى تقييم إيجابي جداً (مقارنة مع الصورة الحيادية) أما الصورة السلبية فقد أدت إلى تقييم سلبي (مقارنة مع أثر الصورة الحيادية بشكل خاص). لمعرفة طبيعة هذا الأثر يمكننا أن ننظر إلى اختبارات post hoc والمقارنات (انظر الفقرة 5.9.11).

Estimates

Measure: MEASURE_1

imagery	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
1	21.267	.977	19.222	23.312
2	-5.583	1.653	-9.043	-2.124
3	8.000	.969	5.972	10.028

الخرج 14.11

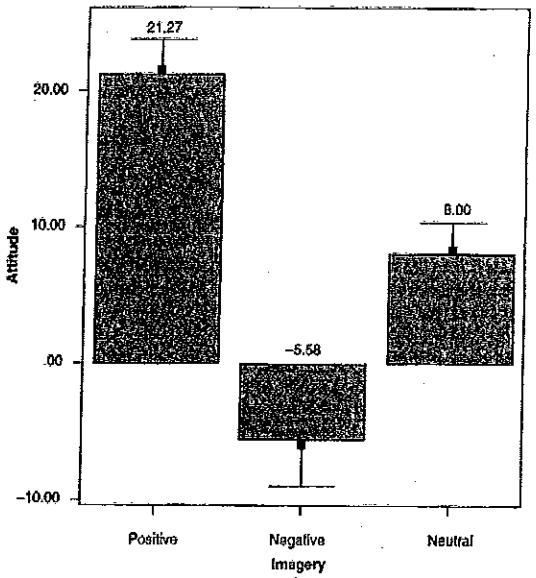

الشكل 13.11 مخطط القيم المتوسطة لمستويات المتحول imagery

يعرض الخرج 15.11 المقارنات الثنائية للأثر الرئيسي للمتحول imagery مصححاً باستخدام تعديل Bonferroni. يدل هذا الجدول على أن الأثر الرئيسي ذا الدلالة يعكس فروقاً مهمة (جميع القيم $p<0.01$) بين المستوى الأول (الصورة الإيجابية) والمستوى الثاني (الصورة السلبية)، وبين المستوى الأول والمستوى الثالث (الصورة الحيادية)، وبين المستوى الثاني والمستوى الثالث.

4.9.11 أثر التفاعل (drink×imagery)

يدل الخرج 11.11 على أن المتحول imagery يتفاعل بطريقة ما مع مستويات المتحول drink (أنواع المشروب المستخدمة). ومن هذا الجدول يمكننا أن نقول أن هناك تفاعلاً مهماً بين نوع المشروب المستخدم والصورة المرتبطة به، $F(4,76)=17.16,\ p<0.001$. ويدلنا هذا الأثر على أن لنوع الصورة المستخدمة أثراً مختلفاً يعتمد على نوع المشروب المقدم معها.

Pairwise Comparisons

Measure: MEASURE_1

(I) imagery	(J) imagery	Mean Difference (I-J)	Std. Error	Sig.[a]	95% Confidence Interval for Difference[a]	
					Lower Bound	Upper Bound
1	2	26.850*	1.915	.000	21.824	31.876
	3	13.267*	1.113	.000	10.346	16.187
2	1	-26.850*	1.915	.000	-31.876	-21.824
	3	-13.583*	1.980	.000	-18.781	-8.386
3	1	-13.267*	1.113	.000	-16.187	-10.346
	2	13.583*	1.980	.000	8.386	18.781

Based on estimated marginal means

*. The mean difference is significant at the .05 level.

a. Adjustment for multiple comparisons: Bonferroni.

الخرج 15.11

وكما رأينا سابقاً فإنه يمكننا استخدام قيم المتوسط (التي طلبناها في الفقرة 4.8.11) لتحديد طبيعة هذا التفاعل (يجب أن يكون هذا الجدول تحت المقارنات الثنائية للمتحول imagery. وهو موضح في الخرج 16.11). إن جدول قيم المتوسط في الخرج 16.11 هو نفس جدول الإحصائيات الوصفية الأولية في الخرج 9.11 باستثناء أنه يعرض قيم الأخطاء المعيارية بدلاً من الانحرافات المعيارية.

Estimates

Measure: MEASURE_1

drink	imagery	Mean	Std. Error	95% Confidence Interval	
				Lower Bound	Upper Bound
1	1	21.050	2.909	14.962	27.138
	2	4.450	3.869	-3.648	12.548
	3	10.000	2.302	5.181	14.819
2	1	25.350	1.507	22.197	28.503
	2	-12.000	1.382	-14.893	-9.107
	3	11.650	1.396	8.728	14.572
3	1	17.400	1.582	14.089	20.711
	2	-9.200	1.521	-12.384	-6.016
	3	2.350	1.529	-.851	5.551

الخرج 16.11

تُستخدم قيم المتوسط في الخرج 16.11 لرسم المخطط الذي طلبناه في الفقرة 3.8.11، ويفيد هذا المخطط في تفسير التفاعل. يعرض الشكل 14.11 مخطط التفاعل (تم تعديله بشكل طفيف ليبدو أجمل)، ونبحث فيه عن الخطوط غير المتوازية. يبين مخطط التفاعل أن نمط الاستجابة عبر أنواع المشروب متشابه في حالتي استخدام الصورة الإيجابية والصورة الحيادية. لقد كان التقييم إيجابيا

للبيرة وارتفع قليلاً من أجل النبيذ ثم عاد وانخفض قليلاً من أجل الماء. يدل وجود الخط الممثل للصورة الإيجابية عند قيم أعلى من الخط الممثل للصورة الحيادية على أن الصورة الإيجابية تسبب منح علامات أعلى من الصورة الحيادية وذلك من أجل جميع أنواع المشروب. يبين الخط السفلي (الذي يمثل الصورة السلبية) أثراً مختلفاً، فالعلامات كانت أقل من أجل النبيذ والماء ولكنها ليست كذلك من أجل البيرة. لذلك فإن للصورة السلبية الأثر المرغوب على الموقف تجاه النبيذ والماء، ولكن لسبب ما فإن الموقف تجاه البيرة يبقى حيادياً. ولذلك فإن التفاعل يعكس حقيقة أن للصورة السلبية أثراً مختلفاً عن آثار كل من الصورة الإيجابية والحيادية (لأنها تخفض العلامات بدلاً من أن تزيدها). وهذا التفاعل متوافق تماماً مع التوقعات التجريبية. للتحقق من تفسير أثر التفاعل علينا العودة إلى المقارنات المطلوبة في الفقرة 2.8.11.

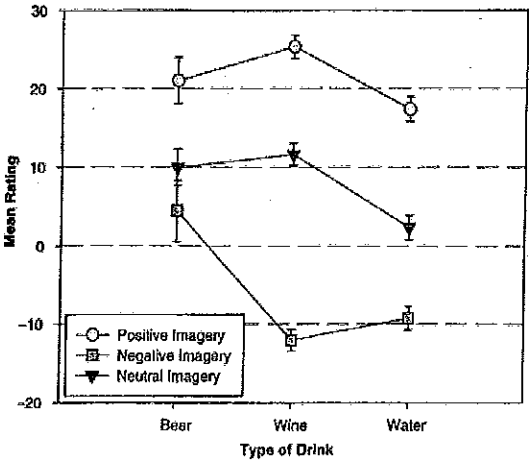

الشكل 14.11 مخطط التفاعل لبيانات Attitude.sav

5.9.11 المقارنات لمتحولات القياسات المكررة

طلبنا في الفقرة 2.8.11 مقارنات بسيطة للمتحول drink (حيث يكون الماء هو الفئة المرجعية) وللمتحول imagery (حيث تكون الصورة الحيادية هي الفئة المرجعية). يعرض الخرج 17.11 النتائج الملخصة لهذه المقارنات. تم تقسيم الجدول إلى الآثار الرئيسية والتفاعلات، وتقسيم كل أثر إلى مكونات المقارنة. فمن أجل الأثر الرئيسي للمتحول drink، تقارن المقارنة الأولى المستوى الأول (البيرة) مع الفئة المرجعية (الماء). ويمكنك العودة إلى الخرج 9.11 لمعرفة المستويات. إن النتيجة ذات دلالة $F(1,19)=6.22, p<0.05$ وهذا يتعارض مع ما وجدناه باستخدام اختبارات post hoc (انظر الخرج 13.11). تقارن المقارنة التالية المستوى الثاني (النبيذ) مع الفئة المرجعية (الماء) وتؤكد الفرق المهم الذي عثرت عليه اختبارات post hoc, $F(1,19)=18.61, p<0.001$. ومن أجل الأثر الرئيسي للمتحول imagery فإن المقارنة الأولى تقارن المستوى الأول (الصورة

الإيجابية) مع الفئة المرجعية (الصورة الحيادية) وتؤكد الفرق المهم الذي عثرت عليه اختبارات F(1,19)=142.19, p<0.001, post hoc. كما تؤكد المقارنة الثانية الفرق المهم بين الصورة السلبية و الصورة الحيادية، F(1,19)=47.07, p<0.001. وجميع هذه المقارنات جيدة ولكنها تخبرنا عما نعرفه سابقاً فقط (على الرغم من زيادة القدرة الإحصائية المبينة بقيم الدلالة الأكثر ارتفاعاً). تكتسب هذه المقارنات أهمية أكبر عند النظر إلى حد التفاعل.

Tests of Within-Sbjects Contrasts

Measure: MEASURE_1

Source	drink	imagery	Type III Sum of Squares	df	Mean Square	F	Sig.
drink	Level 1 vs. Level 3		1383.339	1	1383.339	6.218	.022
	Level 2 vs. Level 3		464.006	1	464.006	18.613	.000
Error(drink)	Level 1 vs. Level 3		4226.772	19	222.462		
	Level 2 vs. Level 3		473.661	19	24.930		
Imagery		Level 1 vs. Level 3	3520.089	1	3520.089	142.194	.000
		Level 2 vs. Level 3	3690.139	1	3690.139	47.070	.000
Error(Imagery)		Level 1 vs. Level 3	470.356	19	24.756		
		Level 2 vs. Level 3	1489.528	19	78.396		
drink * Imagery	Level 1 vs. Level 3	Level 1 vs. Level 3	320.000	1	320.000	1.576	.225
		Level 2 vs. Level 3	720.000	1	720.000	6.752	.018
	Level 2 vs. Level 3	Level 1 vs. Level 3	36.450	1	36.450	.235	.633
		Level 2 vs. Level 3	2928.200	1	2928.200	26.906	.000
Error(drink*Imagery)	Level 1 vs. Level 3	Level 1 vs. Level 3	3858.000	19	203.053		
		Level 2 vs. Level 3	2026.000	19	106.632		
	Level 2 vs. Level 3	Level 1 vs. Level 3	2948.550	19	155.082		
		Level 2 vs. Level 3	2067.800	19	108.832		

الخرج 17.11

1.5.9.11 البيرة مقابل الماء والصورة الإيجابية مقابل الحيادية

يظهر حد التفاعل الأول عند مقارنة المستوى الأول للمتحول drink (البيرة) مع المستوى الثالث (الماء) وذلك عندما تتم مقارنة المستوى الأول للمتحول imagery (الصورة الإيجابية) مع المستوى الثالث (الصورة الحيادية). إن هذه المقارنة بدون دلالة. تدلنا هذه النتيجة على أن التشابه المتزايد الموجود عند استخدام الصورة الإيجابية (مقارنة مع الصورة الحيادية) هو ذاته لكل من البيرة والماء. وباستخدام مفاهيم مخطط التفاعل (انظر الشكل 14.11) فهذا يعني أن المسافة بين الدائرة والمثلث في حالة البيرة تساوي تقريباً المسافة بين الدائرة والمثلث في حالة الماء. إذا طبعنا هذا الجزء من المخطط فمن السهل ملاحظة أن الخطين متوازيان تقريباً، مما يدل على عدم وجود أثر للتفاعل. يمكننا أن نستنتج أن تحسين العلامات العائد للصورة الإيجابية مقارنة مع الصورة الحيادية لايتأثر بنوع المشروب الذي يقوم المشتركون بتقييمه.

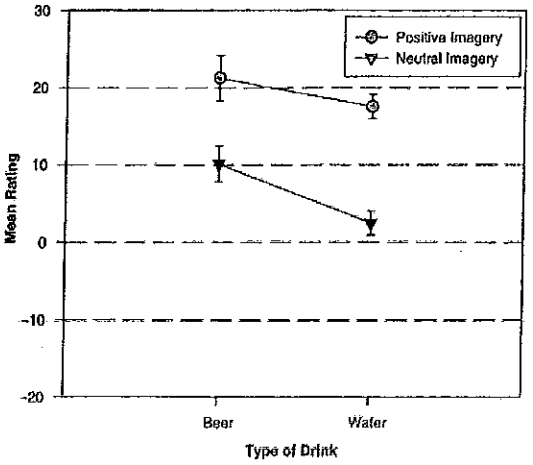

2.5.9.11 البيرة مقابل الماء والصورة السلبية مقابل الحيادية

يبحث حد التفاعل الثاني في مقارنة المستوى الأول للمتحول drink (البيرة) مع المستوى الثالث (الماء) عندما تتم مقارنة المستوى الثاني للمتحول imagery (الصورة السلبية) مع المستوى الثالث (الصورة الحيادية). وهذه المقارنة ذات دلالة $F(1,19)=6.75,\ p<0.05$. تدلنا هذه النتيجة على أن التشابه المتناقص الموجود عند استخدام الصورة السلبية (مقارنة مع الصورة الحيادية) مختلف عند استخدام البيرة مقارنة باستخدام الماء. وباستخدام مفاهيم مخطط التفاعل (الشكل 14.11) فإن ذلك يعني أن المسافة بين المربع والمثلث في حالة البيرة (فرق صغير) هي أصغر بكثير من المسافة بين المربع والمثلث في حالة الماء (فرق أكبر). ويمكننا أن نستنتج أن التناقص في العلامات العائد للصورة السلبية (مقارنة مع الحيادية) الذي يحصل عند استخدام البيرة في الإعلان هو أصغر من التناقص عند استخدام الماء.

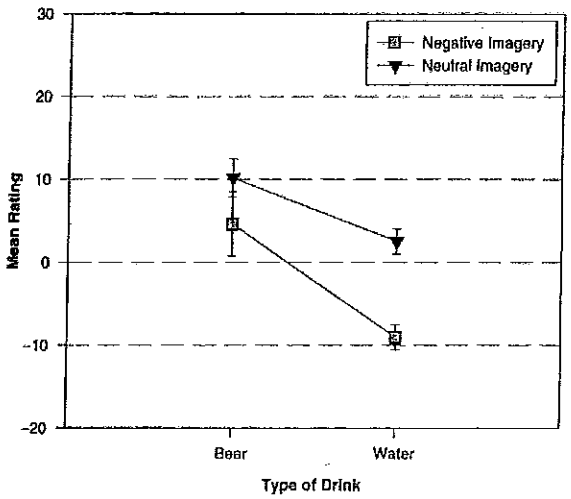

3.5.9.11 النبيذ مقابل الماء والصورة الإيجابية مقابل الحيادية

يبحث حد التفاعل الثالث في مقارنة المستوى الثاني للمتحول drink (النبيذ) مع المستوى الثالث (الماء) عندما تتم مقارنة المستوى الأول للمتحول imagery (الصورة الإيجابية) مع المستوى الثالث (الصورة الحيادية). وهذه المقارنة بدون دلالة، مما يدل على أن التشابه المتزايد الموجود عند استخدام الصورة الإيجابية (مقارنة مع الصورة الحيادية) متماثل لكل من النبيذ والماء. وباستخدام مفاهيم مخطط التفاعل (الشكل 14.11) فإن ذلك يعني أن المسافة بين الدائرة والمثلث في حالة النبيذ تساوي تقريباً المسافة بين الدائرة والمثلث في حالة الماء. إذا طبعنا هذا الجزء من المخطط فمن السهل ملاحظة أن الخطين متوازيان، مما يدل على عدم وجود أثر للتفاعل. يمكننا أن نستنتج أن تحسين العلامات العائد للصورة الإيجابية مقارنة مع الصورة الحيادية لا يتأثر بنوع المشروب الذي يقوم المشتركون بتقييمه.

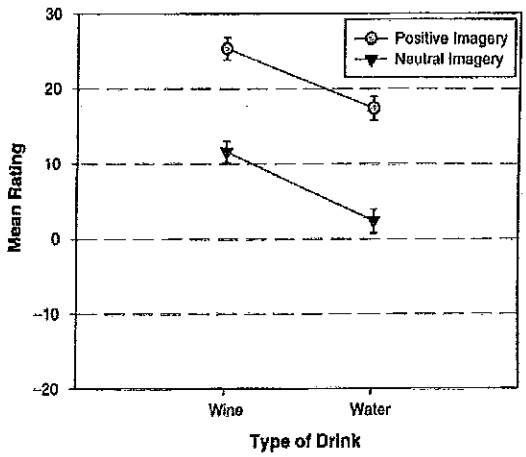

4.5.9.11 النبيذ مقابل الماء والصورة السلبية مقابل الحيادية

يبحث حد التفاعل الأخير في مقارنة المستوى الثاني للمتحول drink (النبيذ) مع المستوى الثالث (الماء) عندما تتم مقارنة المستوى الثاني للمتحول imagery (الصورة السلبية) مع المستوى الثالث (الصورة الحيادية). وهذه المقارنة ذات دلالة $F(1,19)=26.91,\ p<0.001$. تدلنا هذه النتيجة على أن التشابه المتناقص الموجود عند استخدام الصورة السلبية (مقارنة مع الصورة الحيادية) مختلف عند استخدام النبيذ مقارنة مع الماء. وباستخدام مفاهيم مخطط التفاعل (الشكل 14.11) فإن ذلك يعني أن المسافة بين المربع والمثلث في حالة النبيذ (فرق كبير) هي أكبر بكثير من المسافة بين المربع والمثلث في حالة الماء (فرق أصغر). ويمكننا أن نستنتج أن التناقص في العلامات العائد للصورة السلبية (مقارنة مع الحيادية) هو أكبر بكثير عند الإعلان عن النبيذ منه عند الإعلان عن الماء.

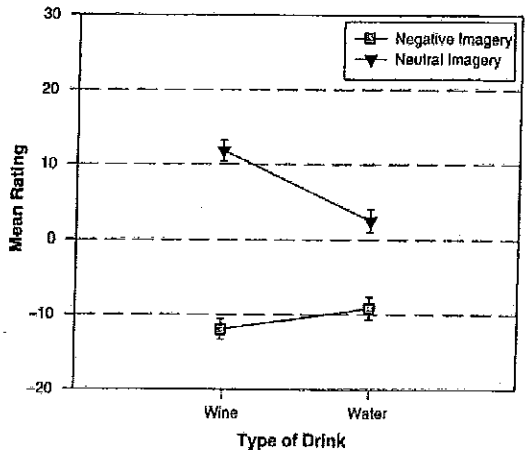

5.5.9.11 محدودية هذه المقارنات

لا تخبرنا هذه المقارنات بأي شيء عن الفروق بين حالتي البيرة والنبيذ (أو حالتي الصورة الإيجابية والسلبية) ويجب تنفيذ مقارنات مختلفة لإيجاد المزيد من النتائج. على كل حال، من الواضح أن الصور الإيجابية (مقارنة مع الحيادية) تزيد التشابه من أجل المنتجات بشكل أكبر أو أقل وذلك بغض النظر عن المنتج، وأن للصور السلبية أثراً أكبر على النبيذ وأثراً أصغر على البيرة. وهذه الفروق غير متوقعة. على الرغم مما يبدو أنه قضاء وقت طويل في تفسير التحليل بهذا العمق، فمن المفضل إتباع هذه الطريقة المنهجية إذا أردت أن تفهم الآثار التي حصلت عليها بشكل صحيح. إن تفسير التفاعلات معقد جداً لذلك لا تثبط عزيمتك عندما تجد ذلك صعباً. حاول أن تكون دقيقاً واعمل على تقسيم كل من الآثار قدر المستطاع باستخدام المقارنات.

أفكار مفيدة

- يقارن ANOVA ثنائي الاتجاه للقياسات المكررة عدة قيم لمتوسط عند وجود متحولين مستقلين، واستخدام نفس المشتركين في جميع الحالات التجريبية.
- اختبر فرضية الكروية عندما تكون هناك ثلاث حالات أو أكثر من القياسات المكررة. يتم اختبار الكروية باستخدام اختبار Mauchly. ابحث في الجدول الخاص بهذا الاختبار عن قيمة الدلالة في العمود المسمى .Sig، فإذا كانت قيمة الدلالة أصغر من 0.05 فإن فرضية الكروية غير محققة. أما إذا كانت قيمة الدلالة أكبر من 0.05 فإن فرضية الكروية محققة. يجب اختبار هذه الفرضية من أجل جميع الآثار (في حالة ANOVA ثنائي الاتجاه، يجب اختبار فرضية الكروية من أجل كلا المتحولين ومن أجل حد التفاعل).
- يعرض الجدول المسمى Tests of within-Subjects Effects النتائج الأساسية لـ ANOVA . في ANOVA ثنائي الاتجاه لدينا ثلاثة آثار: أثر رئيسي لكل متحول مستقل، والتفاعل بين المتحولين المستقلين. من أجل كل أثر، إذا كان فرضية الكروية محققة فإننا

ننظر إلى الصف المسمى Sphericity Assumed. أما إذا تم خرق فرضية الكروية فإننا ننظر إلى الصف المسمى Greenhouse-Geisser (كما يمكنك النظر إلى Huynh-Feldt، ولكن إذا قرأت هذا الفصل فإنك تدرك المزايا النسبية لكل من الإجرائيتين). بعد اختيار الصف المناسب نبحث عن قيمة الدلالة في العمود المسمى .Sig فإذا كانت قيمة الدلالة أصغر من 0.05 فإن متوسطات المجموعات مختلفة بشكل كبير.

- وزع الآثار الرئيسية وحدود التفاعل باستخدام المقارنات. تظهر هذه المقارنات في الجدول المسمى Tests of within-Subjects Contrasts، ابحث عن قيمة الدلالة في العمود المسمى .Sig لاكتشاف فيما إذا كانت المقارنات ذات دلالة (ويتحقق ذلك عندما تكون قيمة الدلالة أقل من 0.05).

10.11 حجم الأثر من أجل ANOVA العاملي للقياسات المكررة

قلنا سابقاً أن حجم الأثر يكون أكثر فائدة عندما يصف أثراً مركّزاً، لذلك ننصح بحساب حجم الأثر للمقارنات عند التعامل مع تصميم عاملي (ومن أجل أي آثار رئيسية تقارن مجموعتين فقط). يعرض الخرج 17.11 القيم لعدة مقارنات ولجميعها درجة حرية واحدة للنموذج (فهي تمثل مقارنة مركزة وقابلة للتفسير) و 19 درجة حرية للبواقي. يمكننا أن نستخدم النسب F ونحولها إلى حجم أثر r وذلك باستخدام العلاقة التي استخدمناها سابقاً:

$$r = \sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}$$

من أجل المقارنتين المنفذتين على المتحول drink (الخرج 17.11) فإننا نحصل على:

$$r_{\text{Beer vs. Water}} = \sqrt{\frac{6.22}{6.22 + 19}} = 0.50$$

$$r_{\text{Wine vs. Water}} = \sqrt{\frac{18.61}{18.61 + 19}} = 0.70$$

وهكذا، تعطي كلتا المقارنتين أثراً ذا حجم كبير. ومن أجل المقارنتين المنفذتين على المتحول imagery (الخرج 17.11) فإننا نحصل على:

$$r_{\text{Positive vs. Neutral}} = \sqrt{\frac{142.19}{142.19 + 19}} = 0.94$$

$$r_{\text{Negative vs. Neutral}} = \sqrt{\frac{47.07}{47.07 + 19}} = 0.84$$

ومرة أخرى أعطت المقارنتان أثراً ذا حجم كبير. ومن أجل حدود التفاعل فهناك 4 مقارنات، ولكننا نحولها إلى r لأنها تملك درجة حرية واحدة للنموذج (الخرج 17.11):

$$r_{\text{Beer vs. Water, Positive vs. Neutral}} = \sqrt{\frac{1.58}{1.58+19}} = 0.28$$

$$r_{\text{Beer vs. Water, Negative vs. Neutral}} = \sqrt{\frac{6.75}{6.75+19}} = 0.51$$

$$r_{\text{Wine vs. Water, Positive vs. Neutral}} = \sqrt{\frac{0.24}{0.24+19}} = 0.11$$

$$r_{\text{Wine vs. Water, Negative vs. Neutral}} = \sqrt{\frac{26.91}{26.91+19}} = 0.77$$

وبما أن اثنين من الآثار كانا مهمين (البيرة مع الماء والصورة السلبية مع الحيادية، النبيذ مع الماء والصورة السلبية مع الحيادية) فقد أعطيا حجم أثر كبير، أما الأثران المتبقيان اللذان لم يكونا مهمين فقد أعطى أحدهما أثراً متوسط الحجم بينما أعطى الآخر أثراً صغير الحجم.

11.11 تقديم نتائج ANOVA العاملي للقياسات المكررة

يمكننا تقديم ANOVA العاملي للقياسات المكررة بنفس الطريقة المتبعة مع أي تحليل تباين آخر. تذكر أن لدينا 3 آثار ينبغي تقديمها، وقد تكون لهذه الآثار درجات حرية مختلفة. فمن أجل الآثار الرئيسية للمتحولين drink وimagery، نعلم أن فرضية الكروية غير محققة لذلك علينا تقديم درجات الحرية المصححة بتصحيح Greenhouse-Geisser. يمكننا أن نبدأ بتقديم خرق فرضية الكروية:

- ✓ يشير اختبار Mauchly إلى أنه تم خرق فرضية الكروية للآثار الرئيسية للمتحول drink، $\chi^2(2)=23.75$, $p<0.001$، وللمتحول imagery، $\chi^2(2)=7.42$, $p<0.05$. لذلك تم تصحيح درجات الحرية باستخدام تقديرات Greenhouse-Geisser للكروية ($\varepsilon=0.58$ للأثر الرئيسي للمتحول drink و$\varepsilon=0.75$ للأثر الرئيسي للمتحول imagery).

يمكننا بعد ذلك تقديم الآثار الثلاثة من هذا التحليل كما يلي:

- ✓ جميع الآثار ذات دلالة عند مستوى $p<0.05$. هناك أثر رئيسي مهم لنوع المشروب على علامات المشروب، $F(1.15,21.93)=5.11$. وتكشف المقارنات أن تقييم كل من البيرة، $F(1,19)=6.22$, $r=0.50$، والنبيذ $F(1,19)=18.61$, $r=0.70$ كانا أعلى بكثير من الماء.
- ✓ هناك أيضاً أثر رئيسي مهم لنوع الصورة على علامات المشروب، $F(1.50,28.40)=122.57$. وتكشف المقارنات أن العلامات بعد عرض الصور الإيجابية كانت أعلى من العلامات بعد عرض الصور الحيادية $F(1,19)=142.19$, $r=0.94$. وبالمقابل فإن العلامات بعد عرض الصور السلبية كانت أدنى من العلامات بعد عرض الصور الحيادية $F(1,19)=47.07$, $r=0.84$.
- ✓ هناك أيضاً أثر تفاعل مهم بين نوع المشروب ونوع الصورة المستخدمة، $F(4,76)=17.16$. وهذا يدل على أن للصورة آثاراً مختلفة على تقييم المشتركين وذلك تبعاً لنوع المشروب الذي يتم تقييمه. لتقسيم هذا التفاعل تم تنفيذ المقارنات لمقارنة جميع أنواع المشروب مع الفئة

المرجعية (الماء) ولمقارنة جميع أنواع الصور مع الفئة المرجعية (الصورة الحيادية). وقد كشفت هذه المقارنات عن تفاعلات مهمة عند مقارنة الصورة السلبية مع الصورة الحيادية من أجل مقارنة البيرة مع الماء، $F(1,19)=6.75$, $r=0.51$، ومقارنة النبيذ مع الماء، $F(1,19)=26.91$, $r=0.77$ وعند النظر إلى مخطط التفاعل، فإن هذه الآثار تعكس أن الصورة السلبية (مقارنة مع الحيادية) تخفض العلامات في حالة الماء أكثر مما تفعله من أجل البيرة، كما تخفض العلامات في حالة النبيذ أكثر مما تفعله من أجل الماء. وتكشف المقارنات المتبقية عن حد تفاعل غير مهم عند مقارنة الصورة الإيجابية مع الصورة الحيادية من أجل مقارنة البيرة مع الماء، $F(1,19)=1.58$, $r=0.28$، ومقارنة النبيذ مع الماء، $r=0.11$, $F(1,19)<1$. على كل حال، تقود هذه المقارنات إلى حجم أثر صغير ومتوسط.

12.11 ما الذي اكتشفناه حول الإحصاء؟

لقد ساعدنا هذا الفصل على المضي قدماً في تصاميم القياسات المكررة. الشيء الأول الذي تعلمناه هو وجود فرضية إضافية في تصاميم القياسات المكررة هي الكروية Sphericity. وأنه عند خرق هذه الفرضية يمكن معالجتها بسهولة. انتقلنا بعد ذلك إلى نظرية ANOVA للقياسات المكررة في حالة متحول مستقل وحيد. ومع أن ذلك غير ضروري فقد كان تمريناً مفيداً في برهان أنها مشابهة للتصميم المستقل (مع وجود بعض الخلافات). نفذنا بعد ذلك مثالاً في برنامج SPSS وانتقلنا لحساب أوميغا مربع. ثم انتقلنا إلى التصميم العاملي للقياسات المكررة وخاصة عند وجود متحولين مستقلين. وتعلمنا أنه كبقية التصاميم العاملية الأخرى علينا الاهتمام بحدود التفاعل. ولكننا اكتشفنا أيضاً بعض الطرق المفيدة لتقسيم هذه الحدود باستخدام المقارنات. يمكننا تركيب تصميم القياسات المكررة مع التصميم المستقل والحصول على تصميم مختلط، وهذا ما سنراه في الفصل القادم.

13.11 المصطلحات الأساسية التي اكتشفناها

التناظر المركب	(Compound symmetry)
تصحيح Greenhouse-Geisser	(Greenhouse-Geisser correction)
تصحيح Huynh-Feldt	(Huynh-Feldt correction)
تقدير الحد الأدنى	(Lower-Bound estimate)
اختبار Mauchly	(Mauchly's test)
تحليل التباين للقياسات المكررة	(Repeated-measures ANOVA)
الكروية	(Sphericity)

14.11 مهمات يجب تنفيذها

- **المهمة الأولى:** تخيل أننا نريد دراسة أثر الكحول على المتعة الجنسية (roving eye). لقد زودنا 20 رجلاً بنظارات متطورة جداً يمكنها تعقب حركات العين وتسجيل هذه الحركة مع الكائن الذي تتم مراقبته. وخلال 4 ليالي مختلفة تم إعطاء هؤلاء الأشخاص عدداً من أقداح البيرة بين 1 و4 في أحد النوادي الليلية. وتم في كل ليلة تسجيل عدد النساء التي تمت مراقبتهن من الرأس إلى القدمين. وللتحقق من هذا القياس تم جمع مقدار من لعاب الرجل عند نظره إلى المرأة. يحوي الملف RovingEye.sav هذه البيانات، حلل هذه البيانات باستخدام ANOVA وحيد الاتجاه.
- **المهمة الثانية:** درسنا في الفصل السابق الأثر beer-goggles ووجدنا أنه أقوى عند الرجال منه عند النساء، ويحدث بعد تناول قدحين من البيرة. تخيل أننا نريد بحث هذه النتيجة ومعرفة العوامل التي تؤثر على هذا الأثر. نعتقد أن الأثر beer-goggles يصبح أسوأ في النوادي الليلية التي تكون الإضاءة فيها خافتة. أخذنا عينة من 26 رجلاً (لأن الأثر أقوى عند الرجال) وأعطيناهم جرعات مختلفة من الكحول خلال 4 أسابيع مختلفة (0 و2 و4 و6 أقداح من البيرة). وبذلك يكون المتحول المستقل الأول هو استهلاك الكحول وله 4 مستويات. وفي كل أسبوع كنا نطلب من المشتركين اختيار شريك في نادي ذو إضاءة خافتة ثم اختيار شريك آخر في نادي مصمم خصيصاً إضاءته ساطعة. وبذلك يكون المتحول المستقل الثاني هو إضاءة النادي وله مستويان. النتيجة المقاسة هي جاذبية الشريك التي تقوم لجنة خاصة مستقلة بتقييمها. لقد شارك جميع المشتركين في جميع المستويات لمتحول استهلاك الكحول، واختيار الشركاء في كلا الناديين. يحوي الملف BeerGoggleLighting.sav البيانات لهذه المهمة، حلل هذه البيانات باستخدام ANOVA ثنائي الاتجاه للقياسات المكررة.
- **المهمة الثالثة:** باستخدام المعلومات في المربع 1.11، عدّل البرنامج النصي في الملف SimpleEffectsAttitude.sps ليبحث أثر المتحول drink على المستويات المختلفة للمتحول imagery.

يحوي الملف Answers(Chapter 11).pdf الإجابات على هذه المهمات.

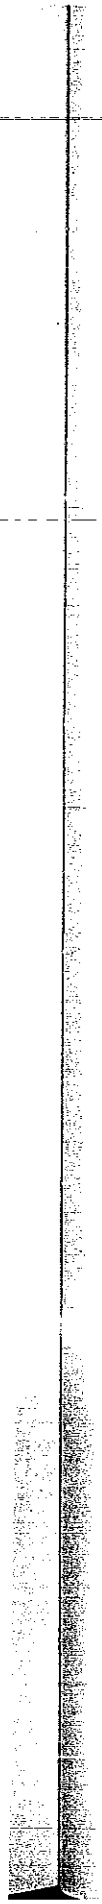

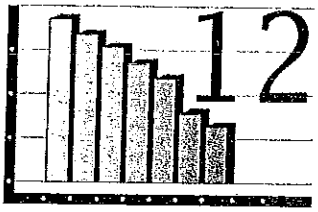

تصميم ANOVA المختلط (GLM5)

1.12 ماذا يخبرنا هذا الفصل؟

التصميم الأخير الذي سنتحدث عنه هو تصميم يحوي خليطاً من المتحولات بين المجموعات ومتحولات القياسات المكررة، إنه تصميم مختلط (Mixed design). من الواضح أننا نحتاج لمتحولين مستقلين على الأقل ليكون هذا النوع من التصميم ممكناً، ولكن هناك سيناريوهات أكثر تعقيداً (متحولين اثنين بين المجموعات ومتحول واحد للقياسات المكررة، أو متحول واحد بين المجموعات ومتحولَي قياسات مكررة، أو متحولَين من كل نوع). يسمح برنامج SPSS باختبار جميع التصاميم مهما كانت درجة تعقيدها. على كل حال، يكون تفسير حدود التفاعل صعباً جداً في حالة متحولين فقط، لذلك يمكنك أن تتخيل مدى الصعوبة إذا شمل 4 متحولات. وأفضل نصيحة يمكن تقديمها هي المحافظة على ثلاثة متحولات أو أقل لتتمكن من تفسير حدود التفاعل.

يقودنا هذا الفصل عبر مثال عن ANOVA المختلط. ولن تكون هناك دراسة نظرية لأننا نعتقد أننا قدمنا ما فيه الكفاية لتكون لديك فكرة جيدة عما سنفعله. لذلك سنقوم بتنفيذ المثال في برنامج SPSS وتفسير الخرج. وخلال هذه العملية ستتمكن من تطوير فهمك لحدود التفاعل وكيفية تقسيمها باستخدام المقارنات.

2.12 عما يبحث الإنسان في الشريك؟

يبدو أن عدداً كبيراً من المجلات يشكو طوال الوقت من الأمور التي يريدها الرجال والنساء من علاقاتهم. السؤال الكبير الذي نريد معرفة إجابته هو: ما هو أكثر أهمية المظهر (Looks) أم الشخصية (Personality)؟ تخيل أننا نريد وضع ذلك تحت الاختبار. نبتكر خطة ماكرة لإعداد ليلة مواعدة سريعة. ويعلم عدد قليل من المدعوين أننا سنطلب من بعض الأصدقاء أن يقوموا بأدوار الشركاء في هذه السهرة. وقد قبل 9 رجال و9 نساء القيام بذلك. وفي كل مجموعة من المجموعات هناك 3 أشخاص ذوي جاذبية (attractive) كبيرة ولكنهم مختلفوا الشخصية: أحدهم ذو كاريزما (جاذبية شخصية) عالية (High charisma) ويتمتع الثاني ببعض الكاريزما (Some charisma) أما الثالث فهو ممل جداً (Dull). في المجموعة الثانية هناك 3 أشخاص متوسطي الجاذبية ولكنهم مختلفوا الشخصية أيضاً: أحدهم ذو كاريزما عالية، ويتمتع الثاني ببعض الكاريزما، أما الثالث فهو ممل

جداً. أما المجموعة الأخيرة فقد ضمت 3 أشخاص لا يتمتعون بالجاذبية مطلقاً (Pig-ugly) ولكنهم مختلفوا الشخصية أيضاً: أحدهم ذو كاريزما عالية، ويتمتع الثاني ببعض الكاريزما، أما الثالث فهو ممل جداً. وكان المشتركون هم الأشخاص الذين تمت دعوتهم لهذه السهرة لاختيار شركاء لهم، وفي نهاية السهرة تمت المواعدة السريعة لجميع الأصدقاء (9 رجال و9 نساء) مع جميع المشتركين من الجنس الآخر. وبعد انقضاء 5 دقائق طلبنا من كل مشترك تقييم مدى رغبته في إقامة علاقة منتظمة مع هؤلاء الشركاء كنسبة مئوية (100% تعني "أدفع كل ما أملك للحصول على رقم هاتف هذا الشريك" و0% تعني "أدفع كل ما أملك للحصول على بطاقة طائرة تأخذني أبعد ما يمكن عن هذا الشخص"). وهكذا قام كل مشترك بتقييم 9 أشخاص مختلفين في الجاذبية والشخصية. لذلك لدينا متحولا قياسات مكررة هما looks (مع ثلاثة مستويات لمظهر الشخص: جذاب ومتوسط وقبيح) و charisma (مع ثلاثة مستويات أيضاً للكاريزما: عالي ومتوسط وممل). ويمكن أن يكون المشترك الذي قام بالتقييم ذكراً أو أنثى، لذلك يجب تضمين جنس المشترك gender (ذكر أو أنثى) وهذا هو المتحول بين المجموعات. يبين الجدول 1.12 البيانات لهذا المثال.

الشخصية	عالي الكاريزما			متوسط الكاريزما			ممل		
المظهر	جذاب	متوسط	قبيح	جذاب	متوسط	قبيح	جذاب	متوسط	قبيح
ذكر	86	84	67	88	69	50	97	48	47
	91	83	53	83	74	48	86	50	46
	89	88	48	99	70	48	90	45	48
	89	69	58	86	77	40	87	47	53
	80	81	57	88	71	50	82	50	45
	80	84	51	96	63	42	92	48	43
	89	85	61	87	79	44	86	50	45
	100	94	56	86	71	54	84	54	47
	90	74	54	92	71	58	78	38	45
	89	86	63	80	73	49	91	48	39
أنثى	89	91	93	88	65	54	55	48	52
	84	90	85	95	70	60	50	44	45
	99	100	89	80	79	53	51	48	44
	86	89	83	86	74	58	52	48	47
	89	87	80	83	74	43	58	50	48
	80	81	79	86	59	47	51	47	40
	82	92	85	81	66	47	50	45	47
	97	69	87	95	72	51	45	48	46
	95	92	90	98	64	53	54	53	45
	95	93	96	79	66	46	52	39	47

الجدول 1.12 البيانات من الملف looksorPeronality.sav

3.12 ANOVA المختلط في برنامج SPSS

1.3.12 التحليل الأساسي

لإدخال هذه البيانات في برنامج SPSS فإننا نستخدم نفس الإجرائيات المتبعة في ANOVA ثنائي الاتجاه للقياسات المكررة والتي تعاملنا معها في الفصل السابق. تذكر أن كل صف في محرر البيانات يمثل البيانات لمشترك واحد. إذا شارك المشترك في جميع الحالات التجريبية (وفي هذا المثال، التقى المشترك بجميع الأشخاص المختلفين من حيث الجاذبية وجميع الأشخاص المختلفين من حيث الشخصية) فإن كل حالة تجريبية ستقع ضمن عمود خاص بها في محرر البيانات. في هذا المثال لدينا 9 حالات تجريبية، لذلك علينا إدخال البيانات في 9 أعمدة مستقلة (بتنسيق مماثل للجدول 1.12). نقوم بإنشاء 9 متحولات في محرر البيانات ونعطيها الأسماء والتسميات المبينة فيما يلي:

اسم المتحول	التسمية	ملاحظة
att_high	Attractive + High charisma	جذاب + كاريزما عالية
av_high	Average look + High charisma	مظهر متوسط + كاريزما عالية
ug_high	Ugly + High charisma	قبيح + كاريزما عالية
att_some	Attractive + Some charisma	جذاب + بعض الكاريزما
av_some	Average look + Some charisma	مظهر متوسط + بعض الكاريزما
ug_some	Ugly + Some charisma	قبيح + بعض الكاريزما
att_none	Attractive + Dullard	جذاب + ممل
av_none	Average look + Dullard	مظهر متوسط + ممل
ug_none	Ugly+ Dullard	قبيح + ممل

بعد الانتهاء من تعريف المتحولات، يتم إدخال البيانات كما في الجدول 1.12. إذا لم ترغب بإدخال البيانات يدوياً أو صادفتك مشكلة ما في عملية الإدخال فيمكنك استخدام الملف LooksorPeronality.sav. علينا أولاً تعريف متحولات القياسات المكررة عن طريق مربع الحوار Define Factor(s) الذي يتم الوصول إليه عبر أمر القائمة Analyze ⇒ General Linear Model ⇒ Repeated Measures... وكما في حالة ANOVA ثنائي الاتجاه للقياسات المكررة، علينا أن نعطي أسماءً لمتحولات القياسات المكررة وتحديد عدد مستويات كل منها. في هذا المثال لدينا عاملان ضمن المشترك هما: looks (جذاب، متوسط، قبيح) وcharisma (عالي الكاريزما، بعض الكاريزما، ممل). نستبدل الكلمة factor1 في مربع الحوار Define Factor(s) بالكلمة looks، ونكتب الرقم 3 في الحيز المسمى Number of levels لتحديد عدد المستويات لهذا العامل. ننقر الزر Add لإضافة هذا العامل إلى لائحة متحولات القياسات المكررة، حيث يظهر في الحيز السفلي من مربع الحوار بالشكل looks(3). نكرر العملية السابقة لتعريف العامل charisma وتحديد عدد مستوياته (3) بحيث نحصل عليه في الحيز السفلي بالشكل charisma(3). يبين (الشكل 1.12) الشكل النهائي لمربع الحوار. ننقر الزر Define للانتقال إلى مربع الحوار الرئيسي.

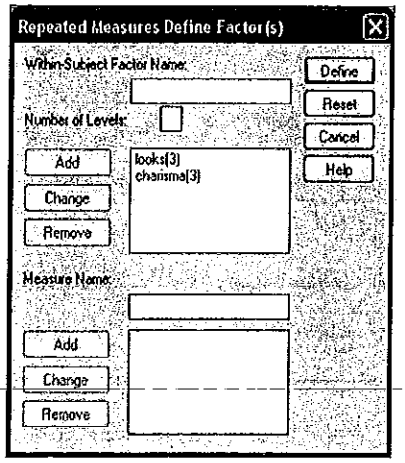

الشكل 1.12 مربع الحوار Define Factor(s) من أجل ANOVA العاملي للقياسات المكررة

يبين (الشكل 2.12) مربع الحوار الرئيسي من أجل ANOVA العاملي للقياسات المكررة. يعرض برنامج SPSS في السطر العلوي من مربع الحوار عبارة تدل على المتحولات ضمن المشتركين المستخدمة في المثال، وهما العاملان (looks, charisma). وتحت هذه العبارة هناك سلسلة من علامات الاستفهام تليها أرقام محصورة بين قوسين. تمثل الأرقام بين القوسين مستويات العاملين (المتحولان المستقلان). انظر الفصل السابق لمزيد من التفاصيل.

في هذا المثال لدينا متحولان مستقلان، وهناك رقمان بين القوسين. يمثل الرقم الأول مستويات العامل الأول المذكور في السطر العلوي من مربع الحوار الرئيسي (وفي هذه الحالة looks). بينما يمثل الرقم الثاني مستويات العامل الثاني (وهو charisma). وكما في الحالات الأخرى من ANOVA للقياسات المكررة والتي صادفناها سابقاً، ينبغي علينا استبدال علامات الاستفهام بالمتحولات الموجودة في القسم الأيسر من مربع الحوار. في حالة القياسات المكررة ليس هناك مخطط ترميز لذلك علينا تحديد الحالة التي ينبغي تعيينها لكل مستوى في هذه المرحلة (يمكنك العودة إلى الفصل السابق لمعرفة المزيد عن هذا الموضوع). ولهذا السبب فمن الضروري أن نفكر ملياً بنوع المقارنات التي نرغب باستخدامها وذلك قبل إدخال البيانات في مربع الحوار الرئيسي. إذا نظرنا إلى المتحول الأول في هذا المثال looks نجد أنه يملك ثلاثة مستويات (جذاب، متوسط، قبيح). من البديهي أن نقارن الحالتين جذاب وقبيح مع الحالة متوسط، لأن الشخص متوسط الجاذبية يمثل القاعدة أو المستوى الطبيعي (وليس من الخطأ مقارنة جذاب ومتوسط مع الحالة قبيح). يمكن تنفيذ هذه المقارنة بتحديد مقارنة بسيطة (انظر الجدول 6.8) بشرط أن يتم ترميز المستوى متوسط ليكون الفئة الأولى أو الأخيرة. لنفكر الآن بالعامل الثاني charisma الذي يملك ثلاثة مستويات أيضاً (عالي الكاريزما، بعض الكاريزما، ممل). يمثل المستوى بعض الكاريزما القاعدة أو المستوى الطبيعي، ولذلك يمكننا استخدام هذا المستوى كفئة مرجعية تتم مقارنة المستويات الأخرى معها. لذلك

يمكننا تنفيذ مقارنة بسيطة تتم فيها مقارنة جميع المستويات مع المستوى بعض الكاريزما، ولهذا يتم إدخال هذه الفئة المرجعية كفئة أولى أو أخيرة.

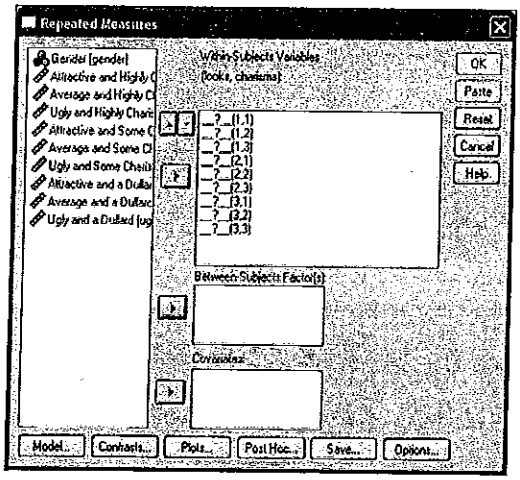

الشكل 2.12 مربع الحوار الرئيسي من أجل ANOVA العاملي للقياسات المكررة

اعتماداً على ما تمت مناقشته حول استخدام المقارنات، فمن المفيد وضع الفئة متوسط average في المستوى الثالث للعامل looks، ووضع الفئة بعض الكاريزما Some charisma في المستوى الثالث للعامل charisma. أما بقية المستويات فيمكن تحديدها بشكل اختياري. لقد اخترنا المستوى جذاب attractive ليكون المستوى الأول، والمستوى قبيح ugly ليكون المستوى الثاني للعامل looks. أما من أجل العامل charisma فقد اخترنا عالي الكاريزما high charisma ليكون المستوى الأول، وممل أو عديم الكاريزما none ليكون المستوى الثالث. ولذلك يكون ترتيب المتحولات الواجب إدخالها كما يلي:

att_high	_?_(1,1)
att_none	_?_(1,2)
att_some	_?_(1,3)
ug_high	_?_(2,1)
ug_none	_?_(2,2)
ug_some	_?_(2,3)
av_high	_?_(3,1)
av_none	_?_(3,2)
av_some	_?_(3,3)

لقد تعمدنا أن يكون ترتيب المتحولات مختلفاً عن ترتيب المتحولات في محرر البيانات، وذلك لتوضيح أنه يمكنك إدخال المتحولات بالترتيب الذي تريده. بعد ذلك تصبح الإجرائية مشابهة لتصاميم القياسات المكررة الأخرى. على كل حال، لدينا تصميم مختلط هنا، لذلك علينا تحديد

متحول بين المجموعات أيضاً. يتم ذلك باختيار المتحول gender من لائحة المتحولات ونقله إلى الحيز المسمى Between-Subjects Factor(s). يبين الشكل 3.12 مربع الحوار الرئيسي المكتمل.

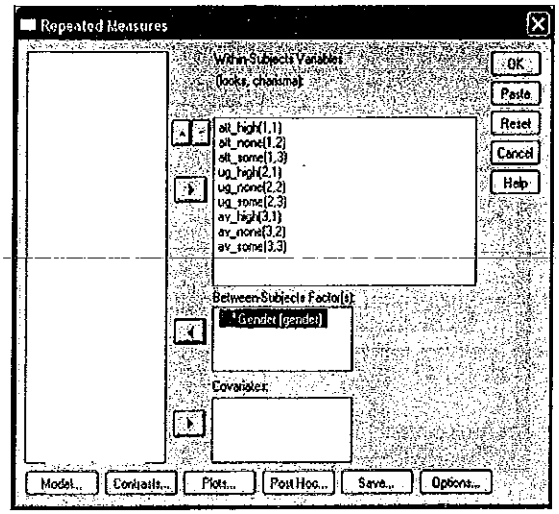

الشكل 3.12 مربع الحوار الرئيسي المكتمل من أجل ANOVA المختلط

2.3.12 الخيارات الأخرى

بعد تنفيذ التحليل الأساسي، من المفيد مقارنة مستويات المتحولات المستقلة لتحديد المختلف فيما بينها. وكما رأينا سابقاً فلا توجد هناك وسيلة لإدخال رموز المقارنة (ما لم يتم استخدام القواعد) لذلك نعتمد على المقارنات القياسية المتوفرة (انظر الجدول 6.8). يبين الشكل 4.12 مربع الحوار لتنفيذ المقارنات ونحصل عليه بنقر الزر ...Contrasts في مربع الحوار الرئيسي. لقد استخدمنا مربع الحوار Contrasts في الفقرات 3.3.9 و 2.4.11 سابقاً لذلك نكتفي بالقول أننا نريد استخدام مقارنة بسيطة Simple لكل من المتحولات المستقلة. بالنسبة للمتحولين المستقلين، فقد أدخلنا المتحولات بحيث تكون الفئة المرجعية هي الأخيرة، لذلك لا نغير الخيار المحدد. بعد الانتهاء من تعريف المقارنات ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

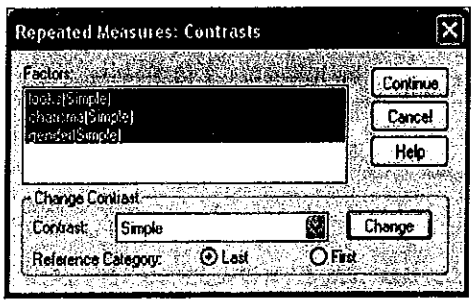

الشكل 4.12 مربع الحوار Contrasts

للمتحول gender مستويان فقط (ذكر وأنثى) لذلك لانحتاج لتحديد مقارنات لهذا المتحول. إن إضافة عامل بين المجموعات يعني أنه يمكننا تحديد اختبارات post hoc لهذا المتحول وذلك بنقر الزر Post Hoc... يمكن استخدام مربع الحوار post hoc test (انظر الفقرة 2.3.8) بنفس الطريقة المشروحة سابقاً. على كل حال، لا نحتاج لاختبار post hoc لأن للمتحول gender مستويان فقط.

إن إضافة متحول آخر تجعل من الضروري اختيار مخطط مختلف عن المخطط للمثال في الفصل السابق. انقر الزر Plots... لفتح مربع الحوار المبين في الشكل 5.12. نضع المتحول looks في الحيز المسمى Horizontal Axis ليكون المحور الأفقي والمتحول charisma في الحيز المسمى Separate Line، والمتحول gender في الحيز المسمى Separate Plots. انقر بعد ذلك الزر Add لإضافة المخطط المعرَّف إلى لائحة المخططات. عندما نطلب من برنامج SPSS أن يرسم المخطط looks×charisma×gender فإننا نحصل على مخطط التفاعل بين looks وcharisma وفي نسخة منفصلة من هذا المخطط فإننا نحصل على المشتركين الذكور والإناث.

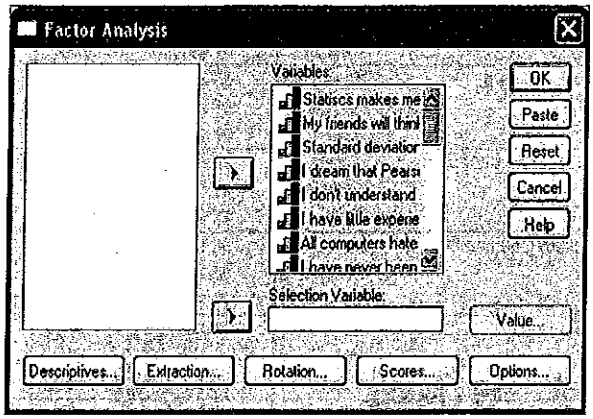

الشكل 5.12 مربع الحوار Plots من أجل ANOVA ثلاثي الاتجاه مختلط

أما بالنسبة لبقية الخيارات فإننا نحدد نفس الخيارات المستخدمة في المثال السابق (انظر الفقرة 4.8.11). حيث نختار المتوسطات الهامشية المقدّرة لجميع الآثار (لأن هذه القيم تساعدنا في فهم الآثار ذات الدلالة)، و لم نطلب مجالات الثقة لهذه الآثار لأننا درسنا هذا الجزء من الخرج بالتفصيل سابقاً. عند الانتهاء من تحديد الخيارات المناسبة ننقر الزر OK لتنفيذ التحليل.

4.12 الخرج من أجل ANOVA العاملي المختلط: التحليل الأساسي

يعرض الخرج 1.12 الخرج الأولي الذي يحوي جدولاً يعرض متحولات القياسات المكررة والمستويات التي تمثلها لكل متحول مستقل. أما الجدول الثاني فيحوي الإحصائيات الوصفية (قيم المتوسط والانحراف المعياري) لكل من الحالات التسع مقسماً وفق جنس المشترك (ذكر أم أنثى).

إن الإحصائيات الوصفية مفيدة لأنها تبين نمط المتوسطات عبر جميع الحالات التجريبية (لذلك نستخدم هذه المتوسطات للحصول على مخططات للتفاعل ثلاثي الاتجاه).

Within-Sbjects Factors

Measure: MEASURE_1

looks	charisma	Dependent Variable
1	1	att_high
	2	att_none
	3	att_some
2	1	ug_high
	2	ug_none
	3	ug_some
3	1	av_high
	2	av_none
	3	av_some

Descriptive Statistics

	Gender	Mean	Std. Deviation	N
Attractive and Highly Charismatic	Male	88.30	5.697	10
	Female	89.60	6.637	10
	Total	88.95	6.057	20
Attractive and a Dullard	Male	87.30	5.438	10
	Female	51.80	3.458	10
	Total	69.55	18.743	20
Attractive and Some Charisma	Male	88.50	5.740	10
	Female	87.10	6.806	10
	Total	87.80	6.170	20
Ugly and Highly Charismatic	Male	56.80	5.731	10
	Female	86.70	5.438	10
	Total	71.75	16.274	20
Ugly and a Dullard	Male	45.80	3.584	10
	Female	46.10	3.071	10
	Total	45.95	3.252	20
Ugly and Some Charisma	Male	48.30	5.376	10
	Female	61.20	6.463	10
	Total	48.75	5.476	20
Average and Highly Charismatic	Male	82.80	7.005	10
	Female	88.40	8.329	10
	Total	85.60	8.022	20
Average and a Dullard	Male	47.80	4.185	10
	Female	47.00	3.742	10
	Total	47.40	3.885	20
Average and Some Charisma	Male	71.80	4.417	10
	Female	68.90	5.953	10
	Total	70.35	5.314	20

الخرج 1.12

يعرض الخرج 2.12 نتائج اختبار Mauchly للكروية لكل من الآثار الثلاثة للقياسات المكررة في النموذج. لم يخرق أي من هذه الآثار فرضية الكروية لأن جميع القيم في العمود .Sig هي أكبر من 0.05، لذلك يمكن أن نعتبر الكروية عند النظر إلى الإحصائيات F.

Mauchly's Test of Sphericity[b]

Measure: MEASURE_1

Within Subjects Effect	Mauchly's W	Approx. Chi-Square	df	Sig.	Epsilon[a]		
					Greenhouse-Geisser	Huynh-Feldt	Lower-bound
looks	.960	.690	2	.708	.962	1.000	.500
charisma	.929	1.246	2	.536	.934	1.000	.500
looks * charisma	.813	8.025	9	.534	.799	1.000	.250

Tests the null hypothesis that the error covariance matrix of the orthonormalized transformed dependent variables is proportional to an identity matrix.

a. May be used to adjust the degrees of freedom for the averaged tests of significance. Corrected tests are displayed in the Tests of Within-Subjects Effects table.

b. Design: Intercept+gender
Within Subjects Design: looks+charisma+looks*charisma

الخرج 2.12

يعرض الخرج 3.12 الجدول الملخص لآثار القياسات المكررة في ANOVA مع قيم F المصححة. وكما في حالة ANOVA العاملي للقياسات المكررة فقد تم تقسيم الخرج إلى أقسام خاصة بكل أثر من الآثار في النموذج والخطأ المرتبط به. الفرق الوحيد هو أنه يحوي التفاعلات بين المتحول gender وآثار القياسات المكررة.

ننظر إلى قيم الدلالة في العمود .Sig فإذا كانت هذه القيم أصغر من 0.05 من أجل أثر معين فإن هذا الأثر ذو دلالة إحصائية. وبدراسة هذا الجدول من الأعلى فإننا نجد أثراً مهماً للعامل looks وهذا يعني أنه إذا أهملنا فيما إذا كان الشخص ذا كاريزما وفيما إذا كان تقييمه يتم من قبل امرأة أو رجل فإن جاذبية الشخص تؤثر بشكل كبير على العلامة التي يحصل عليها. إن التفاعل looks×gender ذو دلالة أيضاً، وهذا يعني أنه على الرغم من أن التقييم يتأثر بكون الشريك جذاباً أو متوسط الجاذبية أو قبيحاً، فإن طريقة تأثير الجاذبية على التقييم تختلف أيضاً بين الذكور والإناث الذين يعطون العلامات.

نجد بعد ذلك أثراً ذا دلالة للكاريزما، وهذا يعني أنه إذا أهملنا جاذبية الشريك، وجنس الشخص الذي يقوم بالتقييم فإن كاريزما الشخص تؤثر بشكل كبير على العلامات التي يحصل عليها. إن التفاعل charisma×gender ذو دلالة أيضاً، وهذا يعني أنه على الرغم من أن التقييم يتأثر بكون الشريك ذا كاريزما عالية أو متوسط الكاريزما أو مملاً، فإن طريقة تأثير الشخصية (الكاريزما) على التقييم تختلف أيضاً بين الذكور والإناث الذين يعطون العلامات.

نجد بعد ذلك تفاعلاً ذا دلالة بين العاملين looks و charisma، وهذا يعني أنه إذا أهملنا جنس الشخص الذي يقوم بالتقييم فإن شكل التقييم عبر المستويات المختلفة للجاذبية مختلف حسب شخصية الشريك (ذو كاريزما عالية، متوسط الكاريزما، ممل). ويمكن أن نقول ذلك بطريقة أخرى: إن شكل التقييم عبر المستويات المختلفة للشخصية مختلف حسب جاذبية الشريك (جذاب، متوسط، قبيح). ولزيادة التشويش والإرباك فإن التفاعل looks×charisma×gender ذو دلالة أيضاً، وهذا يعني أن التفاعل looks×charisma مختلف بشكل كبير بين المشتركين الذكور والإناث.

وسنقوم في الفقرات التالية بدراسة كل من هذه الآثار على حدا. ولكننا سنقوم أولاً بدراسة ما يحدث للأثر الرئيسي للمتحول gender.

Tests of Within-Sbjects Effects

Measure: MEASURE_1

Source		Type III Sum of Squares	df	Mean Square	F	Sig.
looks	Sphericity Assumed	20779.633	2	10389.817	423.733	.000
	Greenhouse-Geisser	20779.633	1.923	10803.275	423.733	.000
	Huynh-Feldt	20779.633	2.000	10389.817	423.733	.000
	Lower-bound	20779.633	1.000	20779.633	423.733	.000
looks * gender	Sphericity Assumed	3944.100	2	1972.050	80.427	.000
	Greenhouse-Geisser	3944.100	1.923	2050.527	80.427	.000
	Huynh-Feldt	3944.100	2.000	1972.050	80.427	.000
	Lower-bound	3944.100	1.000	3944.100	80.427	.000
Error(looks)	Sphericity Assumed	882.711	36	24.520		
	Greenhouse-Geisser	882.711	34.622	25.496		
	Huynh-Feldt	882.711	36.000	24.520		
	Lower-bound	882.711	18.000	49.040		
charisma	Sphericity Assumed	23233.600	2	11616.800	328.250	.000
	Greenhouse-Geisser	23233.600	1.868	12437.761	328.250	.000
	Huynh-Feldt	23233.600	2.000	11616.800	328.250	.000
	Lower-bound	23233.600	1.000	23233.600	328.250	.000
charisma * gender	Sphericity Assumed	4420.133	2	2210.067	62.449	.000
	Greenhouse-Geisser	4420.133	1.868	2366.252	62.449	.000
	Huynh-Feldt	4420.133	2.000	2210.067	62.449	.000
	Lower-bound	4420.133	1.000	4420.133	62.449	.000
Error(charisma)	Sphericity Assumed	1274.044	36	35.390		
	Greenhouse-Geisser	1274.044	33.624	37.891		
	Huynh-Feldt	1274.044	36.000	35.390		
	Lower-bound	1274.044	18.000	70.780		
looks * charisma	Sphericity Assumed	4055.267	4	1013.817	36.633	.000
	Greenhouse-Geisser	4055.267	3.197	1268.295	36.633	.000
	Huynh-Feldt	4055.267	4.000	1013.817	36.633	.000
	Lower-bound	4055.267	1.000	4055.267	36.633	.000
looks * charisma * gender	Sphericity Assumed	2669.667	4	667.417	24.116	.000
	Greenhouse-Geisser	2669.667	3.197	834.945	24.116	.000
	Huynh-Feldt	2669.667	4.000	667.417	24.116	.000
	Lower-bound	2669.667	1.000	2669.667	24.116	.000
Error(looks*charisma)	Sphericity Assumed	1992.622	72	27.675		
	Greenhouse-Geisser	1992.622	57.554	34.622		
	Huynh-Feldt	1992.622	72.000	27.675		
	Lower-bound	1992.622	18.000	110.701		

الخرج 3.12

1.4.12 أثر المتحول gender

يتم عرض الأثر الرئيسي للمتحول gender بشكل منفصل عن آثار القياسات المكررة وذلك في جدول يحمل التسمية Tests of Between-Subjects Effects. وقبل أن ننظر إلى هذا الجدول، من المهم التحقق من فرضية تجانس التباين باستخدام اختبار Levene (انظر الفقرة 6.3). كما يعطي

برنامج SPSS جدولاً يعرض اختبار Levene لكل من متحولات القياسات المكررة المعرفة في محرر البيانات، وعلينا أن ننظر إلى المتحولات التي لها قيم ذات دلالة. يعرض الخرج 4.12 كلا الجدولين. يشير الجدول الذي يعرض اختبار Levene إلى أن التباينات متجانسة لجميع مستويات متحولات القياسات المكررة (لأن جميع قيم الدلالة أكبر من 0.05). لو كانت إحدى القيم ذات دلالة لأصبحت دقة الاختبار F للمتحول gender موضع شك، ولتوجب علينا تحويل جميع البيانات للحصول على تجانس التباينات بين المجموعات (انظر الفصل 3). لحسن الحظ فإن تحويل البيانات في هذا المثال غير ضروري. يعرض الجدول الثاني الملخص للأثر الرئيسي للمتحول gender، ويبين أن هذا الأثر غير مهم (لأن قيمة الدلالة 0.946 وهي أعلى بكثير من المعيار القياسي 0.05).

Levene's Test of Equality of Error Variances[a]

	F	df1	df2	Sig.
Attractive and Highly Charismatic	1.131	1	18	.302
Attractive and a Dullard	1.949	1	18	.180
Attractive and Some Charisma	.599	1	18	.449
Ugly and Highly Charismatic	.005	1	18	.945
Ugly and a Dullard	.082	1	18	.778
Ugly and Some Charisma	.124	1	18	.729
Average and Highly Charismatic	.102	1	18	.753
Average and a Dullard	.004	1	18	.950
Average and Some Charisma	1.763	1	18	.201

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a. Design: Intercept+gender
Within Subjects Design: looks+charisma+looks*charisma

Tests of Between-Subjects Effects

Measure: MEASURE_1
Transformed Variable: Average

Source	Type III Sum of Squares	df	Mean Square	F	Sig.
Intercept	94027.756	1	94027.756	20036.900	.000
gender	.022	1	.022	.005	.946
Error	84.469	18	4.693		

الخرج 4.12

يمكننا القول بأن الأثر الرئيسي بدون دلالة (ns) ونكتب: $F(1,18)<1$, ns. ويشير هذا الأثر إلى أنه إذا أهملنا جميع المتحولات الأخرى، فإن تقييم المشتركين الذكور مماثل لتقييم المشتركات الإناث. إذا طلبنا من برنامج SPSS إظهار قيم المتوسط للأثر gender فإن علينا البحث عن جدول في القسم المسمى Estimated Marginal Means. يعرض الخرج 5.12 هذا الجدول لقيم المتوسط للأثر الرئيسي للمتحول gender مع الخطأ المعياري المرتبط بها. وقد تم رسم هذه المعلومات في الشكل 6.12. ومن الواضح أن علامات الذكور والإناث متماثلة بشكل عام.

1. Gender

Measure: MEASURE_1

Gender	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
Male	68.600	.685	67.161	70.039
Female	68.533	.685	67.094	69.973

الخرج 5.12

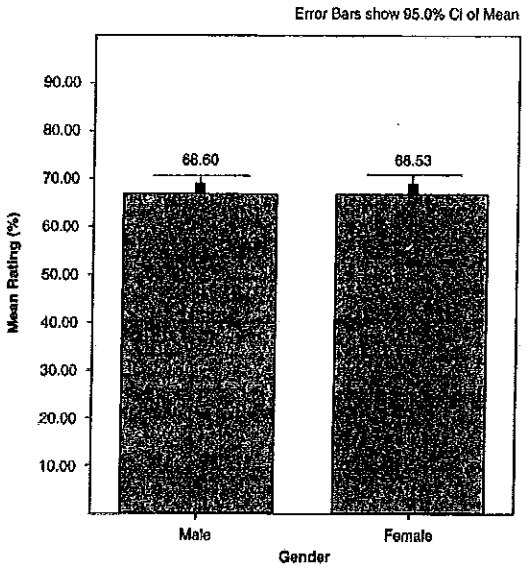

الشكل 6.12 مخطط قيم المتوسط للمتحول gender

2.4.12 أثر المتحول looks

لقد رأينا الأثر الرئيسي للمتحول looks في الخرج 3.12. وسنتعرف الآن على معنى هذا الأثر. يمكننا القول بأن هناك أثراً رئيسياً ذا دلالة للمتحول looks، $F(2,36)=423.73,\ p<0.001$. ويدلنا هذا الأثر على أنه إذا أهملنا جميع المتحولات الأخرى، فإن تقييم المستويات المختلفة للمتحول looks (جذاب، متوسط، قبيح) كان مختلفاً. إذا طلبنا إظهار قيم المتوسط لأثر المتحول looks فإننا نجد الجدول LOOKS في القسم المسمى Estimated Marginal Means. يعرض الخرج 6.12 هذا الجدول لقيم المتوسط للأثر الرئيسي للمتحول looks مع الخطأ المعياري المرتبط بها. تمت تسمية مستويات المتحول looks بالأرقام 1 و2 و3، وعليك أن تتذكر ترتيب إدخال المتحولات أو النظر إلى الجدول الملخص الذي يعطيه برنامج SPSS في بداية الخرج (الخرج 1.12). وهكذا نجد أن المستوى 1 يمثل الحالة جذاب، والمستوى 2 يمثل الحالة قبيح، والمستوى 3 يمثل الحالة متوسط.

2. looks

Measure: MEASURE_1

looks	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
1	82.100	.652	80.729	83.471
2	55.817	.651	54.449	57.184
3	67.783	.820	66.061	69.505

الخرج 6.12

ولتسهيل ذلك فقد تم رسم المعلومات السابقة على المخطط المبين في الشكل 7.12. يمكننا أن نرى أنه عند انخفاض الجاذبية، تنخفض قيم المتوسط أيضاً. لذلك يبدو أن الأثر الرئيسي يعكس تعبير الأشخاص الذين يقومون بعملية التقييم عن رغبتهم في الخروج أو إقامة علاقات مع الأشخاص الجذابين أكثر من رغبتهم في الأشخاص متوسطي الجاذبية أو عديمي الجاذبية. على كل حال، علينا النظر إلى بعض المقارنات لمعرفة ما يحدث بالضبط.

يعرض الخرج 7.12 المقارنات المطلوبة. وننظر حالياً إلى الصف المسمى LOOKS. تذكّر أننا قمنا بمقارنة بسيطة ولهذا حصلنا على مقارنة بين المستوى 1 والمستوى 3، ومقارنة بين المستوى 2 والمستوى 3، وذلك لأن الترتيب المعتمد لإدخال المتحولات يجعل المقارنة تتم بين جذاب ومتوسط (المستوى 1 مع المستوى 3) وبين قبيح ومتوسط (المستوى 2 مع المستوى 3). لننظر إلى قيم F لكل من هذه المقارنات وقيم الدلالة المرتبطة بها، وهذا يدلنا على أن أثر الجاذبية يمثل حقيقة أن الأشخاص ذوي الجاذبية حصلوا على علامات أعلى بكثير من علامات الأشخاص عديمي الجاذبية، $F(1,18)=160.07, p<0.001$.

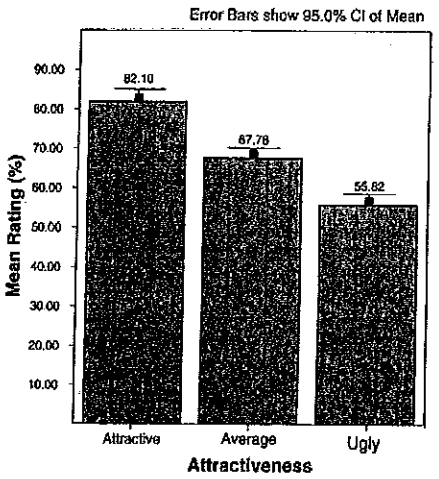

الشكل 7.12 مخطط قيم المتوسط للمتحول looks

Tests of Within-Sbjects Contrasts

Measure: MEASURE_1

Source	looks	charisma	Type III Sum of Squares	df	Mean Square	F	Sig.
looks	Level 1 vs. Level 3		4099.339	1	4099.339	226.986	.000
	Level 2 vs. Level 3		2884.022	1	2884.022	160.067	.000
looks * gender	Level 1 vs. Level 3		781.250	1	781.250	43.259	.000
	Level 2 vs. Level 3		540.800	1	540.800	30.225	.000
Error(looks)	Level 1 vs. Level 3		325.078	18	18.060		
	Level 2 vs. Level 3		322.067	18	17.893		
charisma		Level 1 vs. Level 3	3276.800	1	3276.800	109.937	.000
		Level 2 vs. Level 3	4500.000	1	4500.000	227.941	.000
charisma * gender		Level 1 vs. Level 3	810.689	1	810.689	27.199	.000
		Level 2 vs. Level 3	665.089	1	665.089	33.689	.000
Error(charisma)		Level 1 vs. Level 3	536.511	18	29.806		
		Level 2 vs. Level 3	355.356	18	19.742		
looks * charisma	Level 1 vs. Level 3	Level 1 vs. Level 3	3976.200	1	3976.200	21.944	.000
		Level 2 vs. Level 3	441.800	1	441.800	4.091	.058
	Level 2 vs. Level 3	Level 1 vs. Level 3	911.250	1	911.250	6.231	.022
		Level 2 vs. Level 3	7334.450	1	7334.450	88.598	.000
looks * charisma * gender	Level 1 vs. Level 3	Level 1 vs. Level 3	168.200	1	168.200	.928	.348
		Level 2 vs. Level 3	6552.200	1	6552.200	60.669	.000
	Level 2 vs. Level 3	Level 1 vs. Level 3	1711.250	1	1711.250	11.701	.003
		Level 2 vs. Level 3	110.450	1	110.450	1.334	.263
Error(looks*charisma)	Level 1 vs. Level 3	Level 1 vs. Level 3	3261.800	18	181.200		
		Level 2 vs. Level 3	1944.000	18	108.000		
	Level 2 vs. Level 3	Level 1 vs. Level 3	2632.500	18	146.250		
		Level 2 vs. Level 3	1490.100	18	82.783		

الخرج 7.12

3.4.12 أثر المتحول charisma

لقد رأينا الأثر الرئيسي للمتحول charisma في الخرج 3.12. ويمكننا القول بأن هناك أثراً رئيسياً ذا دلالة للمتحول charisma، $F(2,36)=328.25,\ p<0.001$. ويدلنا هذا الأثر على أنه إذا أهملنا جميع المتحولات الأخرى، فإن تقييم المستويات المختلفة للمتحول charisma (عالي، بعض، ممل) كان مختلفاً. يدلنا الجدول charisma الموجود في القسم Estimated Marginal Means (الخرج 8.12) على معنى هذا الأثر. لقد تمت تسمية مستويات المتحول charisma بالأرقام 1 و2 و3، حيث يدل المستوى 1 على الحالة عالي الكاريزما، والمستوى 2 على الحالة ممل، والمستوى 3 على الحالة بعض الكاريزما.

تم رسم المعلومات السابقة على المخطط المبين في الشكل 8.12. يمكننا أن نرى أنه عند انخفاض الكاريزما، تنخفض قيم المتوسط أيضاً. لذلك يبدو أن الأثر الرئيسي يعكس تعبير الأشخاص الذين يقومون بعملية التقييم عن رغبتهم في الخروج أو إقامة علاقات مع الأشخاص ذوي الكاريزما العالية أكثر من رغبتهم في الأشخاص ذوي بعض الكاريزما أو المملين.

3. charisma

Measure: MEASURE_1

charisma	Mean	Std. Error	95% Confidence Interval	
			Lower Bound	Upper Bound
1	82.100	1.010	79.978	84.222
2	54.300	.573	53.096	55.504
3	69.300	.732	67.763	70.837

الخرج 8.12

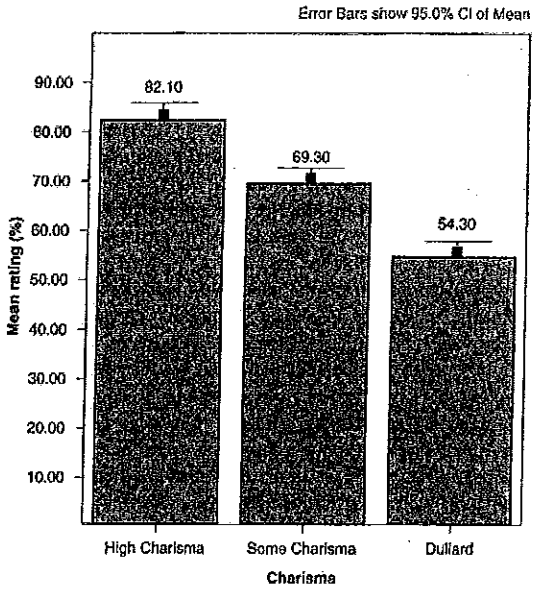

الشكل 8.12 مخطط قيم المتوسط للمتحول charisma

يعرض الخرج 7.12 المقارنات المطلوبة. وننظر حالياً إلى الصف المسمى CHARISMA ونتذكر أننا طلبنا مقارنات بسيطة. حصلنا على مقارنة تقارن المستوى 1 مع المستوى 3، وأخرى تقارن المستوى 2 مع المستوى 3. وطريقة تفسيرنا لهذه المقارنات يعتمد على ترتيب الإدخال لمتحولات القياسات المكررة. وفي هذا المثال تمثل المقارنة الأولى مقارنة عالي الكاريزما مع بعض الكاريزما (المستوى 1 مع المستوى 3)، وتمثل المقارنة الثانية مقارنة الممل مع بعض الكاريزما (المستوى 2 مع المستوى 3). تدلنا هذه المقارنات على أن أثر الكاريزما يمثل حقيقة أن الأشخاص ذوي الكاريزما العالية حصلوا على علامات أعلى بكثير من علامات الأشخاص ذوي بعض الكاريزما، $F(1,18)=109.94,\ p<0.001$، والأشخاص ذوي بعض الكاريزما حصلوا على علامات أعلى بكثير من علامات الأشخاص المملين، $F(1,18)=227.94,\ p<0.001$.

4.4.12 التفاعل بين المتحولين gender و looks

يدل الخرج 3.12 على أن المتحول gender يتفاعل بطريقة ما مع المتحول looks (جاذبية الشريك). ومن الجدول الملخص يمكننا القول أن هناك تفاعلاً مهماً بين جاذبية الشريك وجنس المشترك، $F(2,36)=80.43, p<0.001$. ويدل هذا الأثر على أن شكل العلامات للشركاء من ذوي الجاذبية المختلفة كان مختلفاً بين الذكور والإناث. يمكننا استخدام قيم المتوسط الهامشية المقدَّرة لتحديد طبيعة هذا التفاعل (أو يمكننا أن نطلب من برنامج SPSS أن يرسم مخطط التفاعل gender×looks باستخدام مربع الحوار المبين في الشكل 5.12). يبين الخرج 9.12 قيم المتوسط، ويبين الشكل 9.12 مخطط التفاعل لهذه النتائج. يبين مخطط التفاعل متوسط العلامات للذكور عند المستويات المختلفة للجاذبية (المتحول looks) وذلك بإهمال الشخصية (المتحول charisma) ويتم تمثيله بالدوائر، أما متوسط علامات الإناث فيتم تمثيله بالمربعات. يبين المخطط بوضوح أن علامات الذكور والإناث متماثلة جداً عند المستوى 2 (جاذبية متوسطة)، ولكن الرجال يعطون علامات أعلى من النساء للشركاء ذوي الجاذبية العالية (المستوى 1)، أما النساء فيعبرون عن رغبة في الخروج مع الرجال عديمي الجاذبية أكبر من رغبة الرجال. وبشكل عام يبدو أن هذا التفاعل يشير إلى أن اهتمام الرجال بمواعدة شخص ما يتأثر بالمظهر أكثر من تأثر النساء. ومع أن اهتمام الرجال والنساء ينخفض عند نقصان الجاذبية، فإن هذا الانخفاض عند الرجال أكثر حدة منه عند النساء. يمكن توضيح هذا التفاعل باستخدام المقارنات المحددة قبل التحليل.

1.4.4.12 التفاعل الأول من looks×gender: جذاب مقابل متوسط، ذكر مقابل أنثى

يقارن حد التفاعل الأول المستوى الأول للمتحول looks (جذاب) مع المستوى الثالث (متوسط)، مع مقارنة علامات الذكر والأنثى. إن هذه المقارنة عالية الدلالة، $F(1,18)=43.26, p<0.001$. وتدلنا هذه النتيجة على أن الاهتمام المتزايد بالشريك الجذاب مقارنة بالشريك ذو المظهر المتوسط موجود عند الرجال بصورة أكبر منه عند النساء. لذلك نجد في الشكل 9.12 أن ميل الخط الواصل بين الدوائر التي تمثل علامات الذكور (عند المستويين جذاب ومتوسط) أشد انحداراً من الخط الواصل بين المربعات التي تمثل علامات الإناث (عند المستويين جذاب ومتوسط). ويمكننا أن نستنتج أن تفضيل الشريك الجذاب على الشريك ذو المظهر المتوسط عند الرجال هو أكبر منه عند النساء.

4. Gender*looks

Measure: MEASURE_1

Gender	looks	Mean	Std. Error	95% Confidence Interval	
				Lower Bound	Upper Bound
Male	1	88.033	.923	86.095	89.972
	2	50.300	.921	48.366	52.234
	3	67.467	1.159	65.031	69.902
Female	1	76.167	.923	74.228	78.105
	2	61.333	.921	59.399	63.267
	3	68.100	1.159	65.665	70.535

الخرج 9.12

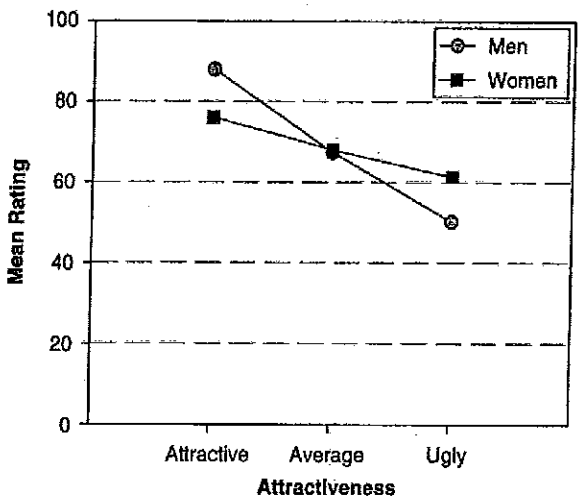

الشكل 9.12 مخطط التفاعل looks×gender

2.4.4.12 التفاعل الثاني من looks×gender: قبيح مقابل متوسط، ذكر مقابل أنثى

يقارن حد التفاعل الثاني المستوى الثاني للمتحول looks (قبيح) مع المستوى الثالث (متوسط)، مع مقارنة علامات الذكر والأنثى. إن هذه المقارنة عالية الدلالة، $F(1,18)=30.23,\ p<0.001$. وتدلنا هذه النتيجة على أن الاهتمام المتناقص بالشريك القبيح مقارنة بالشريك ذو المظهر المتوسط موجود عند الرجال بصورة أكبر منه عند النساء. لذلك نجد في الشكل 9.12 أن ميل الخط الواصل بين الدوائر التي تمثل علامات الذكور (عند المستويين قبيح ومتوسط) أشد انحداراً من الخط الواصل بين المربعات التي تمثل علامات الإناث (عند المستويين قبيح ومتوسط). ويمكننا أن نستنتج أن تفضيل الشريك ذو المظهر المتوسط على الشريك القبيح عند الرجال هو أكبر منه عند النساء.

5.4.12 التفاعل بين المتحولين gender و charisma

يدل الخرج 3.12 على أن المتحول gender يتفاعل بطريقة ما مع المتحول charisma (شخصية الشريك). ومن الجدول الملخص يمكننا القول أن هناك تفاعلاً مهماً بين شخصية الشريك وجنس الشريك، $F(2,36)=62.45,\ p<0.001$. ويدل هذا الأثر على أن شكل العلامات للشركاء من ذوي الشخصيات المختلفة كان مختلفاً بين الذكور والإناث. يمكننا استخدام قيم المتوسط الهامشية المقدَّرة لتحديد طبيعة هذا التفاعل (أو يمكننا أن نطلب من برنامج SPSS أن يرسم مخطط التفاعل charisma×gender باستخدام مربع الحوار المبين في الشكل 5.12). يبين الخرج 10.12 قيم المتوسط، ويبين الشكل 10.12 مخطط التفاعل لهذه النتائج. يبين مخطط التفاعل متوسط العلامات للذكور عند المستويات المختلفة للشخصية (المتحول charisma) وذلك بإهمال الجاذبية (المتحول looks) ويتم تمثيله بالدوائر، أما متوسط علامات الإناث فيتم تمثيله بالمربعات. يبين المخطط أن علامات الذكور والإناث متماثلة جداً عند القيمة الطبيعية للكاريزما (المستوى 2، بعض الكاريزما)، ولكن الرجال يُبدون اهتماماً أكبر من النساء بالأشخاص المملين، بينما تعبر النساء عن اهتمام أكبر من الرجال بالأشخاص ذوي الكاريزما العالية. وبشكل عام يبدو أن هذا التفاعل يشير إلى أن اهتمام النساء بمواعدة شخص ما يتأثر بالشخصية أكثر من تأثر الرجال. ومع أن اهتمام الرجال والنساء ينخفض عند نقصان الكاريزما، فإن هذا الانخفاض عند النساء أكثر حدة منه عند الرجال. يمكن توضيح هذا التفاعل باستخدام المقارنات المحددة قبل التحليل.

6. looks * charisma

Measure: MEASURE_1

Gender	charisma	Mean	Std. Error	95% Confidence Interval	
				Lower Bound	Upper Bound
Male	1	75.967	1.428	72.966	78.967
	2	60.300	.810	58.598	62.002
	3	69.533	1.035	67.360	71.707
Female	1	88.233	1.428	85.233	91.234
	2	48.300	.810	46.598	50.002
	3	69.067	1.035	66.893	71.240

الخرج 10.12

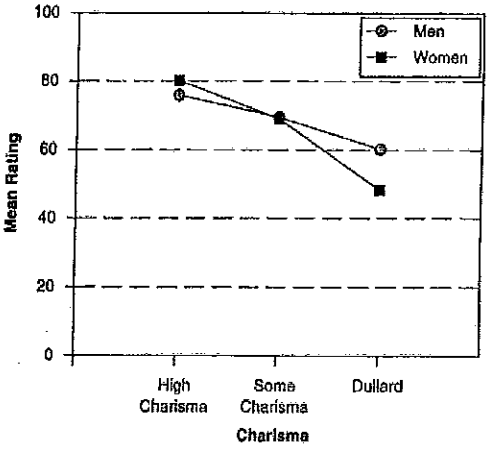

الشكل 10.12 مخطط التفاعل charisma×gender

1.5.4.12 التفاعل الأول من charisma×gender: عالي مقابل بعض الكاريزما، ذكر مقابل أنثى

يقارن حد التفاعل الأول المستوى الأول للمتحول charisma (عالي الكاريزما) مع المستوى الثالث (بعض الكاريزما)، مع مقارنة علامات الذكر والأنثى. إن هذه المقارنة عالية الدلالة، $F(1,18)=27.20, p<0.001$. وتدلنا هذه النتيجة على أن الاهتمام المتزايد بالشريك عالي الكاريزما مقارنة بالشريك متوسط الكاريزما موجود عند النساء بصورة أكبر منه عند الرجال. لذلك نجد في الشكل 10.12 أن ميل الخط الواصل بين المربعات التي تمثل علامات النساء عند المستويين عالي ومتوسط الكاريزما أشد انحداراً من الخط الواصل بين الدوائر التي تمثل علامات الذكور عند المستويين عالي ومتوسط الكاريزما. ويمكننا أن نستنتج أن تفضيل الشريك عالي الكاريزما على الشريك متوسط الكاريزما عند النساء هو أكبر منه عند الرجال.

2.5.4.12 التفاعل الثاني من charisma×gender: ممل مقابل بعض الكاريزما، ذكر مقابل أنثى

يقارن حد التفاعل الثاني المستوى الثاني للمتحول charisma (ممل) مع المستوى الثالث (بعض الكاريزما)، مع مقارنة علامات الذكر والأنثى. إن هذه المقارنة عالية الدلالة، $F(1,18)=33.69$، $p<0.001$. وتدلنا هذه النتيجة على أن الاهتمام المتناقص بالشريك الممل مقارنة بالشريك متوسط الكاريزما موجود عند النساء بصورة أكبر منه عند الرجال. لذلك نجد في الشكل 10.12 أن ميل الخط الواصل بين المربعات التي تمثل علامات النساء عند المستويين متوسط الكاريزما وممل أشد انحداراً من الخط الواصل بين الدوائر التي تمثل علامات الذكور عند المستويين متوسط الكاريزما وممل. ويمكننا أن نستنتج أن تفضيل الشريك متوسط الكاريزما على الشريك الممل عند النساء هو أكبر منه عند الرجال.

6.4.12 التفاعل بين المتحولين looks و charisma

يدل الخرج 3.12 على أن جاذبية الشريك تتفاعل بطريقة ما مع شخصية الشريك. ومن الجدول الملخص يمكننا القول أن هناك تفاعلاً مهماً بين جاذبية الشريك وشخصية الشريك، $F(4,72)=36.63,\ p<0.001$. ويدل هذا الأثر على أن شكل أن العلامات للشركاء من ذوي الشخصيات المختلفة كان مختلفاً من أجل المستويات المختلفة للمتحول looks (جذاب، متوسط، قبيح). وتدلنا قيم المتوسط الهامشية المقدَّرة (أو مخطط التفاعل looks×charisma باستخدام مربع الحوار المبين بالشكل 5.12) على معنى هذا التفاعل (انظر الخرج 11.12 والشكل 11.12 الذي يبين معنى هذه النتيجة).

6. looks *charisma

Measure: MEASURE_1

looks	charisma	Mean	Std. Error	95% Confidence Interval	
				Lower Bound	Upper Bound
1	1	88.950	1.383	86.045	91.855
	2	69.550	1.019	67.409	71.691
	3	87.800	1.408	84.842	90.758
2	1	71.750	1.249	69.126	74.374
	2	45.950	.746	44.382	47.518
	3	49.750	1.211	47.206	52.294
3	1	85.600	1.721	81.985	89.215
	2	47.400	.888	45.535	49.265
	3	70.350	1.172	67.888	72.812

الخرج 11.12

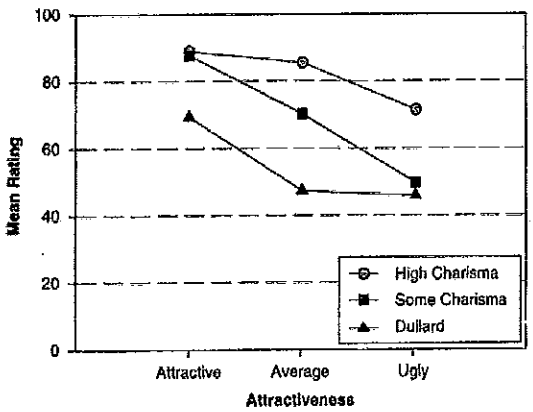

الشكل 11.12 مخطط التفاعل looks×charisma

يوضح المخطط متوسطات المستويات المختلفة للمتحول looks عندما يكون الشريك عالي الكاريزما (الدوائر)، أو لديه بعض الكاريزما (المربعات) أو مملاً (المثلثات). لننظر أولاً إلى الفروق بين الشريك الجذاب والمتوسط الجاذبية. لايتغير الاهتمام بالشريك عالي الكاريزما (فالخط الواصل

بين الدائرتين هو شبه أفقي)، أما بالنسبة للشريك متوسط الكاريزما أو الممل فإن الاهتمام به يتناقص. لذلك إذا كان الشخص عالي الكاريزما فإن اهتمام الناس به لا ينخفض سواءً كان جذاباً أو متوسط الجاذبية. والآن إذا نظرنا إلى الفرق بين الشريك متوسط الجاذبية والقبيح فإننا نلاحظ نمطاً مختلفاً. فمن أجل الأشخاص المملين (المثلثات) ليس هناك فرق بين الأشخاص القبيحين أو متوسطي الجاذبية (أي أنه إذا كان الشخص مملاً فعليه أن يكون جذاباً كي يحظى باهتمام الناس). أما الأشخاص ذوي الكاريزما العالية فهناك انحدار في اهتمام الناس بهم إذا كانوا قبيحين (لذلك إذا كان الشخص قبيحاً يتمتع بكاريزما فإن ذلك لن يساعده كثيراً). إن هذا التفاعل معقد جداً، ولكن يمكننا تقسيمه باستخدام المقارنات المحددة قبل التحليل.

1.6.4.12 التفاعل الأول من looks×charisma: جذاب مقابل متوسط، عالي مقابل بعض الكاريزما

يقارن حد التفاعل الأول المستوى الأول للمتحول looks (جذاب) مع المستوى الثالث (متوسط الجاذبية)، مع مقارنة المستوى الأول للمتحول charisma (عالي الكاريزما) مع المستوى الثالث (بعض الكاريزما). وهذا يشبه طرح السؤال التالي "هل الفرق بين الشخص عالي الكاريزما والشخص متوسط الكاريزما هو ذاته من أجل الأشخاص الجذابين والأشخاص متوسطي الجاذبية؟". إن أفضل طريقة لفهم ما تختبره هذه المقارنة هي استخلاص الجزء المفيد من مخطط التفاعل المبين في الشكل 11.12. إذا نظرنا إلى هذا الجزء من المخطط فإننا نرى أن الاهتمام (ممثلاً بالعلامات المرتفعة) بالأشخاص الجذابين هو ذاته بغض النظر عن كون الشخص عالي الكاريزما أو متوسط الكاريزما. أما بالنسبة للأشخاص متوسطي الجاذبية فهناك اهتمام بالشخص عالي الكاريزما أكبر من الاهتمام بالشخص متوسط الكاريزما. وهذه المقارنة عالية الدلالة، $F(1,18)=21.94$، $p<0.001$. وتدلنا على أنه مع انخفاض جاذبية الشخص يتناقص الاهتمام به أكثر وذلك إذا كان متوسط الكاريزما مقارنة بشخص عالي الكاريزما.

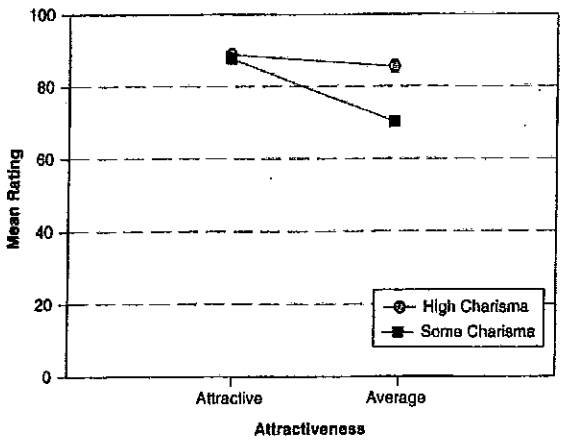

2.6.4.12 التفاعل الثاني من looks×charisma: جذاب مقابل متوسط، ممل مقابل بعض الكاريزما

يقارن حد التفاعل الثاني المستوى الأول للمتحول looks (جذاب) مع المستوى الثالث (متوسط الجاذبية)، مع مقارنة المستوى الثاني للمتحول charisma (ممل) مع المستوى الثالث (بعض الكاريزما). وهذا يشبه طرح السؤال التالي "هل الفرق بين الشخص الممل والشخص متوسط الكاريزما هو ذاته من أجل الأشخاص الجذابين والأشخاص متوسطي الجاذبية؟". ومرة أخرى تكون أفضل طريقة لفهم ما تختبره هذه المقارنة هي استخلاص الجزء المفيد من مخطط التفاعل المبين في الشكل 11.12. إذا نظرنا إلى هذا الجزء من المخطط فإننا نرى أن الاهتمام (ممثلاً بالعلامات المرتفعة) بالأشخاص الجذابين إذا كانوا متوسطي الكاريزما هو أعلى من الاهتمام بهم إذا كانوا مملين. وهذا صحيح أيضاً من أجل الأشخاص متوسطي الجاذبية. فالخطان متوازيان تقريباً. ولكن هذه المقارنة بدون دلالة، F(1,18)=4.09, ns. وهي تدلنا على أنه مع انخفاض جاذبية الشخص يتناقص الاهتمام بالشخص سواءً كان متوسط الكاريزما أو مملاً.

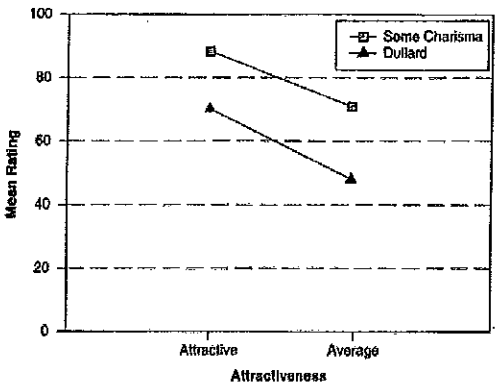

3.6.4.12 التفاعل الثالث من looks×charisma: قبيح مقابل متوسط، عالي مقابل بعض الكاريزما

يقارن حد التفاعل الثالث المستوى الثاني للمتحول looks (قبيح) مع المستوى الثالث (متوسط الجاذبية)، مع مقارنة المستوى الأول للمتحول charisma (عالي الكاريزما) مع المستوى الثالث (بعض الكاريزما). وهذا يشبه طرح السؤال التالي "هل الفرق بين الشخص عالي الكاريزما والشخص متوسط الكاريزما هو ذاته من أجل الأشخاص القبيحين والأشخاص متوسطي الجاذبية؟". إذا استخلصنا الجزء المفيد من مخطط التفاعل المبين في الشكل 11.12 فإنه يمكننا أن نرى أن الاهتمام (ممثلاً بالعلامات المرتفعة) يتناقص من الأشخاص متوسطي الجاذبية إلى الأشخاص القبيحين وذلك سواءً كان الشخص عالي أو متوسط الكاريزما. ولكن التناقص أكبر قليلاً في حالة الأشخاص متوسطي الكاريزما (الخط الواصل بين المربعات أشد انحداراً). إن هذه المقارنة ذات

دلالة، F(1,18)=6.23, p<0.05. وتدلنا على أنه مع انخفاض جاذبية الشخص يتناقص الاهتمام بالشخص متوسط الكاريزما أكثر منه في حالة الشخص عالي الكاريزما.

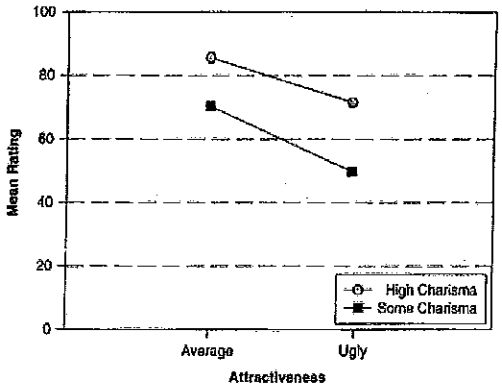

4.6.4.12 التفاعل الرابع من looks×charisma: قبيح مقابل متوسط، ممل مقابل بعض الكاريزما

يقارن حد التفاعل الأخير المستوى الثاني للمتحول looks (قبيح) مع المستوى الثالث (متوسط الجاذبية)، مع مقارنة المستوى الثاني للمتحول charisma (ممل) مع المستوى الثالث (بعض الكاريزما). وهذا يشبه طرح السؤال التالي "هل الفرق بين الشخص الممل والشخص متوسط الكاريزما هو ذاته من أجل الأشخاص القبيحين والأشخاص متوسطي الجاذبية؟". إذا استخلصنا الجزء المفيد من مخطط التفاعل المبين في الشكل 11.12 فإنه يمكننا أن نرى أن الاهتمام (ممثلاً بالعلامات المرتفعة) بالأشخاص متوسطي الجاذبية إذا كانوا متوسطي الكاريزما هو أعلى من الاهتمام بهم إذا كانوا مملين، ولكن من أجل الأشخاص القبيحين فإن العلامات تبقى ذاتها تقريباً مهما كان مستوى الكاريزما. إن هذه المقارنة عالية الدلالة، F(1,18)=88.60, p<0.001. وتدلنا على أنه مع انخفاض جاذبية الشخص يتناقص الاهتمام بالشخص متوسط الكاريزما أكثر منه في حالة الشخص الممل.

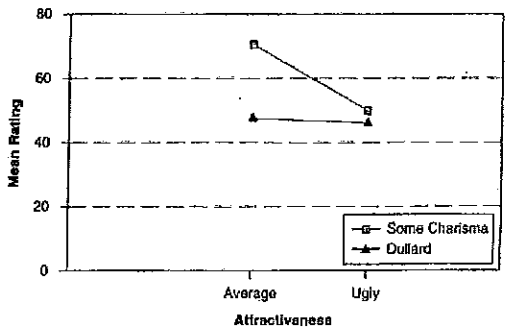

7.4.12 التفاعل بين المتحولات looks×charisma×gender

يدلنا التفاعل ثلاثي الاتجاه على فيما إذا كان التفاعل looks×charisma الموصوف سابقاً هو ذاته من أجل الذكور والإناث (أي فيما إذا كان الأثر المركب للجاذبية والشخصية هو ذاته للمشتركين سواءً كانوا ذكوراً أم إناثاً). يبين الخرج 3.12 أن هناك تفاعلاً ثلاثي الاتجاه (looks×charisma×gender) ذو دلالة، $F(4,72)=24.12,\ p<0.001$. ويكشف الشكل 12.12 طبيعة هذا التفاعل، حيث يبين التفاعل looks×charisma لكل من الرجال والنساء بشكل منفصل (تظهر قيم المتوسط التي اعتمدت لرسم المخطط في الخرج 12.12).

7. Gender* looks *charisma

Measure: MEASURE_1

Gender	looks	charisma	Mean	Std. Error	95% Confidence Interval	
					Lower Bound	Upper Bound
Male	1	1	88.300	1.956	84.191	92.409
		2	87.300	1.441	84.273	90.327
		3	88.500	1.991	84.317	92.683
	2	1	56.800	1.767	53.089	60.511
		2	45.800	1.055	43.583	48.017
		3	48.300	1.712	44.703	51.897
	3	1	82.800	2.434	77.687	87.913
		2	47.800	1.255	45.163	50.437
		3	71.800	1.657	68.318	75.282
Female	1	1	89.600	1.956	85.491	93.709
		2	51.800	1.441	48.773	54.827
		3	87.100	1.991	82.917	91.283
	2	1	86.700	1.767	82.989	90.411
		2	46.100	1.055	43.883	48.317
		3	51.200	1.712	47.603	54.797
	3	1	88.400	2.434	83.287	93.513
		2	47.000	1.255	44.363	49.637
		3	68.900	1.657	65.418	72.382

الخرج 12.12

يبين مخطط الرجال (الأيسر) أنه عندما يكون الشريك جذاباً فإن الرجال يبدون اهتماماً كبيراً بغض النظر عن مستوى الكاريزما (تتطابق الدائرة والمربع والمثلث). وعندما يكون الشريك قبيحاً فإن الرجال يبدون اهتماماً قليلاً مهما كان مستوى الكاريزما (جميع العلامات منخفضة). والمرة الوحيدة التي تلعب فيها الشخصية دوراً في خلق فرق واضح هي عندما يكون الشريك متوسط الجاذبية، حيث تزيد الكاريزما العالية مستوى الاهتمام، ويخفض الملل مستوى الاهتمام، بينما تدفع

بعض الكاريزما بالاهتمام إلى مستوى بين الحدين السابقين. والخلاصة هي أن الرجال أغبياء سطحيون يهتمون بالمظاهر الخارجية. أما الصورة عند النساء فهي مختلفة جداً. فإذا كان الشخص عالي الكاريزما فإن المرأة لا تعير اهتماماً للجاذبية (الخط الواصل بين الدوائر شبه أفقي). أما إذا كان الشخص مملاً فإن المرأة لا تهتم به بغض النظر عن جاذبيته (الخط الواصل بين المثلثات شبه أفقي). والمرة الوحيدة التي تلعب فيها الجاذبية دوراً في خلق فرق واضح هي عندما يكون للشخص بعض الكاريزما، حيث ترفع الجاذبية العالية مستوى الاهتمام، ويخفض القبح مستوى الاهتمام. فالمرأة تعطي أولوية للكاريزما تفوق اهتمامها بالمظهر الخارجي. ومرة أخرى يمكننا النظر إلى بعض المقارنات لتقسيم هذا التفاعل. وهذه المقارنات مشابهة لتلك المستخدمة في التفاعل looks×charisma، ولكنها تأخذ الآن أثر المتحول gender بعين الاعتبار.

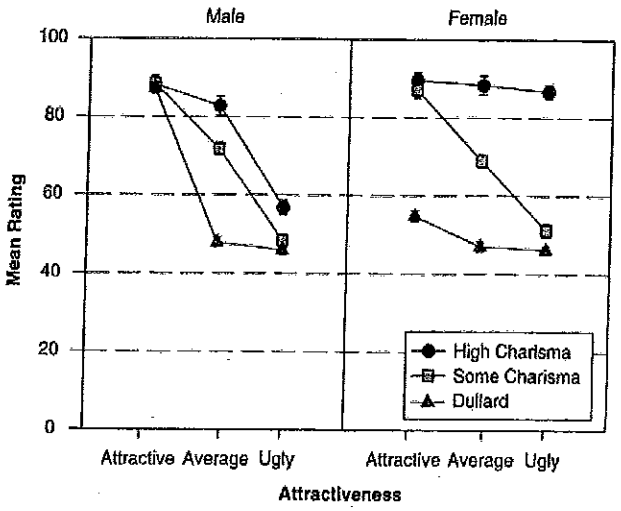

الشكل 12.12 مخطط التفاعل looks×charisma لكل من الرجال والنساء

1.7.4.12 التفاعل الأول من looks×gender×charisma: جذاب مقابل متوسط، عالي مقابل بعض الكاريزما، ذكر مقابل أنثى

يقارن الحد الأول للتفاعل المستوى الأول للمتحول looks (جذاب) مع المستوى الثالث (متوسط)، عند مقارنة المستوى الأول للمتحول charisma (عالي الكاريزما) مع المستوى الثالث (بعض الكاريزما) في حالة مقارنة الذكور مع الإناث، F(1,18), ns. إذا استخلصنا الجزء المفيد من مخطط التفاعل المبين في الشكل 12.12 فإنه يمكننا أن نرى أن الاهتمام (ممثلاً بالعلامات المرتفعة) بالأشخاص الجذابين هو ذاته بغض النظر عن مستوى الكاريزما للشخص (عالي أو متوسط). أما من أجل الأشخاص متوسطي الجاذبية فإن هناك اهتماماً بالأشخاص ذوي الكاريزما العالية أكبر من الاهتمام بالأشخاص ذوي الكاريزما المتوسطة. وهذا النمط من النتائج هو ذاته مهما كان جنس الشخص (ذكر أم أنثى) وهذا يعكس عدم الدلالة لهذه المقارنة.

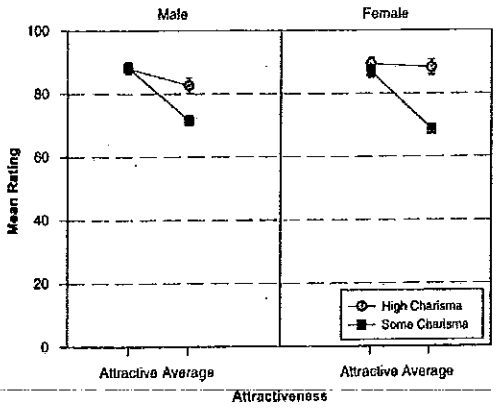

2.7.4.12 التفاعل الثاني من looks×gender×charisma: جذاب مقابل متوسط، ممل مقابل بعض الكاريزما، ذكر مقابل أنثى

يقارن الحد الثاني للتفاعل المستوى الأول للمتحول looks (جذاب) مع المستوى الثالث (متوسط)، عند مقارنة المستوى الثاني للمتحول charisma (ممل) مع المستوى الثالث (بعض الكاريزما) في حالة مقارنة الذكور مع الإناث. ومرة أخرى نستخلص الجزء المفيد من مخطط التفاعل المبين في الشكل 12.12، ونرى أن النمط مختلف بين الرجال والنساء. وهذا يعكس حقيقة أن هذه المقارنة ذات دلالة، $F(1,18)=60.67,\ p<0.001$. لننظر إلى المخطط: إذا نظرنا إلى حالة شخص متوسط الجاذبية فإن كلاً من الرجل والمرأة يبدي اهتماماً بالشخص متوسط الكاريزما أكبر من الاهتمام بالشخص الممل (المسافة بين المربع والمثلث هي ذاتها تقريباً). لذلك لا يبدو هناك فرق في هذه الحالة. إذا نظرنا الآن إلى حالة شخص جذاب فإننا نرى أن الرجل يُظهر نفس الاهتمام بالشخص بغضّ النظر عن مستوى الكاريزما، أما المرأة فهي أقل اهتماماً بالشخص الجذاب إذا كان مملاً. فمن أجل الشخص الجذاب تكون المسافة بين المربع والمثلث في حالة الرجل أصغر من المسافة في حالة المرأة. وإذا اتبعنا طريقة أخرى، فإنه عند النظر إلى الشخص متوسط الكاريزما يكون تناقص الاهتمام بالجاذبية بنفس المستوى عند المرأة والرجل (الخطوط الواصلة بين المربعات لها نفس الميل في كلا المخططين). أما بالنسبة للشخص الممل فإن تناقص الاهتمام إذا كان الشخص متوسط الجاذبية هو عند الرجال أكثر حدة منه عند النساء (الخط الواصل بين المثلثات أشد انحداراً في حالة الرجال). وهذا ما تدلنا عليه هذه المقارنة ذات الدلالة.

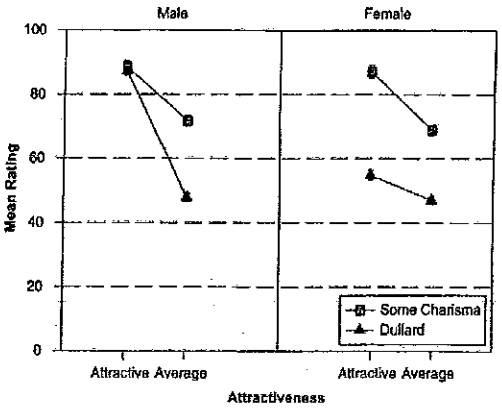

3.7.4.12 التفاعل الثالث من looks×gender×charisma: قبيح مقابل متوسط، عالي مقابل بعض الكاريزما، ذكر مقابل أنثى

يقارن الحد الثالث للتفاعل المستوى الثاني للمتحول looks (قبيح) مع المستوى الثالث (متوسط)، عند مقارنة المستوى الأول للمتحول charisma (عالي الكاريزما) مع المستوى الثالث (بعض الكاريزما) في حالة مقارنة الذكور مع الإناث. ومرة أخرى نستخلص الجزء المفيد من مخطط التفاعل المبين في الشكل 12.12، ونرى أن النمط مختلف بين الرجال والنساء. وهذا يعكس حقيقة أن هذه المقارنة ذات دلالة، $F(1,18)=11.70,\ p<0.01$. لننظر إلى المخطط ونأخذ حالة الرجال أولاً. عندما تتناقص الجاذبية يتناقص الاهتمام بالشخص إذا كان عالي الكاريزما أو متوسط الكاريزما (فالخطان متوازيان تقريباً). لذلك وبغض النظر عن الكاريزما، فإن هناك انخفاضاً متماثلاً في الاهتمام بالشخص عند انخفاض جاذبيته. أما بالنسبة للمرأة فالصورة مختلفة تماماً. عندما تكون الكاريزما عالية فليس هناك تناقص في الاهتمام عند انخفاض الجاذبية (الخط الواصل بين الدوائر شبه أفقي)، ولكن عندما تكون الكاريزما متوسطة فإن الكاريزما تلعب دوراً حيث يكون الاهتمام بالشخص القبيح أدنى من الاهتمام بالشخص متوسط الجاذبية. وإذا نظرنا بطريقة أخرى فإنه إذا كان الشخص متوسط الكاريزما فإن تناقص الاهتمام به إذا تدنت الجاذبية متشابه عند الرجال والنساء (فالخطوط الواصلة بين المربعات لها نفس الميل في كلا المخططين). أما بالنسبة للشخص عالي الكاريزما فإن تناقص الاهتمام به إذا كان قبيحاً هو عند الرجال أكثر حدة منه عند النساء (الخط الواصل بين الدوائر أشد انحداراً في حالة الرجال). وهذا ما تدلنا عليه هذه المقارنة ذات الدلالة.

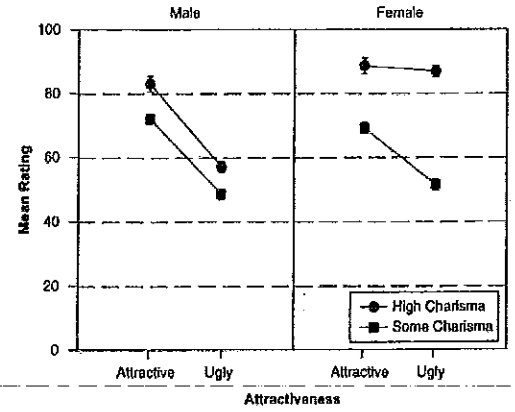

4.7.4.12 التفاعل الرابع من looks×gender×charisma: قبيح مقابل متوسط، ممل مقابل بعض الكاريزما، ذكر مقابل أنثى

يقارن الحد الأخير للتفاعل المستوى الثاني للمتحول looks (قبيح) مع المستوى الثالث (متوسط) عند مقارنة المستوى الثاني للمتحول charisma (ممل) مع المستوى الثالث (بعض الكاريزما) في حالة مقارنة الذكور مع الإناث. إذا استخلصنا الجزء المفيد من مخطط التفاعل المبين في الشكل 12.12 فإنه يمكننا أن نرى أن الاهتمام بالشخص القبيح متماثل عند الرجال والنساء بغض النظر عن مستوى الكاريزما. فمن أجل الشخص متوسط الجاذبية هناك اهتمام أكبر عندما يكون الشخص متوسط الكاريزما مقارنة بشخص ممل. إن نمط النتائج هو ذاته في حالتي الرجل والمرأة وهذا يعكس عدم دلالة هذه المقارنة، $F(1,18)=1.33$, ns.

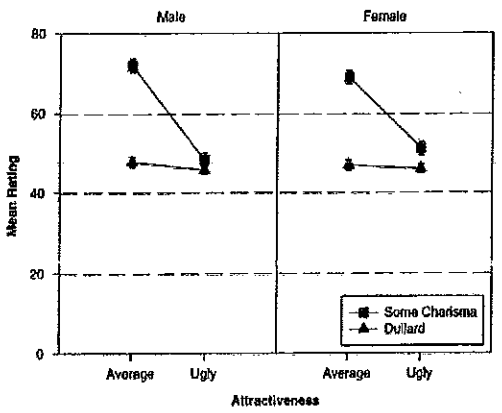

8.4.12 الخلاصة

لا تعطينا هذه المقارنات أية معلومات عن الفروق بين الحالتين جذاب وقبيح (للمتحول looks)، أو الحالتين عالي الكاريزما وممل (للمتحول charisma) لأنه لم تتم مقارنتهما معاً. يمكننا إعادة تنفيذ

التحليل وتحديد المقارنات بشكل مختلف لنحصل على هذه الآثار. على كل حال، من الواضح في البيانات وجود فروق بين الرجال والنساء من حيث تأثرهم بالجاذبية وبالشخصية للشريك المحتمل. ويبدو الرجال أكثر اهتماماً بأي شخص جذاب بغض النظر عن شخصيته. أما النساء فعلى العكس تماماً، إذ أن المرأة أكثر اهتماماً بالشخص ذو الكاريزما بغض النظر عن منظره وجاذبيته (كما أنها غير مهتمة بشخص ممل مهما كان مستوى جاذبيته). والتوافق الوحيد بين الرجال والنساء هو عندما يكون للشخص بعض الكاريزما حيث تؤثر جاذبية الشخص على اهتمام كلا الجنسين به.

من الواضح في هذا الفصل أنه عند استخدام أكثر من متحولين مستقلين في ANOVA تنتج آثار تفاعل معقدة وتتطلب تركيزاً أعلى لتفسيرها (تخيل إذا تفسير تفاعل رباعي الاتجاه!). لذلك من الضروري إتباع طريقة منهجية في التفسير ورسم المخططات. ومن المهم أيضاً التفكير ملياً في اختيار المقارنات المناسبة التي تريد استخدامها للإجابة على الأسئلة المطروحة بخصوص البيانات المتوفرة. إن هذه المقارنات هي التي تساعدك في تفسير التفاعلات لذلك احرص على اختيارها بشكل صحيح.

أفكار مهمة

- يقارن ANOVA المختلط عدة متوسطات عند وجود متحولين مستقلين أو أكثر، أحدهما على الأقل يتم قياسه باستخدام نفس المشتركين، ومتحول آخر على الأقل يتم قياسه باستخدام مشتركين مختلفين.
- اختبر فرضية الكروية من أجل متحول (أو متحولات) القياسات المكررة عند وجود ثلاث حالات تجريبية على الأقل وذلك باستخدام اختبار Mauchly. إذا كانت قيمة الدلالة في العمود المسمى .Sig أصغر من 0.05 فإن فرضية الكروية غير محققة. أما إذا كانت قيمة الدلالة لاختبار Mauchly أكبر من 0.05 فإن فرضية الكروية محققة. يجب اختبار هذه الفرضية من أجل جميع الآثار (عند وجود متحولي قياسات مكررة على الأقل فإن ذلك يعني اختبار الفرضية من أجل جميع المتحولات وحدود التفاعل الموافقة).
- يعرض الجدول المسمى Tests of Within-Subjects Effects نتائج ANOVA لمتحولات القياسات المكررة ولجميع آثار التفاعل. ومن أجل كل أثر، إذا كانت فرضية الكروية محققة فإننا نبحث عن الصف المسمى Sphericity Assumed. أما إذا لم تكن محققة فإننا نبحث عن الصف المسمى Greenhouse-Geisser (يمكنك أن تنظر أيضاً إلى Huynh-Feldt ولكن عليك قراءة الفصل السابق لمعرفة المزايا النسبية لكل من الإجرائيتين). بعد اختيار الصف المناسب، ابحث عن قيمة الدلالة في العمود المسمى .Sig فإذا كانت القيمة أصغر من 0.05 فإن المتوسطات للمجموعات مختلفة بشكل كبير.
- يعرض الجدول المسمى Tests of Between-Subjects Effects نتائج ANOVA للمتحولات بين المجموعات. ابحث عن قيمة الدلالة في العمود المسمى .Sig فإذا كانت القيمة أصغر من 0.05 فإن المتوسطات بين المجموعات هي مختلفة بشكل كبير.

- قسّم الآثار الرئيسية وحدود التفاعل باستخدام المقارنات. وتظهر هذه المقارنات في الجدول المسمى Tests of Within-Subjects Contrasts، ابحث عن قيمة الدلالة في العمود المسمى .Sig لاكتشاف إذا كانت المقارنات ذات دلالة (تكون المقارنات ذات دلالة إذا كانت قيمة الدلالة أصغر من 0.05).
- انظر إلى قيم المتوسط أو ارسم المخططات البيانية لمساعدتك في تفسير المقارنات.

5.12 حساب حجم الأثر

نحسب حجم الأثر من أجل المقارنات في حالة التصميم العاملي (ومن أجل أيّ من الآثار الرئيسية التي تقارن مجموعتين فقط). يعرض الخرج 7.12 القيم لعدة مقارنات، وجميعها ذات درجة حرية واحدة للنموذج (جميعها تمثل مقارنة مركزة وقابلة للتفسير) و18 درجة حرية للبواقي. يمكننا استخدام النسب F وتحويلها إلى حجم الأثر r باستخدام الصيغة التي تعاملنا معها سابقاً:

$$r = \sqrt{\frac{F(1, df_R)}{F(1, df_R) + df_R}}$$

نبدأ أولاً مع الأثر الرئيسي للمتحول gender لأن هذه المقارنة تقارن مجموعتين فقط:

$$r_{gender} = \sqrt{\frac{0.005}{0.005 + 18}} = 0.02$$

ومن أجل المقارنتين الخاصتين بالمتحول looks (انظر الخرج 7.12) فإننا نجد:

$$r_{Attractive\ vs.\ Average} = \sqrt{\frac{226.99}{226.99 + 18}} = 0.96$$

$$r_{Ugly\ vs.\ Average} = \sqrt{\frac{160.07}{160.07 + 18}} = 0.95$$

وهكذا فقد أعطت المقارنتان حجم أثر كبير. ومن أجل المقارنتين الخاصتين بالمتحول charisma (انظر الخرج 7.12) فإننا نجد:

$$r_{High\ vs.\ Some} = \sqrt{\frac{109.94}{109.94 + 18}} = 0.93$$

$$r_{Dullard\ vs.\ gender} = \sqrt{\frac{227.94}{227.94 + 18}} = 0.96$$

ومرة أخرى أعطت المقارنتان حجم أثر كبير. ومن أجل المقارنتين الخاصتين بالتفاعل looks×gender فإننا نجد:

$$r_{\text{Attractive vs. Average, Male vs. Female}} = \sqrt{\frac{43.26}{43.26+18}} = 0.84$$

$$r_{\text{Ugly vs. Average, Male vs. Female}} = \sqrt{\frac{30.23}{30.23+18}} = 0.79$$

ومرة أخرى أعطت المقارنتان حجم أثر كبير. ومن أجل المقارنتين الخاصتين بالتفاعل charisma×gender فإننا نجد:

$$r_{\text{High vs. Some, Male vs. Female}} = \sqrt{\frac{27.20}{27.20+18}} = 0.78$$

$$r_{\text{Dullard vs. Some, Male vs. Female}} = \sqrt{\frac{33.69}{33.69+18}} = 0.81$$

ومرة أخرى حصلنا على حجم أثر كبير. ننتقل الآن إلى التفاعل looks×charisma حيث لدينا 4 مقارنات:

$$r_{\text{Attractive vs. Average, High vs. Some}} = \sqrt{\frac{21.94}{21.94+18}} = 0.74$$

$$r_{\text{Attractive vs. Average, Dullard vs. Some}} = \sqrt{\frac{4.09}{4.09+18}} = 0.43$$

$$r_{\text{Ugly vs. Average, High vs. Some}} = \sqrt{\frac{6.23}{6.23+18}} = 0.51$$

$$r_{\text{Ugly vs. Averagr, Dullard vs. Some}} = \sqrt{\frac{88.60}{88.60+18}} = 0.91$$

يتراوح حجم الأثر لهذه الآثار بين متوسط وكبير. وأخيراً ننتقل إلى التفاعل looks×charisma×gender حيث لدينا 4 مقارنات:

$$r_{\text{Attractive vs. Average, High vs. Some, Male vs. Female}} = \sqrt{\frac{0.93}{0.93+18}} = 0.22$$

$$r_{\text{Attractive vs. Average, Dullard vs. Some, Male vs. Female}} = \sqrt{\frac{60.67}{60.67+18}} = 0.88$$

$$r_{\text{Ugly vs. Average, High vs. Some, Male vs. Female}} = \sqrt{\frac{11.70}{11.70+18}} = 0.63$$

$$r_{\text{Ugly vs. Averagr, Dullard vs. Some, Male vs. Female}} = \sqrt{\frac{1.33}{1.33+18}} = 0.26$$

نظراً لأن اثنين من الآثار كانا مهمّين (الثاني والثالث) فقد أعطيا حجم أثر كبير، أما الأثران الآخران (الأول والرابع) فلم يكونا مهمّين لذلك أعطيا حجم أثر متوسط تقريباً.

6.12 تقديم نتائج ANOVA المختلط

عندما يكون لدينا أكثر من متحولَين مستقلين فإن كمية المعلومات الواجب تقديمها تكون كبيرة. علينا تقديم جميع الآثار الرئيسية وجميع التفاعلات والمقارنات التي تم تنفيذها، ولذلك يجب الاكتفاء بالتفاصيل المهمة فقط للآثار (تكون الآثار الرئيسية غير مفيدة إذا كان التفاعل الذي يتضمن ذلك المتحول ذا دلالة). لنفترض أننا نريد تقديم جميع الآثار، يمكننا القيام بذلك بالشكل التالي:

- ✓ جميع الآثار ذات دلالة عند مستوى P<0.05. هناك أثر رئيسي ذو دلالة لجاذبية الشريك التي يعبر عنها المشترك، F(2,36)=423.73. وتكشف المقارنات أن الشريك الجذاب مرغوب أكثر من الشريك متوسط الجاذبية، F(1,18)=226.99, r=0.96، وأن الشريك القبيح مرغوب بشكل أقل من الشريك متوسط الجاذبية، F(1,18)=160.07, r=0.95.
- ✓ هناك أيضاً أثر رئيسي ذو دلالة لمقدار الكاريزما للشريك، F(2,36)=328.25. وتكشف المقارنات أن الشريك عالي الكاريزما مرغوب أكثر من الشريك المتمتع ببعض الكاريزما، F(1,18)=109.94, r=0.93، وأن الشريك الممل مرغوب أقل من الشريك المتمتع ببعض الكاريزما، F(1,18)=227.94, r=0.96.
- ✓ ليس هناك أثر ذو دلالة للجنس مما يدل على أن العلامات من المشتركين الذكور والإناث كانت متماثلة عموماً، F(1,18)<1, r=0.02.
- ✓ هناك أثر ذو دلالة للتفاعل بين جاذبية الشريك وجنس المشترك، F(2,36)=80.43. ويدل ذلك على أن الرغبة بالشريك عند مختلف مستويات جاذبيته مختلفة بين النساء والرجال. ولتقسيم هذا التفاعل، تم تنفيذ المقارنات لمقارنة كل مستوى من الجاذبية مع المستوى المتوسط للجاذبية وذلك من أجل المشتركين من كلا الجنسين. وقد كشفت هذه المقارنات عن تفاعلات ذات دلالة عند مقارنة علامات الذكور والإناث التي أعطوها للشركاء الجذابين مقارنة مع الشركاء متوسطي الجاذبية، F(1,18)=43.26, r=0.84. والعلامات التي أعطوها للشركاء القبيحين مقارنة مع الشركاء متوسطي الجاذبية، F(1,18)=30.23, r=0.79. وبالنظر إلى مخطط التفاعل، نرى أن علامات الذكور والإناث متشابهة جداً من أجل الشريك متوسط الجاذبية، ولكن الذكور يمنحون علامات للشريك الجذاب أعلى مما تمنحه الإناث، بينما تمنح الإناث علامات للشريك القبيح أعلى مما يمنحه الذكور. ومع أن اهتمام كلا الجنسين يتناقص مع انخفاض جاذبية الشريك فإن هذا التناقص أكثر حدة عند الرجال، وهذا يعني أنه عند إهمال الكاريزما، فإن اهتمام الرجال بمواعدة شخص ما يتأثر بمظهره الخارجي أكثر من تأثر النساء بذلك.
- ✓ هناك أثر ذو دلالة للتفاعل بين مستوى الكاريزما للشريك وجنس المشترك، F(2,36)=62.45. ويدل ذلك على أن الرغبة بالشريك عند مختلف مستويات الكاريزما مختلفة بين النساء والرجال. ولتقسيم هذا التفاعل، تم تنفيذ المقارنات لمقارنة كل مستوى من الكاريزما مع الفئة

المتوسطة "بعض الكاريزما" وذلك من أجل المشتركين من كلا الجنسين. وقد كشفت هذه المقارنات عن تفاعلات ذات دلالة عند مقارنة علامات الذكور والإناث التي أعطوها للشركاء المتمتعين بكاريزما عالية مقارنة مع الشركاء المتمتعين ببعض الكاريزما، F(1,18)=27.20, r=0.78. والعلامات التي أعطوها للشركاء المملين مقارنة مع الشركاء المتمتعين ببعض الكاريزما، F(1,18)=33.69, r=0.81. وبالنظر إلى مخطط التفاعل، نرى أن الرجال يبدون اهتماماً بالشريك الممل أكثر من اهتمام النساء، بينما تهتم النساء بالشريك عالي الكاريزما أكثر من اهتمام الرجال. ويتناقص اهتمام كلا الجنسين مع انخفاض الكاريزما، ولكن هذا التناقص أكثر حدة عند النساء، وهذا يعني أن اهتمام النساء بمواعدة شخص ما يتأثر بشخصيته أكثر من تأثر الرجال بذلك.

- ✓ هناك أثر ذو دلالة للتفاعل بين مستوى الكاريزما للشريك وجاذبيته، F(4,72)=36.63. ويدل ذلك على أن الرغبة بالشريك عند مختلف مستويات الكاريزما تختلف تبعاً لجاذبيته. ولتقسيم هذا التفاعل، تم تنفيذ المقارنات لمقارنة كل مستوى من الكاريزما مع الفئة المتوسطة "بعض الكاريزما" من أجل كل مستوى من الجاذبية مقارنة مع الفئة المتوسطة للجاذبية. تكشف المقارنة الأولى عن تفاعل ذي دلالة عند مقارنة الشريك الجذاب مع الشريك متوسط الجاذبية وذلك عندما يكون عالي الكاريزما مقارنة بمن يتمتع ببعض الكاريزما، F(1,18)=21.94، r=0.74. وتدلنا على أنه عندما يصبح الشريك أقل جاذبية فإن هناك انخفاضاً أكبر في الاهتمام به إذا كان متوسط الكاريزما مقارنة بمن يتمتع بكاريزما عالية. تقارن المقارنة الثانية الشريك الجذاب مع الشريك متوسط الجاذبية وذلك عندما يكون مملاً مقارنة بمن يتمتع ببعض الكاريزما. وهذه المقارنة بدون دلالة، F(1,18)=4.09, r=0.43. وتدلنا على أنه عندما يصبح الشريك أقل جاذبية فإن هناك انخفاضاً كبيراً في الاهتمام به سواءً كان يتمتع ببعض الكاريزما أو كان مملاً. تقارن المقارنة الثالثة الشريك القبيح مع الشريك متوسط الجاذبية وذلك عندما يتمتع بكاريزما عالية مقارنة بمن يتمتع ببعض الكاريزما. وهذه المقارنة ذات دلالة، F(1,18)=6.23, r=0.51. وتدلنا على أنه عندما يصبح الشريك أقل جاذبية فإن هناك انخفاضاً أكبر في الاهتمام به إذا كان متوسط الكاريزما مقارنة بمن يتمتع بكاريزما عالية. أما المقارنة الأخيرة فتقارن الشريك القبيح مع الشريك متوسط الجاذبية وذلك عندما يكون مملاً مقارنة بمن يتمتع ببعض الكاريزما. وهذه المقارنة مرتفعة الدلالة، F(1,18)=88.60, r=0.9، وتدلنا على أنه عندما يصبح الشريك أقل جاذبية فإن هناك انخفاضاً أكبر في الاهتمام به إذا كان يتمتع ببعض الكاريزما مقارنة مع الشخص الممل.
- ✓ أخيراً لدينا التفاعل ذو الدلالة looks×charisma×gender، F(4,72)=24.12. ويدل ذلك على أن التفاعل looks×charisma الموصوف سابقاً يختلف بين المشتركين من كلا الجنسين. ومرة أخرى تم استخدام المقارنات لتقسيم هذا التفاعل: تقارن هذه المقارنات علامات الذكور والإناث عند كل مستوى للكاريزما مقارنة بالفئة الوسطى "بعض الكاريزما" من أجل كل مستوى من مستويات الجاذبية مقارنة بفئة الجاذبية المتوسطة. تكشف المقارنة الأولى عن فرق

غير مهم بين استجابات الذكور والإناث عند مقارنة الشريك الجذاب مع الشريك متوسط الجاذبية وعندما يكون الشريك عالي الكاريزما مقارنة بمن يتمتع ببعض الكاريزما، $F(1,18)<1$, $r=0.22$، وتدلنا على أنه من أجل كلا الجنسين وعندما تنخفض جاذبية الشريك فإن هناك انخفاضاً أكبر في الاهتمام به إذا كان يتمتع ببعض الكاريزما مقارنة بمن يتمتع بكاريزما عالية. وتكشف المقارنة الثانية عن فروق بين الذكور والإناث عند مقارنة الشريك الجذاب مع الشريك متوسط الجاذبية وعندما يكون الشريك مملاً مقارنة بمن يتمتع ببعض الكاريزما. وهذه المقارنة ذات دلالة، $F(1,18)=60.67$, $r=0.88$. وتدلنا على أنه من أجل الشريك المتمتع ببعض الكاريزما فإن تناقص الاهتمام عندما تنخفض الجاذبية هو نفسه عند الرجال والنساء، أما من أجل الشريك الممل فإن تناقص الاهتمام إذا كان متوسط الجاذبية هو أكثر حدة عند الرجال مقارنة بالنساء. وتبحث المقارنة الثالثة في الفروق بين الذكور والإناث عند مقارنة الشريك القبيح مع الشريك متوسط الجاذبية وعندما يتمتع الشريك بكاريزما عالية مقارنة بمن يتمتع ببعض الكاريزما. وهذه المقارنة ذات دلالة، $F(1,18)=11.7$، $r=0.63$. وتدلنا على أنه من أجل الشريك المتمتع ببعض الكاريزما فإن تناقص الاهتمام عندما تنخفض الجاذبية متماثل تقريباً عند الرجال والنساء، ولكن من أجل الشريك عالي الكاريزما فإن تناقص الاهتمام إذا كان الشريك قبيحاً هو أكثر حدة عند الرجال مقارنة بالنساء. أما المقارنة الأخيرة فتبحث عن الفروق بين الرجال والنساء عند مقارنة الشريك القبيح مع الشريك متوسط الجاذبية وعندما يكون الشريك مملاً مقارنة بمن يتمتع ببعض الكاريزما. وهذه المقارنة بدون دلالة، $F(1,18)=1.33$, $r=0.26$، وتدلنا على أنه من أجل الرجال والنساء فإنه عند تناقص جاذبية الشريك فإن تناقص الاهتمام بالشريك المتمتع ببعض الكاريزما هو أكثر حدة مقارنة بالشريك الممل.

7.12 ما الذي اكتشفناه عن الإحصاء؟

نأمل في نهاية هذا الفصل أنك اكتشفت أن ANOVA تتمتع بالمرونة بحيث يمكنك خلط المتحولات المستقلة التي قيست باستخدام نفس المشتركين أو مشتركين مختلفين. وأنك بدأت تتأكد من وجود أسباب حقيقية للحد من عدد المتحولات المستقلة المتضمنة (من أجل التفسير).

8.12 المصطلحات الأساسية التي اكتشفناها

ANOVA المختلط (Mixed ANOVA)

التصميم المختلط (Mixed design)

9.12 مهمات يجب تنفيذها

- **المهمة الأولى:** سنقوم في هذه المهمة بتوسيع المثال المقدم في الفصل السابق (الإعلانات والصور المختلفة) وذلك بإضافة متحول بين المجموعات إلى التصميم (يحوي المثال الأصلي متحولي قياسات مكررة drink وimagery). تخيل أننا ندوّن جنس المشترك، أي أننا نعتقد أن الاستجابات لنوع المشروب تختلف بين الرجال والنساء. لذلك نريد إعادة تحليل البيانات بأخذ هذا المتحول الإضافي بعين الاعتبار. إن المتحول الجديد هو متحول بين المجموعات لأن المشترك يمكن أن يكون ذكراً أو أنثى (لا يستطيع المشترك الذكر أن يغير جنسه ويشارك مرة أخرى في التجربة!). يحوي الملف MixedAttitude.sav بيانات هذه المهمة. نفذ ANOVA مختلط على هذه البيانات.
- **المهمة الثانية:** تعتبر الرسائل القصيرة SMS وسيلة اتصال شعبية جداً لدى مستخدمي الهواتف المحمولة بحيث تم نشر عدة كتب حول طريقة كتابة الرسائل القصيرة باللغة الانكليزية (hope u no wat I mean by spk)، وأحد مخاطر هذا النوع من رسائل الاتصال على الأطفال هو التأثير السلبي على قابليتهم على تعلم الكتابة الصحيحة باللغة الانكليزية. وقد قاد أحد الباحثين المهتمين بالموضوع تجربة قام فيها بتشجيع مجموعة من الأطفال على إرسال الرسائل القصيرة من هواتفهم المحمولة خلال 6 أشهر، فيما منع مجموعة أخرى من إرسال الرسائل القصيرة خلال نفس الفترة، وقد ضمت كل مجموعة 25 مشتركاً مختلفاً. وكانت النتيجة هي علامة المشتركين في اختبار القواعد (كنسبة مئوية) والذي تم تنفيذه قبل التجربة وبعدها. المتحول المستقل الأول هو استخدام الرسائل القصيرة، والمتحول المستقل الثاني هو الزمن الذي تم فيه تقييم القدرات اللغوية (قبل أو بعد التجربة). يحوي الملف TextMessages.sav البيانات لهذه المهمة.

يحوي الملف Answers(Chapter 12).pdf على القرص المضغوط المرفق الإجابات.

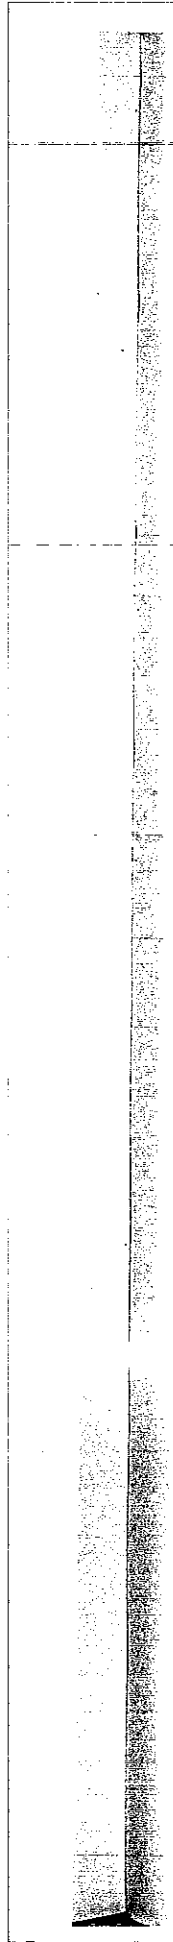

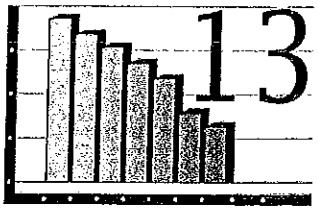

الاختبارات اللابارامترية

1.13 بماذا يخبرنا هذا الفصل؟

رأينا في الفصول السابقة كيفية استخدام التقنيات المختلفة للبحث عن الفروق بين المتوسطات. وتعتمد جميع تلك الاختبارات على فرضيات البارامترية (وخاصة التوزع الطبيعي للبيانات). وقد رأينا في الفصل 3 أن البيانات لا تكون دائماً موزعة طبيعياً. ولا يمكن تصحيح هذه المشاكل دائماً. ماذا نفعل في هذه الحالة؟ الجواب هو أننا نستخدم أنواعاً خاصة من الإجرائيات الإحصائية تدعى الاختبارات اللابارامترية (Non-Parametric tests). وتدعى أحياناً بالاختبارات الخالية من الفرضيات لأنها تضع عدداً أقل من الفرضيات حول نوع البيانات التي يمكن استخدامها. وتعمل معظم هذه الطرق على مبدأ ترتيب البيانات (ranking)، أي أنها تبحث عن العلامة الأدنى وتعطيها المرتبة 1 ثم تبحث عن العلامة الأعلى منها وتعطيها المرتبة 2 وهلم جرا. وينتج عن هذه العملية تمثيل العلامات العليا بالمراتب الكبيرة، والعلامات الدنيا بالمراتب الصغيرة. يتم بعد ذلك تنفيذ التحليل على المراتب بدلاً من البيانات الفعلية. وهذه العملية هي طريقة بارعة للتعامل مع مشكلة استخدام البيانات التي تخرق فرضيات البارامترية. ويعتقد بعض الناس أن للاختبارات اللابارامترية قدرة أقل من مثيلاتها البارامترية، ولكن كما سنرى في المربع 2.13 أن ذلك ليس صحيحاً دائماً. في هذا الفصل سنتعرف على 4 إجرائيات لابارامترية شائعة: اختبار Mann-Whitney، اختبار Wilcoxon للمرتبة ذات الإشارة، اختبار Friedman واختبار Kruskal-Wallis. وسنكتشف كيفية تنفيذ التحليل في برنامج SPSS لكل من هذه الإجرائيات، وكيفية تفسير النتائج وتقديمها.

2.13 مقارنة حالتين مستقلتين: اختبار Wilcoxon لمجموع المراتب واختبار Mann-Whitney

عندما نريد اختبار الفروق بين حالتين تم استخدام مشتركين مختلفين في كل منهما فإنه يمكننا تنفيذ أحد الاختبارين: اختبار Mann-Whitney واختبار Wilcoxon لمجموع المراتب. وهذه الاختبارات هي المكافئات اللابارامترية لاختبار t المستقل، وهما متكافئان.

على سبيل المثال، يقوم طبيب أمراض عصبية بتجربة للبحث عن الآثار المكدِّرة لنوع معين من أدوية تحديد النشاط. لذلك قام باختبار 20 شخصاً من رواد النوادي، فأعطى 10 منهم أقراصاً منشطة (Ecstasy) ليلة السبت، وسمح للباقين بشرب الكحول فقط. ثم قاسَ مستوى الكآبة باستخدام مؤشر BDI في اليوم التالي (يوم الأحد) وفي منتصف الأسبوع (يوم الأربعاء). يعرض الجدول 1.13 هذه البيانات.

رقم المشترك	المخدر	BDI (الأحد)	BDI (الأربعاء)
1	منشط	15	28
2	منشط	35	35
3	منشط	16	35
4	منشط	18	24
5	منشط	19	39
6	منشط	17	32
7	منشط	27	27
8	منشط	16	29
9	منشط	13	36
10	منشط	20	35
11	كحول	16	5
12	كحول	15	6
13	كحول	20	30
14	كحول	15	8
15	كحول	16	9
16	كحول	13	7
17	كحول	14	6
18	كحول	19	17
19	كحول	18	3
20	كحول	18	10

الجدول 1.13 البيانات لتجربة المخدر

1.2.13 نظرية

لنتخيل سيناريو لايكون فيه فرق في مستوى الكآبة بين المشتركين الذين تناولوا المنشط أو الكحول. إذا أردنا ترتيب البيانات من الأدنى إلى الأعلى بإهمال المجموعة التي ينتمي إليها المشترك (حيث نعطي العلامة الأدنى المرتبة 1، والعلامة الأعلى منها المرتبة 2 وهكذا) فماذا نتوقع أن نجد؟ إذا لم يكن هناك فرق بين المجموعات فإننا نتوقع أن نجد عدداً متماثلاً من المراتب العليا في كل مجموعة. وبالتحديد، إذا جمعنا المراتب فإننا نتوقع أن يكون المجموع الكلي للمراتب في المجموعة

الأولى مساوياً تقريباً للمجموع الكلي للمراتب في المجموعة الثانية. ماذا يحدث إذا كان هناك فرق بين المجموعات؟ لنتخيل أن مجموعة المنشط أكثر كآبة من مجموعة الكحول. وإذا رتبنا العلامات كما فعلنا سابقاً، فإننا نتوقع أن تكون المراتب العليا في مجموعة المنشط، وأن تكون المراتب الدنيا في مجموعة الكحول. وإذا جمعنا المراتب في كل مجموعة فإننا نتوقع أن يكون مجموع المراتب في مجموعة المنشط أعلى من مجموع المراتب في مجموعة الكحول.

يعمل اختبارا Mann-Whitney وWilcoxon لمجموع المراتب على هذا المبدأ. عندما يكون عدد المشتركين في المجموعات غير متساوٍ فإن إحصائية الاختبار (Ws) من أجل اختبار Wilcoxon لمجموع المراتب هي ببساطة مجموع المراتب في المجموعة التي تحوي أقل عدد من المشتركين، وعندما تكون المجموعات متساوية من حيث عدد المشتركين فإن إحصائية الاختبار (Ws) هي مجموع المراتب الأصغري. لنلقِ نظرة على آلية عملية الترتيب بشكل عملي.

يعرض الشكل 1.13 عملية الترتيب لبيانات يوم الأربعاء الموجودة في الجدول 1.13. نعيد ترتيب العلامات بشكل تصاعدي وذلك بعد أن نعطيها رمزاً يبين المجموعة التي تنتمي إليها (A مجموعة الكحول و E مجموعة المنشط) ثم نبدأ من العلامة الأدنى من العلامة الأدنى ونعطيها المرتبة المحتملة بدءاً من المرتبة 1. والسبب في التسمية "المرتبة المحتملة" هي أن بعض العلامات تتكرر عدة مرات في مجموعة البيانات (تحوي بيانات هذا المثال العلامة 6 مرتين، والعلامة 35 ثلاث مرات). لذلك تدعى المراتب التي تحتلها بالمراتب المتعادلة (tied ranks) لأن هذه العلامات يجب أن تحتل نفس المرتبة، وهكذا نقوم بحساب القيمة المتوسطة للمراتب المحتملة لهذه العلامات ونعين القيمة الناتجة كمرتبة فعلية لتلك العلامات. فمن أجل العلامة 6 كانت المراتب المحتملة هي 3 و4، نحسب القيمة المتوسطة ((3+4)/2=3.5) ونستخدمها كمرتبة من أجل التكرارين للعلامة 6. ومن أجل العلامة 35 كانت المراتب المحتملة هي 16 و17 و18، نحسب القيمة المتوسطة ((16+17+18)/3=17) ونستخدمها كمرتبة من أجل التكرارات الثلاثة للعلامة 35. بعد الانتهاء من ترتيب البيانات، نجمع المراتب لكل من المجموعتين. فمن أجل مجموعة الكحول تكون قيمة مجموع المراتب هي 59، أما مجموع المراتب لمجموعة المنشط فيبلغ 151. نأخذ القيمة الصغرى بين هذين المجموعين لتكون إحصائية الاختبار ليوم الأربعاء هي Ws=59.

بيانات يوم الأربعاء

العلامة	3	5	6	6	7	8	9	10	17	24	27	28	29	30	32	35	35	35	36	39
المرتبة	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
المرتبة الفعلية	1	2	3.5	3.5	5	6	7	8	9	10	11	12	13	14	15	17	17	17	19	20
المجموعة	A	A	A	A	A	A	A	A	A	E	E	E	E	A	E	E	E	E	E	E

مجموع المراتب لمجموعة الكحول (A) = 59 مجموع المراتب لمجموعة المنشط (E) = 151

الشكل 1.13 ترتيب علامات الكآبة ليوم الأربعاء

ننتقل الآن إلى بيانات يوم الأحد. يبين الشكل 2.13 عملية الترتيب والنتائج لبيانات يوم الأحد. إن مجموع المراتب لمجموع الكحول هو 90.5، ومجموع المراتب لمجموعة المنشط هو 119.5. نأخذ القيمة الصغرى بين هذين المجموعين لتكون إحصائية الاختبار ليوم الأحد هي W_s=90.5.

بيانات يوم الأحد

العلامة	13	13	14	15	15	15	16	16	16	16	17	18	18	18	19	19	20	20	27	35
المرتبة	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
المرتبة الفعلية	1.5	1.5	3	5	5	5	8.5	8.5	8.5	8.5	11	13	13	13	15.5	15.5	17.5	17.5	19	20
المجموعة	A	E	A	A	E	A	E	E	E	A	A	E	A	A	E	A	E	A	E	E

مجموع المراتب لمجموعة الكحول (A) = 90.5 مجموع المراتب لمجموعة المنشط (E) = 119.5

الشكل 2.13 ترتيب علامات الكآبة ليوم الأحد

المسألة التالية هي كيفية تحديد فيما إذا كانت إحصائية الاختبار ذات دلالة. يمكن حساب المتوسط ($\overline{W_s}$) والخطأ المعياري (SE_{Ws}) لإحصائية الاختبار W_s من حجم العينة لكل مجموعة (n_1 حجم العينة للمجموعة 1 و n_2 حجم العينة للمجموعة 2):

$$\overline{W_s} = \frac{n_1 \times (n_1 + n_2 + 1)}{2}$$

$$SE_{Ws} = \sqrt{\frac{n_1 \times n_2 \times (n_1 + n_2 + 1)}{12}}$$

إن حجم العينة في المجموعة 1 يساوي حجم العينة في المجموعة 2 ويساوي 10، لذلك نحصل على:

$$\overline{W_s} = \frac{10 \times (10 + 10 + 1)}{2} = 105$$

$$SE_{Ws} = \sqrt{\frac{10 \times 10 \times (10 + 10 + 1)}{12}} = 13.23$$

عندما نعلم قيمة إحصائية الاختبار، والمتوسط والخطأ المعياري لها فإنه يمكننا بسهولة تحويل إحصائية الاختبار إلى علامة z باستخدام المعادلة التي رأيناها في الفصل 1:

$$z = \frac{X - \overline{X}}{s} = \frac{W_S - \overline{W_S}}{SE_{Ws}}$$

وإذا حسبنا هذه القيمة لبيانات يومي الأحد والأربعاء فإننا نحصل على:

$$z_{Sunday} = \frac{W_s - \overline{W_s}}{SE_{Ws}} = \frac{90.5 - 105}{13.23} = 1.10$$

$$z_{Wednesday} = \frac{W_s - \overline{W_s}}{SE_{Ws}} = \frac{59 - 105}{13.23} = 3.48$$

إذا كانت القيمة أكبر من 1.96 (نأخذ القيم المطلقة) فإن إحصائية الاختبار ذات دلالة عند مستوى p<0.05. وهكذا نرى أن هناك فرقاً ذا دلالة بين المجموعات في يوم الأربعاء، ولكن الفرق بدون دلالة يوم الأحد.

إن الإجرائية التي قمنا بشرحها آنفاً هي اختبار Wilcoxon لمجموع المراتب. أما إجرائية Mann-Whitney فهي تعتمد على إحصائية الاختبار U، والتي يتم اشتقاقها بطريقة مشابهة لإجرائية Wilcoxon (هناك علاقة مباشرة بين الاثنتين). يتم حساب U باستخدام المعادلة التالية:

$$U = n_1 \times n_2 + \frac{n_1 \times (n_1 + 1)}{2} - R_1$$

حيث n_1 و n_2 حجم العينة في المجموعة 1 و2 على الترتيب، وR_1 مجموع المراتب للمجموعة 1. وهكذا نحصل على:

$$U_{Sunday} = 10 \times 10 + \frac{10 \times (10 + 1)}{2} - 119.50 = 35.50$$

$$U_{Wednesday} = 10 \times 10 + \frac{10 \times (10 + 1)}{2} - 151.00 = 4.00$$

يقوم برنامج SPSS بحساب الإحصائيتين وهناك علاقة مباشرة بينهما، لذلك يمكنك اختيار أي منهما.

2.2.13 إدخال البيانات والتحليل المؤقت

عند جمع البيانات باستخدام مشتركين مختلفين في كل مجموعة، علينا إدخال البيانات باستخدام متحول ترميز. لذلك سيحوي محرر البيانات ثلاثة أعمدة من البيانات. يحوي العمود الأول متحول الترميز (وندعوه drug) وسيأخذ في هذا المثال قيمتين فقط (1=مجموعة المنشط، 2=مجموعة الكحول). يحوي العمود الثاني قيم المتحول التابع (BDI) مقاساً في اليوم التالي للاختبار (وندعوه sunbdi). أما العمود الثالث فيحوي قيم المتحول التابع (BDI) مقاساً في يوم الأربعاء (وندعوه wedbdi).

عند إدخال البيانات في برنامج SPSS تذكر إدخال الرمز 1 لتمثيل مجموعة المنشط، والرمز 2 لتمثيل مجموعة الكحول (انظر الفقرة 4.4.2). ليست هناك توقعات محددة عن المخدر ذو الأثر الأكبر لذلك يجب أن يكون التحليل ثنائي الطرف. علينا أن نقوم أولاً بتحليل استكشافي للبيانات، وبما أننا سنبحث عن الفروق بين المجموعات فإن علينا تنفيذ التحليل الاستكشافي على كل مجموعة (انظر الفقرة 5.3 و 6.3). بعد تنفيذ هذه التحاليل نحصل على الجداول المبينة في الخرج 1.13. تبين هذا الجداول أن البيانات ليوم الأحد من أجل مجموعة المنشط D(10)=0.28, p<0.05 تبدو موزعة بشكل غير طبيعي، بينما لمجموعة الكحول D(10)=0.07, ns هي موزعة طبيعياً. ويمكننا أن نقول ذلك إذا كانت الدلالة لاختبارَي Shapiro-Wilk وK-S أصغر من 0.05 (ذو دلالة)، أو أكبر من

0.05 (بدون دلالة ns). أما بالنسبة لبيانات يوم الأربعاء، فعلى الرغم من أن بيانات مجموعة المنشط موزعة بشكل غير طبيعي D(10)=0.24, ns فإن بيانات مجموعة الكحول D(10)=0.31, p<0.01 تبدو موزعة بشكل غير طبيعي. وتحذرنا هذه النتيجة إلى حقيقة أنه يجب استخدام الاختبار اللابارامتري من أجل بيانات يومي الأحد والأربعاء وذلك لأن أحد المتحولات موزع بشكل غير طبيعي في كل منهما. يجب أن نلاحظ أن إحصائية Shapiro-Wilk تعطي نفس قيم الدلالة بينما يعطي اختبار K-S في بعض الأحيان تقديراً بقيمة 0.2 للدلالة (انظر بيانات يوم الأحد من أجل مجموعة الكحول) وذلك لأن برنامج SPSS لايستطيع حساب قيم الدلالة الدقيقة. وتشير هذه النتيجة لوجود فرق هام بين اختبار K-S واختبار Shapiro-Wilk، إذ أن اختبار Shapiro-Wilk أكثر دقة. يعرض الجدول الثاني في الخرج 1.13 نتائج اختبار Levene. فمن أجل يوم الأحد F(1,18)=3.64, ns ويوم الأربعاء F(1,18)=0.51, ns البيانات ليست مختلفة بشكل كبير، مما يدل على أن فرضية تجانس التباين محققة. ومع ذلك فإننا سنستخدم إجرائيات إحصائية لابارامترية مع بيانات يومي الأحد والأربعاء وذلك بسبب التوزيع غير الطبيعي للبيانات.

Tests of Normality

		Kolmogorov-Smirnov[a]			Shapiro-Wilk		
	Type of Drug	Statistic	df	Sig.	Statistic	df	Sig.
BDI (sunday)	Ecstasy	.276	10	.030	.811	10	.020
	Alcohol	.170	10	.200*	.959	10	.780
BDI (Wednesday)	Ecstasy	.235	10	.126	.941	10	.566
	Alcohol	.305	10	.009	.753	10	.004

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

Test of Homogeneity of Variance

		Levene Statistic	df1	df2	Sig.
BDI (sunday)	Based on Mean	3.644	1	18	.072
	Based on Median	1.880	1	18	.187
	Based on Median and with adjusted df	1.880	1	10.076	.200
	Based on trimmed mean	2.845	1	18	.109
BDI (Wednesday)	Based on Mean	.508	1	18	.485
	Based on Median	.091	1	18	.766
	Based on Median and with adjusted df	.091	1	11.868	.768
	Based on trimmed mean	.275	1	18	.606

الخرج 1.13

3.2.13 تنفيذ التحليل

نفتح مربع الحوار الرئيسي باستخدام أمر القائمة Analyze ⇒ Nonparametric Tests ⇒ 2 Independent Samples... (انظر الشكل 3.13). نختار المتحولين التابعين (sunbdi و wedbdi)

وننقلهما إلى الحيز المسمى Test Variable List. نختار بعد ذلك المتحول المستقل (متحول الترميز drug) وننقله إلى الحيز المسمى Grouping Variable. عند تحديد متحول الترميز يصبح الزر Define Groups... نشطاً ليسمح بتعريف المجموعات، ننقر هذا الزر لفتح مربع الحوار Define Groups. يحتاج برنامج SPSS لمعرفة الرموز العددية المحددة للمجموعتين، لذلك يحوي مربع الحوار فراغين لإدخال هذين الرمزين. في هذا المثال قمنا بترميز مجموعة المنشط بالرمز 1 ومجموعة الكحول بالرمز 2. ولذلك نكتب هذه القيم في الفراغات المناسبة. عند الانتهاء من تعريف المجموعات ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي. يوفر مربع الحوار الرئيسي أداة لتنفيذ اختبارات أخرى عدا اختبار Mann-Whitney، ويشرح المربع 1.13 هذه الاختبارات البديلة.

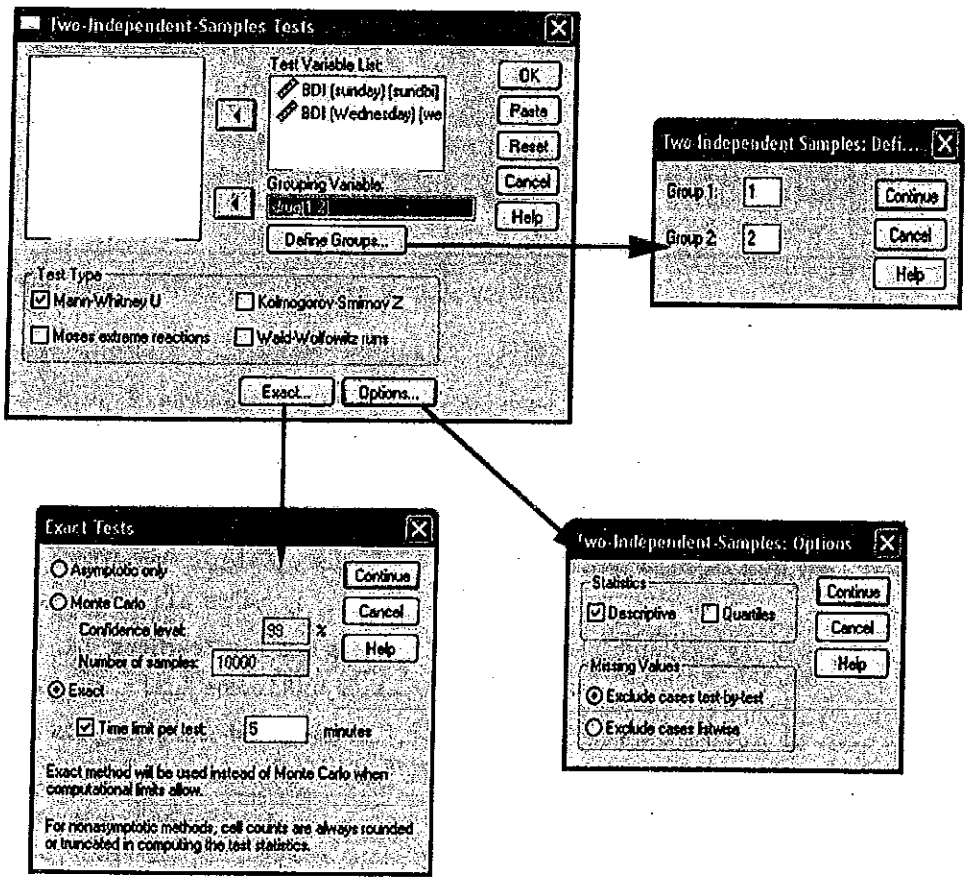

الشكل 3.13 مربعات الحوار من أجل اختبار Mann-Whitney

إذا نقرنا الزر Exact... يظهر مربع حوار آخر (يظهر هذا الزر إذا كانت الوحدة Exact tests لبرنامج SPSS مثبتة). يحسب برنامج SPSS بشكل افتراضي قيمة الدلالة لاختبار Mann-Whitney باستخدام طريقة تكون دقيقة إذا كان حجم العينة كبيراً (تدعى طريقة المُقارب (Asymptotic Method))،

ولكن عندما تكون العينات صغيرة أو البيانات موزعة بشكل ضعيف فإنه يجب استخدام طرق أكثر دقة. إن أكثر الطرق دقة هي استخدام اختبار Exact الذي يحسب قيمة الدلالة لاختبار Kruskal-Wallis بدقة. للحصول على هذه الدقة، هناك ثمن يجب دفعه، ونظراً لتعقيدات الحساب فقد يستغرق برنامج SPSS وقتاً أطول لإيجاد حل عندما تكون العينة كبيرة. هناك طريقة تتطلب جهداً أقل وهي تقدير الدلالة باستخدام طريقة مونت كارلو (Monte Carlo). ويتضمن ذلك إنشاء توزيع مشابه للتوزيع الموجود في العينة ثم أخذ عينات (العدد الافتراضي هو 10000) من هذا التوزيع، بعد ذلك يتم إنشاء قيمة الدلالة الوسطية ومجال الثقة حولها اعتماداً على هذه العينات. وهكذا إذا كانت العينة كبيرة يمكنك استخدام طريقة مونت كارلو، أما إذا كانت العينة صغيرة فيمكنك استخدام الاختبار الدقيق (وهذا ما طبقناه في هذا المثال). ننقر أخيراً الزر ...Options لفتح مربع الحوار الذي يسمح بضبط الخيارات للتحليل. وهذا الخيارات ليست مفيدة بشكل خاص، لأن الخيار الذي يعطي الإحصائيات الوصفية يتعامل مع مجموعة البيانات كاملة (لايقسمها حسب عناصر المجموعات). لهذا السبب ننصح بالحصول على الإحصائيات الوصفية باستخدام الطرق التي تعلمناها في الفقرات 4.3 و5.3. لتنفيذ التحليل نعود إلى مربع الحوار الرئيسي وننقر الزر OK.

المربع 1.13 الخيارات الأخرى لاختبار Mann-Whitney

يحوي مربع الحوار الرئيسي بعض الاختبارات الأخرى التي يمكن اختيارها:

- **اختبار Kolmogorov-Smirnov Z:** تعرفنا في الفصل 3 على اختبار Kolmogorov-Smirnov الذي يختبر فيما إذا كانت العينة من مجتمع موزع طبيعياً. إن هذا الاختبار مختلف، لأنه يختبر فيما إذا كان المجموعتان مأخوذتين من نفس المجتمع (بغض النظر عن ذلك المجتمع). وهذا يعني أنه يقوم بنفس عمل الاختبار Mann-Whitney. وعلى كل حال، يكون اختبار K-S أكثر قدرة من اختبار Mann-Whitney عندما يكون حجم العينة أصغر من 25 عنصراً في المجموعة، ولهذا يستحق أن نختاره في هذه الحالة.
- **اختبار Moses Extreme Reactions:** يقوم بمقارنة التغايرية للعلامات في المجموعتين، ولذلك فهو يشبه اختبار Levene اللابارامتري.
- **اختبار Wald-Wolfowitz:** وهو شكل آخر من الاختبار Mann-Whitney. ويتم فيه ترتيب العلامات كما في اختبار Mann-Whitney، ولكن بدلاً من تحليل المراتب فإنه يبحث عن سلاسل العلامات من نفس المجموعة ضمن ترتيب المراتب. إذا لم يكن هناك فرق بين المجموعات فإن المراتب من المجموعتين يجب أن تكون متداخلة بشكل عشوائي. أما إذا كانت المجموعتان مختلفتين فإننا يجب أن نرى مراتب أكثر من مجموعة ما في الطرف الأدنى، ومراتب أكثر من المجموعة الأخرى في الطرف الأعلى. وبالبحث عن تجمعات العلامات بهذه الطريقة يمكن للاختبار تحديد فيما إذا كانت المجموعتان مختلفتين.

4.2.13 الخرج لاختبار Mann-Whitney

لقد وضحنا في الفقرة 1.2.13 أن اختبار Mann-Whitney ينظر إلى الفروق في المواضع المرتّبة للعلامات في المجموعات المختلفة. لذلك فإن الجزء الأول من الخرج يلخص البيانات بعد ترتيبها. ويعطينا برنامج SPSS بشكل خاص القيمة المتوسطة للمراتب ومجموع المراتب في كل حالة (انظر الخرج 2.13). تذكّر أن اختبار Mann-Whitney يعتمد على العلامات المرتبة من الأدنى إلى الأعلى، لذلك فإن المجموعة ذات متوسط المرتبة الأولى هي المجموعة التي تحوي العدد الأكبر من العلامات الدنيا، والمجموعة ذات متوسط المرتبة الأعلى هي المجموعة التي تحوي العدد الأكبر من العلامات العليا. ولهذا يمكن استخدام الجدول الأولي للتحقق من المجموعة ذات العلامات الأعلى، وهذا مفيد في حالة الرغبة بتفسير نتيجة مهمة. يجب أن تلاحظ أن مجاميع المراتب هي نفس القيم التي تم حسابها في الفقرة 1.2.13.

Ranks

	Type of Drug	N	Mean Rank	Sum of Ranks
BDI (sunday)	Ecstasy	10	11.95	119.50
	Alcohol	10	9.05	90.50
	Total	20		
BDI (Wednesday)	Ecstasy	10	15.10	151.00
	Alcohol	10	5.90	59.00
	Total	20		

الخرج 2.13

يعرض الجدول الثاني (الخرج 3.13) إحصائيات الاختبار الفعلية لاختبار Mann-Whitney وإجرائية Wilcoxon وعلامات z الموافقة (انظر الفقرة 1.2.13). يحوي هذا الجدول عموداً لكل متحول (wedbdi وsunbdi) وفي كل عمود هناك قيمة الإحصائية U لاختبار Mann-Whitney، وقيمة الإحصائية لاختبار Wilcoxon وتقريب z المرتبط بها. لاحظ أن قيم U و W_s وعلامات z المرتبطة بهما مماثلة لما حسبناه في الفقرة 1.2.13.

Test Statistics[b]

	BDI (sunday)	BDI (Wednesday)
Mann-Whitney U	35.500	4.000
Wilcoxon W	90.500	59.000
Z	-1.105	-3.484
Asymp. Sig. (2-tailed)	.269	.000
Exact Sig. [2*(1-tailed Sig.)]	.280[a]	.000[a]

a. Not corrected for ties.

b. Grouping Variable: Type of Drug

الخرج 3.13

الجزء المهم في هذا الجدول هو قيمة الدلالة للاختبار، والذي يعطي الاحتمال ثنائي الطرف لتكون إحصائية الاختبار ناتجة بمحض الصدفة. يمكن استخدام قيمة الدلالة كما هي وذلك عند عدم وجود توقّع مسبق عن المجموعة المختلفة. أما إذا كان هناك توقّع ما (أي إذا قلنا أن مجموعة المنشط ستكون أكثر كآبة من مجموعة الكحول) فإن علينا حساب الاحتمال وحيد الطرف وذلك بتقسيم قيمة الدلالة على 2. من أجل هذه البيانات فإن اختبار Mann-Whitney عديم الدلالة من أجل علامات الكآبة ليوم الأحد. تدل هذه النتيجة على أن المنشط ليس أكثر تأثيراً من الكحول على الكآبة في اليوم التالي لتناوله، فمستويات الكآبة متقاربة في المجموعتين. أما من أجل بيانات يوم الأربعاء فإن النتائج عالية الدلالة ($p<0.001$). وتدل قيمة متوسط المراتب على أن مجموعة المنشط تتمتع بمستويات أعلى للكآبة من مجموعة الكحول. وقد تم التوصل إلى هذه النتيجة بملاحظة أن متوسط المراتب لعلامات يوم الأربعاء ومن أجل مجموعة المنشط (15.10) هي أعلى من المتوسط لمجموعة الكحول (5.90).

يعرض الخرج 4.13 الخرج لاختبار Mann-Whitney عند اختيار الدلالة الدقيقة. ويبين الجدول قيم الدلالة الدقيقة (وحيدة وثنائية الطرف). وهي لا تغير الخلاصة التي توصلنا إليها، ولكن احرص على العودة لهذه القيم خاصةً من أجل قيمة المقارب وعندما يكون حجم العينة صغيراً.

Test Statistics[b]

	BDI (sunday)	BDI (Wednesday)
Mann-Whitney U	35.500	4.000
Wilcoxon W	90.500	59.000
Z	-1.105	-3.484
Asymp. Sig. (2-tailed)	.269	.000
Exact Sig. [2*(1-tailed Sig.)]	.280[a]	.000[a]
Exact Sig. (2-tailed)	.289	.000
Exact Sig. (1-tailed)	.144	.000
Point Probability	.013	.000

a. Not corrected for ties.

b. Grouping Variable: Type of Drug

الخرج 4.13

5.2.13 حساب حجم الأثر

كما رأينا في هذا الكتاب فإن من المهم تقديم حجم الأثر بحيث يمكن للأشخاص الذين يملكون قياسات نظامية لحجم الأثر الذي تراقبه، أن يقارنوا النتائج مع نتائج دراساتهم. لا يحسب برنامج SPSS حجم الأثر، ولكن يمكننا حسابه بشكل تقريبي وبسهولة وذلك لأن برنامج SPSS يحوّل إحصائية الاختبار إلى علامة z. تقوم المعادلة التالية بتحويل علامة z إلى تقدير لحجم الأثر:

$$r = \frac{z}{\sqrt{N}}$$

حيث z هي علامة z التي يعطيها برنامج SPSS، وN عدد المشاهدات الكلي الذي تعتمد عليه z. يبين الخرج 3.13 أن قيمة z هي 1.11- من أجل بيانات يوم الأحد و 3.48- من أجل بيانات يوم الأربعاء. وفي كلتا الحالتين لدينا 10 مشتركين في مجموعة المنشط و10 مشتركين في مجموعة الكحول لذلك فإن N=20. وبذلك يكون حجم الأثر:

$$r_{Sunday} = \frac{-1.11}{\sqrt{20}} = -0.25$$

$$r_{Wednesday} = \frac{-3.48}{\sqrt{20}} = -0.78$$

وبذلك يتراوح حجم الأثر لبيانات يوم الأحد بين الصغير والمتوسط (لأنه أصغر من 0.3)، بينما يكون حجم الأثر لبيانات يوم الأربعاء هائلاً (أكبر من العتبة 0.5). أهم من ذلك أنه يبين بالنسبة لبيانات يوم الأحد كيف يمكن لحجم أثرٍ كبير أن يكون بلا دلالة في العينات الصغيرة.

6.2.13 كتابة النتائج

من أجل اختبار Mann-Whitney علينا أن نقدم إحصائية الاختبار U ودلالتها. ويمكننا طبعاً أن نقدم حجم الأثر. لذلك يمكننا أن نكتب النتائج بالشكل التالي:

- ✓ لا يبدو أن هناك اختلافاً بين متعاطي المنشط (Mdn=17.50) ومتناولي الكحول (Mdn=16.00) من حيث مستوى الكآبة في اليوم التالي لتناول المخدر، U=35.50, ns, r=0.25. ولكن في منتصف الأسبوع فإن متعاطي المنشط (Mdn=33.50) يعانون من كآبة أعلى من متناولي الكحول (Mdn=7.50)، U=4.00, p<0.001, r=0.78.

لاحظ أننا قدمنا قيمة الوسط (median) لكل حالة لأنها تناسب الاختبارات اللابارامترية أكثر من قيمة المتوسط (mean). ويمكننا أن نقدم أيضاً اختبار Wilcoxon بدلاً من إحصائية لاختبار Mann-Whitney وذلك بالشكل التالي:

- ✓ لا يبدو أن هناك اختلافاً بين متعاطي المنشط (Mdn=17.50) ومتناولي الكحول (Mdn=16.00) من حيث مستوى الكآبة في اليوم التالي لتناول المخدر، Ws=90.50, ns, r=0.25. ولكن في منتصف الأسبوع فإن متعاطي المنشط (Mdn=33.50) يعانون من كآبة أعلى من متناولي الكحول (Mdn=7.50)، Ws =59.00, p<0.001, r=0.78.

أفكار مهمة

- يقارن اختبار Mann-Whitney واختبار Wilcoxon لمجموع المراتب حالتين عندما يشترك مشتركون مختلفون في كل حالة تجريبية وتكون البيانات الناتجة موزعة بشكل غير طبيعي أو أنها تخرق فرضية اختبار t المستقل.

- ابحث عن الصف المسمى Asymp. Sig.(2-tailed) فإذا كانت القيمة أصغر من 0.05 فإن المتوسطين للمجموعتين مختلفان بشكل كبير (وإذا اخترت الاختبار الدقيق فابحث عن الصف المسمى Exact Sig.(2-tailed).
- ابحث عن قيم المراتب لمعرفة فيما إذا كانت المجموعتان مختلفتين (المجموعة ذات العلامات الأعلى ستملك المراتب الأعلى).
- يقدم SPSS قيمة الدلالة ثنائية الطرف فقط، إذا أردت قيمة الدلالة وحيدة الطرف فعليك تقسيم تلك القيمة على 2، أما إذا اخترت الاختبار الدقيق فابحث عن الصف المسمى Exact Sig.(1-tailed).
- اكتب قيم الإحصائية U (أو Ws إذا كنت تفضل ذلك)، وقيم z الموافقة. وكذلك قيم الوسط ومجالاتها الموافقة.
- عليك أيضاً حساب حجم الأثر وتقديمه ضمن النتائج.

المربع 2.13 الاختبارات اللابارامترية والقدرة الإحصائية

يعتبر ترتيب البيانات طريقة مفيدة للالتفاف على الفرضيات التوزيعية للاختبارات البارامترية، ولكن الثمن هو فقدان بعض المعلومات حول مطال الفرق بين العلامات. والنتيجة هي أن الاختبارات اللابارامترية يمكن أن تكون أقل قدرة من نظيراتها البارامترية. وقد أدخلنا مفهوم القدرة الإحصائية في الفقرة 5.8.1 وتعني قدرة الاختبار على إيجاد أثر موجود فعلياً. لذلك عندما نقول أن الاختبارات اللابارامترية هي أقل قدرة فإننا نعني أنه إذا كان هناك أثر حقيقي في البيانات، فإنه من المرجح أن يكون الاختبار البارامتري أكثر قدرة على اكتشافه من الاختبار اللابارامتري. إن هذه العبارة صحيحة فقط إذا كانت فرضيات الاختبار البارامتري محققة. لذلك إذا استخدمنا اختباراً بارامترياً واختباراً لابارامترياً على نفس البيانات وكانت هذه البيانات موزعة طبيعياً فإن قدرة الاختبار البارامتري على اكتشاف الأثر هي أكبر من قدرة الاختبار اللابارامتري.

المشكلة أنه لتعريف القدرة لاختبار ما علينا أن نتأكد من أنه يتحكم بمعدل الخطأ من النوع الأول (عدد المرات يجد بها الاختبار أثراً مهماً عندما لايكون هناك أثر حقيقي ، انظر الفقرة 2.8.1). وقد رأينا في الفصل 1 مقولة Fisher حول ضرورة أن يكون معدل الخطأ من النوع الأول هو 5%. ونعلم أنه عندما تكون البيانات موزعة طبيعياً فإن معدل الخطأ من النوع الأول للاختبارات المستندة إلى هذا التوزيع هو 5% بالتأكيد، لذلك يمكننا أن نجد القدرة. على كل حال، عندما تكون البيانات موزعة بشكل غير طبيعي فإن معدل الخطأ من النوع الأول للاختبارات المستندة إلى هذا التوزيع لن يكون 5% (ولا نعرف قيمته لأنها تعتمد على شكل التوزيع) ولذلك لاتوجد طريقة لحساب القدرة (لأن القدرة مرتبطة بمعدل الخطأ من النوع الأول، انظر الفقرة 5.8.1). لذلك وعلى الرغم من أننا نسمع أن للاختبارات اللابارامترية حظاً أوفر من الخطأ من النوع الثاني (حظاً أكبر في قبول عدم وجود فرق بين المجموعات، بينما هناك فرق حقيقي بينها)، وهذا صحيح فقط عندما تكون البيانات موزعة طبيعياً.

3.13 مقارنة حالتين مرتبطتين: اختبار Wilcoxon للمرتبة ذات الإشارة

يُستخدم اختبار Wilcoxon للمرتبة ذات الإشارة (Wilcoxon Signed-Rank test) عند مقارنة مجموعتين من البيانات مأخوذتان من نفس المشتركين. وبذلك فهو المكافئ اللابارامتري لاختبار t التابع (أو اختبار Mann-Whitney لبيانات القياسات المكررة). تخيل أن الباحث في المثال السابق يهتم الآن بالتغير في مستويات الكآبة لكل شخص في المجموعتين. سنقوم الآن بمقارنة علامات BDI ليوم الأحد مع علامات BDI ليوم الأربعاء. علينا استخدام الاختبار اللابارامتري لأن توزيع البيانات لكلا المخدرين هو غير طبيعي في أحد اليومين (انظر الخرج 1.13).

1.3.13 نظرية اختبار Wilcoxon للمرتبة ذات الإشارة

يعمل اختبار Wilcoxon للمرتبة ذات الإشارة بطريقة مشابهة لاختبار t التابع (انظر الفصل 7) من حيث أنه يعتمد على الفروق بين العلامات في الحالتين التجريبيتين اللتين تتم مقارنتهما. بعد حساب هذه الفروق يتم ترتيبها (كما في الفقرة 1.2.13) ولكن يتم إعطاء إشارة الفرق (موجبة أو سالبة) للمرتبة. فإذا استخدمنا نفس البيانات في المثال السابق فإننا نستطيع مقارنة علامات الكآبة ليوم الأحد مع علامات الكآبة ليوم الأربعاء لكل من المجموعتين بشكل منفصل.

يعرض الجدول 2.13 ترتيب هذه البيانات. تذكر أننا نقوم بترتيب المجموعتين بشكل منفصل. نحسب أولاً الفرق بين علامات يوم الأحد ويوم الأربعاء. فإذا كان الفرق يساوي 0 فإننا نستثني البيانات المعنية من الترتيب، ونضع إشارة الفرق في عمود مستقل، ثم نقوم بترتيب الفروق بدءاً من القيمة الصغرى وبإهمال إشارتها (أي نأخذ القيمة المطلقة للفرق). نتعامل مع العلامات المتعادلة بنفس الطريقة التي اتبعناها في الفقرة 1.2.13. وأخيراً نجمع المراتب التي تأتي من الفروق الموجبة بين الحالتين (T_+) كما نقوم بجمع المراتب التي تأتي من الفروق السالبة بين الحالتين ونحصل على مجموع المراتب السالبة (T_-). فمن أجل مجموعة المنشط لدينا $T_+=36$ و$T_-=0$ (لاتوجد مراتب سالبة)، ومن أجل مجموعة الكحول لدينا $T_+=8$ و$T_-=47$. وتكون إحصائية الاختبار T هي القيمة الأصغر بين القيمتين T_- و T_+ لكل من المجموعتين وبذلك تكون $T=0$ لمجموعة المنشط، و$T=8$ لمجموعة الكحول.

لحساب الدلالة لإحصائية الاختبار (T)، فإننا نحسب قيمة المتوسط ($\overline{T}$) والخطأ المعياري (SE_T) من العلاقات التالية:

$$\overline{T} = \frac{n \times (n+1)}{4}$$

$$SE_T = \sqrt{\frac{n \times (n+1) \times (2n+1)}{24}}$$

BDI (الأحد)	BDI (الأربعاء)	الفرق	الإشارة	المرتبة	المراتب الموجبة	المراتب السالبة
			مجموعة المنشط			
15	28	13	+	2.5	2.5	
35	35	0	مستثناة			
16	35	19	+	6	6	
18	24	6	+	1	1	
19	39	20	+	7	7	
17	32	15	+	4.5	4.5	
27	27	0	مستثناة			
16	29	13	+	2.5	2.5	
13	36	23	+	8	8	
20	35	15	+	4.5	4.5	
				المجموع	**36**	**0**
			مجموعة الكحول			
16	5	-11	-	9		9
15	6	-9	-	7		7
20	30	10	+	6	8	
15	8	-7	-	3.5		3.5
16	9	-7	-	3.5		3.5
13	7	-6	-	2		2
14	6	-8	-	5.5		5.5
19	17	-2	-	1		1
18	3	-15	-	10		10
18	10	-8	-	5.5		5.5
				المجموع	**8**	**47**

الجدول 2.13 ترتيب البيانات من أجل اختبار Wilcoxon للمرتبة ذات الإشارة

حيث n حجم العينة (ولأننا نستخدم نفس المشتركين فإن هناك حجم عينة وحيد). ومن أجل المجموعتين n=10، ولكن في مجموعة المنشط تم استثناء مشتركين اثنين لأن الفرق كان 0، لذلك فإن حجم العينة لمجموعة المنشط هو 8 وليس 10، وهذا يعطينا:

$$\bar{T}_{Ecstasy} = \frac{8 \times (8+1)}{4} = 18$$

$$SE_{T\,Ecstasy} = \sqrt{\frac{8 \times (8+1) \times (16+1)}{24}} = 7.14$$

ومن أجل مجموعة الكحول n=10:

$$\bar{T}_{Alcohol} = \frac{10 \times (10+1)}{4} = 27.50$$

$$SE_{T\ Alcohol} = \sqrt{\frac{10 \times (10+1) \times (20+1)}{24}} = 9.81$$

وهكذا يمكننا تحويل إحصائية الاختبار إلى علامة z بمعرفة قيمة المتوسط والانحراف المعياري وباستخدام العلاقة التي رأيناها في الفصل 1 واستخدمناها في الفقرة السابقة:

$$z = \frac{X - \bar{X}}{s} = \frac{T - \bar{T}}{SE_T}$$

وإذا حسبنا هذه القيمة للمجموعتين فإننا نحصل على:

$$z_{Ecstasy} = \frac{0 - 18}{7.14} = -2.52$$

$$z_{Alcohol} = \frac{8 - 27.5}{9.81} = -1.99$$

إذا كانت هذه القيم أكبر من 1.96 (بإهمال الإشارة السالبة) فإنها تكون ذات دلالة عند مستوى $p<0.05$. لذلك يبدو أن هناك فرقاً مهماً في علامات الكآبة بين يومي الأحد والأربعاء ومن أجل كلتا المجموعتان.

2.3.13 تنفيذ التحليل

لإجراء نفس التحليل في برنامج SPSS يمكننا استخدام البيانات السابقة، ولكن بما أننا نريد النظر إلى التغير لكل مخدر على حدا، فإننا نستخدم التعليمة Split file ونطلب من برنامج SPSS تقسيم الملف بالمتحول drug. تضمن هذه العملية تنفيذ عمليات التحليل اللاحقة على كل من المجموعتين بشكل منفصل. بعد تقسيم الملف نفتح مربع الحوار الرئيسي باستخدام أمر القائمة Analyze ⇒ Nonparametric Tests ⇒ 2 Related Samples... (انظر الشكل 4.13). يسمح مربع الحوار الرئيسي باختيار اختبارات أخرى أيضاً (انظر المربع 3.13).

بعد فتح مربع الحوار، نختار المتحول sunbdi ليكون المتحول Variable 1 في الحيز المسمى Current Selections، والمتحول wedbdi ليكون المتحول Variable 2. وننقل هذين المتحولين إلى الحيز المسمى Test Pair(s) List. إذا أردنا تنفيذ عدة اختبارات Wilcoxon فيمكننا اختيار أزواج أخرى من المتحولات ونقلها إلى لائحة المتحولات. في هذا المثال نريد تنفيذ اختبار واحد فقط. إذا نقرنا الزر...Exact فإننا نحصل على مربع حوار جديد يسمح بتحديد الخيارات لحساب قيم الدلالة الدقيقة (انظر الفقرة 3.2.13). ونكرر هنا ما قلناه سابقاً حول استخدام طريقة مونت كارلو من أجل العينات كبيرة الحجم، واختيار الاختبار الدقيق من أجل العينات الصغيرة. ولكننا لم نعتمد أي منهما في هذا المثال. إذا نقرنا الزر...Options فإننا نحصل على مربع حوار جديد يسمح باختيار

الإحصائيات الوصفية. وبعكس اختبار Mann-Whitney فإنه من المفضل تحديد الإحصائيات الوصفية لأن التغير عبر المتحولات (الأعمدة في محرر البيانات) هو المهم. لتنفيذ التحليل، نعود إلى مربع الحوار الرئيسي وننقر الزر OK.

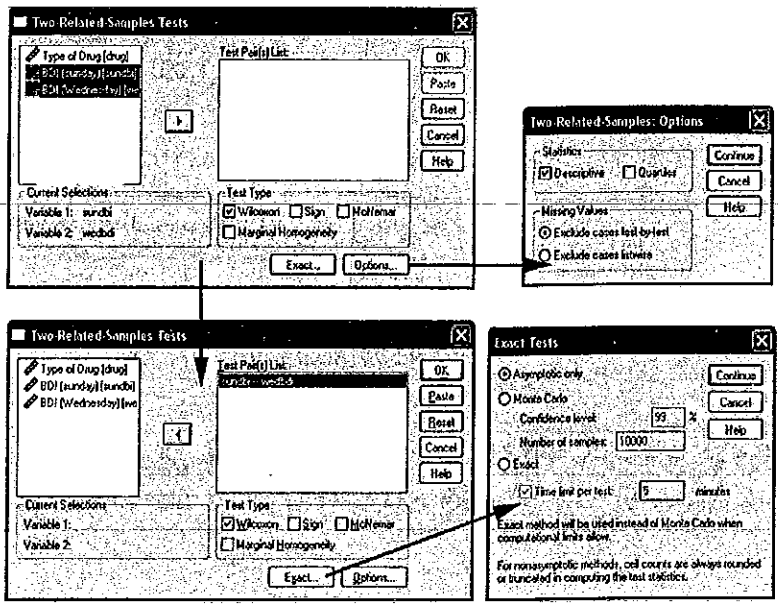

الشكل 4.13 مربعات الحوار لاختبار Wilcoxon للمرتبة ذات الإشارة

المربع 3.13 الخيارات الأخرى لاختبار Wilcoxon للمرتبة ذات الإشارة

يحوي مربع الحوار Options بعض الاختبارات الأخرى التي يمكن اختيارها:

- **اختبار الإشارة (Sign):** يقوم اختبار الإشارة بنفس ما يقوم به اختبار Wilcoxon للمرتبة ذات الإشارة، باستثناء أنه يعتمد على اتجاه الفرق فقط (سالب أو موجب)، ويهمل مطال الفرق بشكل تام (بعكس اختبار Wilcoxon حيث تدلنا المرتبة عن المطال النسبي للتغير). ولهذه الأسباب يفتقد اختبار الإشارة للقدرة (ليس قوياً في اكتشاف الآثار) ما لم يكن حجم العينة صغيراً جداً (≤6).
- **اختبار (McNemar):** وهذا الاختبار مفيد عندما تكون البيانات اسمية (nomial) وليست تراتبية (Ordinal). ويستخدم عادة عند البحث عن التغير في علامات الأشخاص ويقارن عدد الذين تغيرت استجاباتهم في اتجاه ما (أي أن علاماتهم ازدادت مثلاً) مع عدد الأشخاص الذين تغيرت استجاباتهم في الاتجاه الآخر (أي أن علاماتهم انخفضت). لذلك يجب استخدام هذا الاختبار عندما يكون لدينا متحولان ثنائيان مرتبطان.
- **إحرائية التجانس الهامشي (Marginal Homogeneity):** وهي توسيع لاختبار McNemar من أجل المتحولات التراتبية. وتقوم بنفس عمل اختبار Wilcoxon تقريباً.

3.3.13 الخرج لمجموعة المنشط

بعد تقسيم الملف، تكون المجموعة الأولى من النتائج خاصة بمجموعة المنشط (انظر الخرج 5.13). يعطي الجدول الأول معلومات عن العلامات المرتبة. ويدلنا على عدد المراتب السالبة (عدد الأشخاص الذين كانت علاماتهم ليوم الأحد أكبر من علامة يوم الأربعاء) وعدد المراتب الموجبة (عدد الأشخاص الذين كانت لديهم علامتهم ليوم الأربعاء أكبر من علامة يوم الأحد). يبين الجدول أن 8 مشتركين من أصل 10 كانت علامتهم ليوم الأربعاء أعلى من علامة يوم الأحد، مما يدل على أن الكآبة في منتصف الأسبوع أعلى منها في اليوم التالي لتناول المنشط. وكانت هناك مرتبتان متعادلتان (للمشترك نفس العلامة في يومي الأحد والأربعاء). كما يبين الجدول العدد المتوسط لكل من المراتب السالبة والمراتب الموجبة ومجموع المراتب السالبة ومجموع المراتب الموجبة. لقد أوضحنا في الفقرة 1.3.13 أن إحصائية الاختبار T هي القيمة الدنيا بين نوعَي المراتب، لذلك تكون قيمة الاختبار هنا هي مجموع المراتب السالبة (أي 0). كما عرضنا كيفية تحويل هذه القيمة إلى علامة z وهذا ما قام به برنامج SPSS. إن ميزة هذا الحل هي أنه يسمح بحساب القيمة الدقيقة للدلالة اعتماداً على التوزيع الطبيعي.

Ranks[d]

		N	Mean Rank	Sum of Ranks
BDI (Wednesday) - BDI (sunday)	Negative Ranks	0[a]	.00	.00
	Positive Ranks	8[b]	4.50	36.00
	Ties	2[c]		
	Total	10		

a. BDI (Wednesday) < BDI (sunday)

b. BDI (Wednesday) > BDI (sunday)

c. BDI (Wednesday) = BDI (sunday)

d. Type of Drug = Ecstasy

Test Statistics[b,c]

	BDI (Wednesday) - BDI (sunday)
Z	-2.527[a]
Asymp. Sig. (2-tailed)	.012

a. Based on negative ranks.

b. Wilcoxon Signed Ranks Test

c. Type of Drug = Ecstasy

الخرج 5.13

أما الجدول الثاني في الخرج 5.13 فيدلنا على أن إحصائية الاختبار مبنية على المراتب السالبة، وأن علامة z هي 2.53- (وهي القيمة المحسوبة في الفقرة 1.3.13) وأن هذه القيمة ذات دلالة عند مستوى p=0.012. لذلك وبما أن هذه القيمة معتمدة على المراتب السالبة (ولأن إحصائية الاختبار

هي الأصغر بين المراتب الموجبة والسالبة فإن معظم المراتب يجب أن تكون موجبة) فيجب علينا أن نستنتج أنه عند تناول المنشط فإن هناك زيادة ملحوظة في الكآبة (كما تقيسها علامات BDI) من صباح اليوم التالي لتناول المنشط إلى منتصف الأسبوع. إذا كانت إحصائية الاختبار معتمدة على المراتب الموجبة فإن ذلك سيدلنا على أن النتائج هي في الاتجاه المعاكس (أي أن علامات BDI كانت في صباح اليوم التالي لتناول المنشط أكبر منها في منتصف الأسبوع). ولذلك يمكننا أن نستنتج أن متعاطي المنشط يعانون من زيادة في مستوى الكآبة اعتباراً من اليوم التالي إلى منتصف الأسبوع ($z=-2.53, p<0.05$).

4.3.13 الخرج لمجموعة الكحول

يحوي القسم الباقي من الخرج نفس الجدولين السابقين ولكن من أجل مجموعة الكحول (انظر الخرج 6.13). يعطي الجدول الأول معلومات عن العلامات المرتبة. ويدلنا على عدد المراتب السالبة (عدد الأشخاص الذين كانت علامتهم ليوم الأحد أكبر من علامة يوم الأربعاء) وعدد المراتب الموجبة (عدد الأشخاص الذين علامتهم ليوم الأربعاء أكبر من علامة يوم الأحد). يبين الجدول أن 9 مشتركين من أصل 10 كانت علاماتهم ليوم الأحد أعلى من علامة يوم الأربعاء، مما يدل على أن الكآبة في اليوم التالي لتناول المنشط أعلى منها في منتصف الأسبوع. ولا توجد في هذه المجموعة مراتب متعادلة . كما يبين الجدول العدد المتوسط لكل من المراتب السالبة والمراتب الموجبة ومجموع المراتب السالبة ومجموع المراتب الموجبة. وقد تم تحويل القيمة الأدنى (وهي 8) إلى علامة z.

Ranks[d]

		N	Mean Rank	Sum of Ranks
BDI (Wednesday) - BDI (sunday)	Negative Ranks	9[a]	5.22	47.00
	Positive Ranks	1[b]	8.00	8.00
	Ties	0[c]		
	Total	10		

a. BDI (Wednesday) < BDI (sunday)

b. BDI (Wednesday) > BDI (sunday)

c. BDI (Wednesday) = BDI (sunday)

d. Type of Drug = Alcohol

Test Statistics[b,c]

	BDI (Wednesday) - BDI (sunday)
Z	-1.990[a]
Asymp. Sig. (2-tailed)	.047

a. Based on positive ranks.

b. Wilcoxon Signed Ranks Test

c. Type of Drug = Alcohol

الخرج 6.13

أما الجدول الثاني في الخرج 6.13 فيدلنا على أن إحصائية الاختبار مبينة على المراتب الموجبة، وأن علامة z تساوي 1.99- (وهي القيمة المحسوبة في الفقرة 1.3.13) وأن هذه القيمة ذات دلالة عند مستوى p=0.047. لذلك علينا أن نستنتج أنه عند تناول الكحول (واعتماداً على استخدام المراتب الموجبة) فإن هناك انخفاضاً ملحوظاً في الكآبة (كما تقيسها علامات BDI) من صباح اليوم التالي لتناول الكحول إلى منتصف الأسبوع، (z=-1.99, p<0.05).

نلاحظ من نتائج المجموعتين المختلفتين أن هناك أثراً عكسياً عند تناول الكحول مقارنة بتناول المنشط. إذ أن الكحول يسبب كآبة في اليوم التالي لتناوله، ولكنها تنخفض مع الوصول إلى منتصف الأسبوع. أما المنشط فيسبب بعض الكآبة في اليوم التالي لتناوله، ولكنها تزداد مع الوصول إلى منتصف الأسبوع. ولمعرفة الأثر الحقيقي صباح اليوم التالي علينا إجراء القياسات قبل إعطاء المنشط والكحول. ويُعرف هذا الأثر المتعاكس بين مجموعات الناس بالتفاعل (أي الحصول على أثر ما في ظروف معينة، والحصول على أثر مختلف في ظروف أخرى) وقد تعاملنا مع ذلك في الفصول 10 و11 و12.

5.3.13 حساب حجم الأثر

يمكن حساب حجم الأثر بنفس الطريقة المتبعة في اختبار Mann-Whitney (انظر المعادلة في الفقرة 5.2.13). في هذه الحالة يعطينا الخرج 6.13 قيمة العلامة z لمجموعة المنشط وهي 2.53- ولمجموعة الكحول وهي 1.99-. وفي كلتا الحالتين هناك 20 مشاهدة (لأننا نستخدم 10 مشتركين، ولكننا نختبرهم مرتين، ولذلك فإن عدد المشاهدات هو المهم وليس عدد الأشخاص). لذلك يكون حجم الأثر:

$$r_{Ecstasy} = \frac{-2.53}{\sqrt{20}} = -0.57$$

$$r_{Alcohol} = \frac{-1.99}{\sqrt{20}} = -0.44$$

ويمثل ذلك تغيراً كبيراً في مستويات الكآبة عند تناول المنشط (أعلى من معيار Cohen البالغ 0.5)، وتغيراً يتراوح بين المتوسط والكبير في مستويات الكآبة عند تناول الكحول (بين المعيارين 0.3 للأثر المتوسط و0.5 للأثر الكبير).

6.3.13 كتابة النتائج وتفسيرها

في حالة اختبار Wilcoxon علينا تقديم إحصائية الاختبار فقط (التي تأخذ الرمز T وتمثل القيمة الأصغر بين مجموعي المراتب) مع قيمة دلالتها وحجم الأثر. لذلك يكون تقديم النتائج بالشكل التالي:

- ✓ في حالة متعاطي المنشط، كانت مستويات الكآبة في يوم الأربعاء (Mdn=33.50) أعلى بكثير منها في يوم الأحد (Mdn=17.50)، T=0, p<0.05, r=-0.57. أما في حالة متناولي الكحول فالعكس هو الصحيح، إذ أن مستويات الكآبة في يوم الأربعاء (Mdn=7.50) كانت أدنى بكثير منها في الأحد (Mdn=16.0)، T=8, p<0.05, r=-0.44.

أو يمكننا تقديم قيم z بدلاً من ذلك:

- ✓ في حالة متعاطي المنشط، كانت مستويات الكآبة في يوم الأربعاء (Mdn=33.50) أعلى بكثير منها في يوم الأحد (Mdn=17.50)، z=-2.53, p<0.05, r=-0.57. أما في حالة متناولي الكحول فإن العكس هو الصحيح، إذ أن مستويات الكآبة في يوم الأربعاء (Mdn=7.50) كانت أدنى منها بكثير منها في يوم الأحد (Mdn=16.0), z=-1.99, p<0.05, r=-0.44.

أفكار مهمة

- يقارن اختبار Wilcoxon للمرتبة ذات الإشارة حالتين تجريبيتين عندما يشارك نفس الأشخاص في كلتا الحالتين و عندما تكون النتائج موزعة بشكل غير طبيعي أو أنها تخرق فرضية اختبار t التابع.
- انظر إلى الصف المسمى Asymp. Sig.(2-tailed) فإذا كانت القيمة أصغر من 0.05 فإن المجموعتين مختلفتان.
- انظر إلى المراتب الموجبة والسالبة (والحواشي الموجودة تحت الجدول التي تشرح معناها) لمعرفة المجموعة المختلفة (العدد الأكبر من المراتب في اتجاه معين يدلك على اتجاه النتيجة).
- يعطي برنامج SPSS قيمة الدلالة ثنائية الطرف (كما في العديد من الاختبارات)، وإذا أردت الحصول على قيمة الدلالة وحيدة الطرف فعليك تقسيم تلك القيمة على 2.
- اكتب قيمة الإحصائية T أو العلامة z الموافقة، مع قيمة الدلالة وحجم الأثر إذا كان ذلك ممكناً. واكتب قيمة الوسط ومجاله الموافق.

4.13 الفروق بين عدة مجموعات مستقلة: اختبار Kruskal-Wallis

اكتشفنا في الفصل 8 تقنية تدعى ANOVA وحيدة الاتجاه المستقلة التي يمكن استخدامها لاختبار الفرق بين عدة مجموعات مستقلة. وذكرنا في ذلك الفصل أن ANOVA متماسكة ومقاومة لخرق فرضياتها. كما رأينا أن هناك بعض الإجراءات التي يمكن اتخاذها عندما تكون التباينات غير متجانسة (المربع 3.8). على كل حال، هناك طريقة بديلة إذ يوجد اختبار لابارامتري مكافئ لتقنية ANOVA وحيدة الاتجاه المستقلة وهو اختبار Kruskal-Wallis. فإذا كانت البيانات موزعة بشكل غير طبيعي أو أنها تخرق بعض الفرضيات الأخرى فيمكننا استخدام هذا الاختبار كطريقة مفيدة في حل المشكلة.

نشرت إحدى الصحف مقالة يدّعي كاتبها أن العلماء اكتشفوا أن مادة كيميائية موجودة في الصويا بشكل طبيعي ترتبط بانخفاض عدد الحيوانات المنوية عند الذكور في الغرب. وعند قراءة المقالة يتضح أن الدراسة قد تمت على الفئران، ولم تجد رابطاً مع تخفيض عدد الحيوانات المنوية، ولكن كان هناك دليل على تطور جنسي غير طبيعي عند ذكور الفئران (ربما لأن هذه المادة الكيميائية تعمل كهرمون الاستروجين). وقد فسر الصحفي ذلك على أنه ارتباط واضح مع انخفاض عدد الحيوانات المنوية في الذكور. لذلك قام أحد الباحثين باختبار هذه الفكرة على البشر بدلاً من الفئران. لذلك جمع 80 ذكراً وقسمهم إلى 4 مجموعات تختلف بعدد وجبات الصويا التي تتناولها في الأسبوع على مدار عام كامل. المجموعة الأولى هي مجموعة المراقبة ولا يتناول عناصرها أي وجبة صويا في الأسبوع (أي 0 وجبة خلال عام كامل). يتناول عناصر المجموعة الثانية وجبة صويا واحدة في الأسبوع (أي 52 وجبة خلال العام). ويتناول عناصر المجموعة الثالثة 4 وجبات صويا في الأسبوع (أي 208 وجبات خلال العام)، بينما يتناول عناصر المجموعة الرابعة 7 وجبات صويا في الأسبوع (أي 364 وجبة خلال العام). وفي نهاية العام تم أخذ عينات من السائل المنوي لكل مشترك وتحليل هذه العينات لمعرفة عدد الحيوانات المنوية.

1.4.13 نظرية اختبار Kruskal-Wallis

إن نظرية Kruskal-Wallis مشابهة جداً لنظرية اختبار Mann-Whitney، ولذلك ننصح بقراءة الفقرة 1.2.13 قبل المتابعة. يعتمد اختبار Kruskal-Wallis على البيانات المرتبة. ولهذا نبدأ بترتيب العلامات من العلامة الأدنى إلى العلامة الأعلى مع إهمال المجموعة التي تنتمي لها العلامة، ثم نعطي العلامة الأدنى المرتبة 1 والعلامة الأعلى منها مباشرة المرتبة 2 وهلم جرا (انظر الفقرة 1.2.13 لمزيد من التفاصيل). بعد الانتهاء من ترتيب البيانات تتم إعادتها لمجموعاتها ونقوم بجمع المراتب في كل مجموعة. تتم تسمية مجموع المراتب في كل مجموعة Ri (حيث i يدل على المجموعة). يبين الجدول 3.13 البيانات لهذا المثال مع مراتبها.

0 وجبة		وجبة واحدة		4 وجبات		7 وجبات	
عدد الحيوانات المنوية (مليون)	المرتبة	عدد الحيوانات المنوية (مليون)	المرتبة	عدد الحيوانات المنوية (مليون)	المرتبة	عدد الحيوانات المنوية (مليون)	المرتبة
0.35	4	0.33	3	0.40	6	0.31	1
0.58	9	0.36	5	0.60	10	0.32	2
0.88	17	0.63	11	0.96	19	0.56	7
0.92	18	0.64	12	1.20	21	0.57	8
1.22	22	0.77	14	1.31	24	0.71	13
1.51	30	1.53	32	1.35	27	0.81	15
1.52	31	1.62	34	1.68	35	0.87	16
1.57	33	1.71	36	1.83	37	1.18	20

0 وجبة		وجبة واحدة		4 وجبات		7 وجبات	
عدد الحيوانات المنوية (مليون)	المرتبة	عدد الحيوانات المنوية (مليون)	المرتبة	عدد الحيوانات المنوية (مليون)	المرتبة	عدد الحيوانات المنوية (مليون)	المرتبة
2.43	41	1.94	38	2.10	40	1.25	23
2.79	46	2.48	42	2.93	48	1.33	25
3.40	55	2.71	44	2.96	49	1.34	26
4.52	59	4.12	57	3.00	50	1.49	28
4.72	60	5.65	61	3.09	52	1.50	29
6.90	65	6.76	64	3.36	54	2.09	39
7.58	68	7.08	66	4.34	58	2.70	43
7.78	69	7.26	67	5.81	62	2.75	45
9.62	72	7.92	70	5.94	63	2.83	47
10.05	73	8.04	71	10.16	74	3.07	51
10.32	75	12.10	77	10.98	76	3.28	53
21.08	80	18.47	79	18.21	78	4.11	56
المجموع R_i	**927**		**883**		**883**		**927**

الجدول 3.13 البيانات لمثال الصويا مع المراتب

بعد الانتهاء من حساب مجموع المراتب لكل مجموعة يتم حساب إحصائية الاختبار H من المعادلة التالية:

$$H = \left[\frac{12}{N(N+1)}\sum_{i=1}^{k}\frac{R_i^2}{n_i}\right] - 3(N+1) \qquad (1.13)$$

يمثل R_i مجموع المراتب في المجموعة i، و N حجم العينة الكلي (N=80)، وn_i حجم العينة للمجموعة i (20 لأن المجموعات متساوية الحجم). وبذلك يمكننا حساب H :

$$H = \left[\frac{12}{80\times(80+1)}\left(\frac{927^2}{20}+\frac{883^2}{20}+\frac{883^2}{20}+\frac{547^2}{20}\right)\right] - 3\times(80+1)$$

$$H = 8.659$$

ولإحصائية الاختبار H نوع خاص من التوزيع يعرف بتوزيع كاي مربع (انظر الفصل 16)، ولهذا التوزيع قيمة واحدة لدرجات الحرية هي k-1 ، وفي هذا المثال 3=1-4 .

2.4.13 إدخال البيانات والتحليل المؤقت

عند جمع البيانات باستخدام مشتركين مختلفين في كل مجموعة، فإننا ندخل البيانات باستخدام متحول ترميز. لذلك يحوي محرر البيانات عمودين من البيانات، أحدهما متحول الترميز(soya) ويأخذ القيمة 1 لمجموعة المراقبة (بدون صويا) و 2 للمجموعة التي تتناول وجبة صويا أسبوعياً، و 3 للمجموعة التي تتناول 4 وجبات صويا أسبوعياً، و 4 للمجموعة التي تتناول 7 وجبات أسبوعياً.

ويحوي العمود الثاني قيم المتحول التابع (عدد الحيوانات المنوية sperm). يحوي الملف Soya.sav البيانات لهذا المثال.

نقوم أولاً بتنفيذ بعض عمليات التحليل الاستكشافي للبيانات، وبما أننا سنبحث عن الفروق بين المجموعات فإننا ننفذ عمليات التحليل الاستكشافي على كل مجموعة (انظر الفقرات 5.3 و6.3)، ونحصل على الخرج المبين في الخرج 7.13. يبين الجدول الأول أن اختبار K-S (انظر الفقرة 5.3) لم يكن ذا دلالة بالنسبة لمجموعة المراقبة (D(20)=0.181, p>0.05) ولكن اختبار Shapiro-Wilk ذو دلالة وهو أكثر دقة عملياً من اختبار K-S (انظر الفصل 3). أما بيانات المجموعة التي يتناول عناصرها وجبة صويا واحدة أسبوعياً فقد كانت مختلفة عن الطبيعية بشكل كبير (D(20)=0.207, p<0.05)، وكذلك كانت بيانات المجموعة التي يتناول عناصرها 4 وجبات صويا أسبوعياً (D(20)=0.267, p<0.01) والمجموعة التي يتناول عناصرها 7 وجبات صويا أسبوعياً (D(20)=0.204, p<0.05). ويعرض الجدول الثاني نتائج اختبار Levene. لقد تم خرق فرضية تجانس التباين F(3,76)=5.12, p<0.01، وتؤكد ذلك قيمة دلالة اختبار Levene (التي كانت أصغر من 0.05). وهكذا نتبين أن هذه البيانات قد خرقت فرضيتين هامتين، فهي موزعة بشكل غير طبيعي وللمجموعات تباينات غير متجانسة.

Tests of Normality

	Number of Soya Meals Per Week	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
		Statistic	df	Sig.	Statistic	df	Sig.
Sperm Count (Millions)	No Soya Meals	.181	20	.085	.805	20	.001
	1 Soya Meal Per Week	.207	20	.024	.826	20	.002
	4 Soyal Meals Per Week	.267	20	.001	.743	20	.000
	7 Soya Meals Per Week	.204	20	.028	.912	20	.071

a. Lilliefors Significance Correction

Test of Homogeneity of Variance

		Levene Statistic	df1	df2	Sig.
Sperm Count (Millions)	Based on Mean	5.117	3	76	.003
	Based on Median	2.860	3	76	.042
	Based on Median and with adjusted df	2.860	3	58.107	.045
	Based on trimmed mean	4.070	3	76	.010

الخرج 7.13

3.4.13 تنفيذ اختبار Kruskal-Wallis في برنامج SPSS

نفتح مربع الحوار الرئيسي باستخدام أمر القائمة Analyze ⇒ Nonparametric Tests ⇒ K Independent Samples... (انظر الشكل 6.13). نختار المتحول التابع من اللائحة (في هذا المثال sperm) وننقله إلى الحيز المسمى Test Variable List. ثم نختار المتحول المستقل (متحول التجميع

soya) وننقله إلى الحيز المسمى Grouping Variable. عند اختيار متحول التجميع يصبح الزر Define Range... فعالاً، ويجب نقر هذا الزر لفتح مربع الحوار Define Range. يحتاج برنامج SPSS لمعرفة المجال للرموز العددية المعينة للمجموعات، وهناك حيز لإدخال الحد الأدنى والحد الأعلى للرموز. وفي هذا المثال يكون الحد الأدنى هو 1 والحد الأعلى هو 4. بعد الانتهاء من تعريف المجال، ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي. يوفر مربع الحوار الرئيسي إمكانية اختيار اختبارات مشابهة لاختبار Kruskal-Wallis (انظر المربع 4.13) وذلك بنقر الزر...Options.

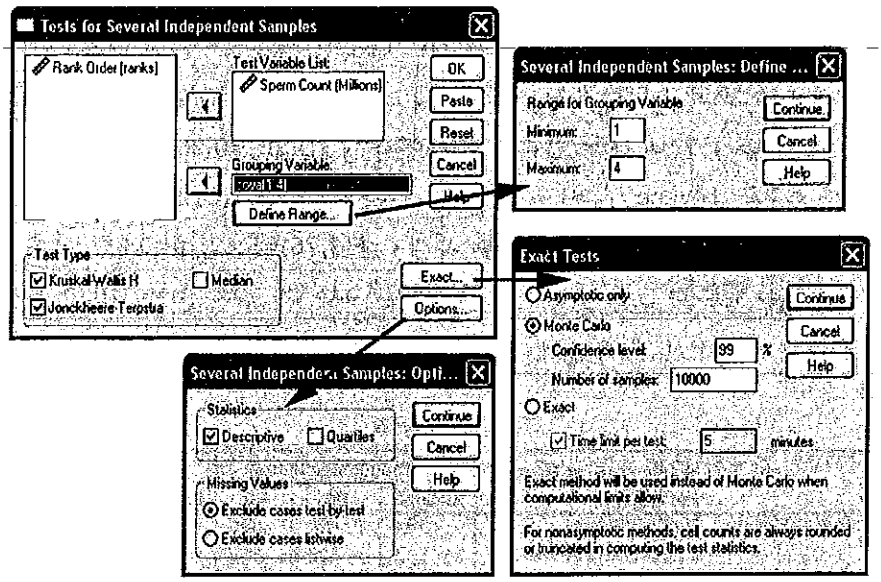

الشكل 6.13 مربعات الحوار لاختبار Kruskal-Wallis

إذا نقرنا الزر...Exact فإننا نحصل على مربع الحوار لاختيار قيم الدلالة الدقيقة لاختبار Kruskal-Wallis. لقد شرحنا هذا الخيار في الفقرة 3.2.13 وقلنا أنه من المفضل استخدام طريقة مونت كارلو إذا كان حجم العينة كبيراً (كما في هذا المثال) واستخدام الاختبار الدقيق عندما يكون حجم العينة صغيراً. أخيراً، إذا نقرنا الزر ...Options فإنه يمكننا تحديد خيارات أخرى للتحليل. وفي هذا المثال يعطي خيار الإحصائيات الوصفية النتائج لمجموعة البيانات كاملة ولا يقسمها حسب المجموعات لذلك فهو غير مفيد. ولهذا السبب ننصح بالحصول على الإحصائيات الوصفية باستخدام الطرق التي تعلمناها في الفقرات 4.3 و 5.3. نعود إلى مربع الحوار الرئيسي وننقر الزر OK لتنفيذ التحليل. الخيار الأخير الذي يمكن تحديده هو اختبار Jonckheere-Terpstra للمنحى الذي يمكن استخدامه للبحث عن منحى خطي في البيانات (انظر الفقرة 5.10.2.8).

المربع 4.13 الخيارات الأخرى

يحوي مربع الحوار الرئيسي بعض الاختبارات الأخرى التي يمكن اختيارها:

- **الوسط Median:** ويختبر فيما إذا كانت العينات مأخوذة من مجتمع له نفس الوسط. لذلك فهو يقوم بنفس عمل اختبار Kruskal-Wallis. حيث يعمل على أساس إنتاج جدول احتمالية وقوع الحدث مقسماً من أجل كل مجموعة إلى عدد العلامات التي تقع فوق وتحت قيمة الوسط المراقب لمجموعة البيانات كاملة. إذا كانت المجموعات من نفس المجتمع فإنك تتوقع أن تكون هذه التكرارات ذاتها من أجل جميع الحالات التجريبية (حوالي 50% أعلى من الوسط، وحوالي 50% أدنى من الوسط).
- **اختبار Terpstra-Jonckheere:** يختبر المناحي في البيانات (انظر الفقرة 6.4.13).

4.4.13 الخرج لاختبار Kruskal-Wallis

يعرض الخرج 8.13 جدولاً ملخصاً للبيانات المرتبة في كل حالة، وسنحتاج لهذه النتائج في تفسير الآثار.

Ranks

	Number of Soya Meals	N	Mean Rank
Sperm Count (Millions)	No Soya Meals	20	46.35
	1 Soya Meal Per Week	20	44.15
	4 Soya Meals Per Week	20	44.15
	7 Soya Meals Per Week	20	27.35
	Total	80	

الخرج 8.13

يعرض الخرج 9.13 إحصائية الاختبار H لاختبار Kruskal-Wallis (مع أن الجدول يعطيها التسمية Chi-Square وذلك بسبب توزيعها كاي مربع) وعدد درجات الحرية المرتبط بها (df=4-1=3) وقيمة الدلالة. إن أهم قيمة يجب أن ننظر إليها هي قيمة الدلالة التي تبلغ 0.034 ولأن هذه القيمة أصغر من 0.05 يمكننا أن نستنتج أن لعدد وجبات الصويا التي يتم تناولها أسبوعياً أثراً هاماً على عدد الحيوانات المنوية. لاحظ أيضاً تقدير مونت كارلو للدلالة، وهو أدنى بقليل من قيمة الدلالة، إذا يبلغ (0.033). وهذه هي القيمة التي يجب النظر إليها إذا كانت مختلفة عن قيمة المقارب. وبمجال الثقة للدلالة مفيد أيضاً، حيث يبلغ حده الأدنى 0.028 والأعلى 0.037، وبما أنه لا يحوي القيمة 0.05 فإن قيمته هامة لأنها تعني أن افتراض أن مجال الثقة هو واحد من 99 مجالاً (من أصل 100) التي تحوي القيمة الصحيحة للدلالة لإحصائية الاختبار، فإن القيمة الصحيحة للدلالة هي أصغر من (0.05). وهذا يمنحنا الثقة بأن الأثر حقيقي. ومع أن هذا الاختبار يدلنا على وجود فرق فإنه لا يدلنا على موقع هذا الفرق بالضبط.

Test Statistics[b,c]

			Sperm Count (Millions)
Chi-Square			8.659
df			3
Asymp. Sig.			.034
Monte Carlo Sig.	Sig.		.031[a]
	99% Confidence Interval	Lower Bound	.027
		Upper Bound	.036

a. Based on 10000 sampled tables with starting seed 2000000.

b. Kruskal Wallis Test

c. Grouping Variable: Number of Soya Meals Per Week

الخرج 9.13

هناك طريقة لمعرفة المجموعات المختلفة وهي النظر إلى مخطط الصندوق (انظر الفقرة 2.3.3) للمجموعات (انظر الشكل 7.13). إن أول ما يجب ملاحظته هو وجود بعض القيم المنعزلة (Outliers) (لاحظ وجود الدوائر والنجوم التي تقع فوق أهداب الصندوق)، وهي حالات الرجال الذين يعطون عدداً كبيراً جداً من الحيوانات المنوية. باستخدام مجموعة المراقبة كمجموعة مرجعية فإن قيم الوسط للمجموعات الثلاث الأولى تبدو متماثلة جداً، أما قيمة الوسط للمجموعة الرابعة (التي يتناول عناصرها 7 وجبات صويا أسبوعياً) فتبدو منخفضة قليلاً، لذلك ربما يكون هنا موقع الفرق. إن هذه الاستنتاجات شخصية وليست موضوعية، ولذلك علينا القيام ببعض المقارنات أو اختبارات post hoc (كما في الفقرات 10.2.8 و 11.2.8).

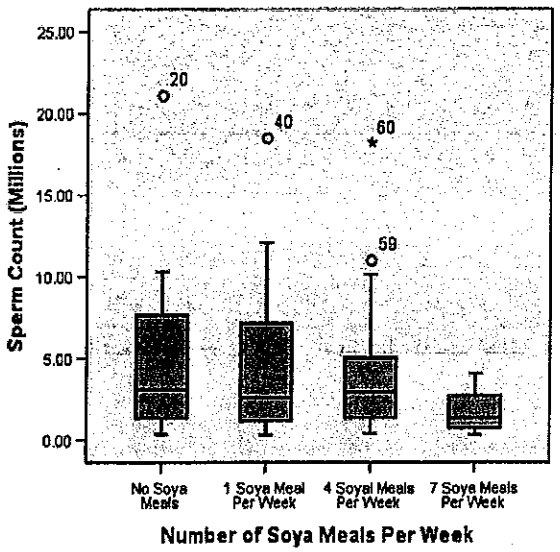

الشكل 7.13

5.4.13 اختبارات post hoc لاختبار Kruskal-Wallis

هناك طريقتان لتنفيذ إجرائيات post hoc اللابارامترية، تتم الأولى باستخدام اختبارات Mann-Whitney (انظر الفقرة 2.13). على كل حال، إذا استخدمنا عدداً كبيراً من اختبارات Mann-Whitney فإنها تضخم معدل الخطأ من النوع الأول (انظر الفقرة 1.2.8) ولهذا لن نبدأ باستخدامها. ولكن إذا أردنا استخدام عدد كبير من اختبارات Mann-Whitney بعد اختبار Kruskal-Wallis فإن علينا القيام ببعض عمليات الضبط للتأكد من أن الأخطاء من النوع الأول لا تتراكم لتكون أكبر من (0.05). إن أسهل طريقة هي استخدام تصحيح Bonferroni الذي يعني (بأبسط أشكاله) تقسيم القيمة الحرجة للدلالة 0.05 على عدد الاختبارات المنفذة. وهكذا تكون القيمة الحرجة للدلالة أصغر بكثير من القيمة الأصلية وبالتالي صارمة جداً. لهذا السبب يجب أن نكون حذرين في اختيار المقارنات التي نريد تنفيذها. في هذا المثال، لدينا مجموعة مراقبة (بدون صويا) لذلك يمكننا أن نختار مجموعة الاختبارات التالية التي تقارن كل مجموعة مع مجموعة المراقبة:

- الاختبار 1: يقارن المجموعة التي يتناول عناصرها وجبة صويا واحدة أسبوعياً مع مجموعة المراقبة.
- الاختبار 2: يقارن المجموعة التي يتناول عناصرها 4 وجبات صويا أسبوعياً مع مجموعة المراقبة.
- الاختبار 3: يقارن المجموعة التي يتناول عناصرها 7 وجبات صويا أسبوعياً مع مجموعة المراقبة.

لقد نتجت لدينا 3 اختبارات، لذلك وبدلاً من قيمة مستوى الدلالة الحرجة 0.05 فإن الدلالة المعتمدة تكون (0.05/3=0.0167). إذا لم نقم باختبارات مركّزة وقمنا بمقارنة جميع المجموعات مع بعضها البعض فإن عدد الاختبارات يكون 6 بدلاً من 3 (بدون صويا مع وجبة واحدة، بدون صويا مع 4 وجبات، بدون صويا مع 7 وجبات، وجبة واحدة مع 4 وجبات، وجبة واحدة مع 7 وجبات، 4 وجبات مع 7 وجبات) وتنخفض قيمة الدلالة إلى (0.05/6=0.0083).

يعرض الخرج 10.13 إحصائيات الاختبار الناتجة عن تنفيذ اختبارات Mann-Whitney على المقارنات المركزة التي اخترناها. إن أسهل طريقة لتنفيذ ذلك في برنامج SPSS هي تغيير قيم الرموز للحيز Group 1 و Group 2 في مربع الحوار Define Groups في الشكل 3.13. تذكر أننا نستخدم قيمة الدلالة 0.0167 لذلك فإن المقارنة الوحيدة ذات الدلالة هي عندما تتم مقارنة المجموعة التي يتناول عناصرها 7 وجبات صويا أسبوعياً مع مجموعة المراقبة (لأن قيمة الدلالة المراقبة هي 0.009<0.0167). أما المقارنتان الباقيتان فتعطيان قيم دلالة أكبر بكثير من القيمة الحرجة 0.0167 ولذلك تكونان بدون دلالة. ولذلك فإن الأثر الذي حصلنا عليه يعكس بشكل أساسي حقيقة أن تناول الصويا 7 مرات أسبوعياً يخفض عدد الحيوانات المنوية (وعرفنا ذلك من قيم الوسط في الشكل 7.13) مقارنة مع عدم تناول الصويا. على كل حال، يبدو أن تناول بعض الصويا (وجبة واحدة أو 4 وجبات أسبوعياً) لا يؤثر على عدد الحيوانات المنوية.

الطريقة الثانية لتنفيذ اختبارات post hoc مماثلة لتنفيذ اختبارات Mann-Whitney على جميع المقارنات الممكنة، وتتضمن أخذ الفروق بين مراتب المتوسط للمجموعات المختلفة ومقارنتها مع قيمة تستند على قيمة z (مصححة من أجل عدد المقارنات المنفذة) وعلى حد ثابت يستند على حجم العينة الكلي وحجم العينة في المجموعتين اللتين تتم مقارنتهما. وهذه المتراجحة هي:

$$\left|\bar{R}_u - \bar{R}_v\right| \geq z_{\alpha/k(k-1)}\sqrt{\frac{N(N+1)}{12}\left(\frac{1}{n_u}+\frac{1}{n_v}\right)} \qquad (2.13)$$

يمثل الحد الأيسر من المتراجحة القيمة المطلقة للفرق بين مرتبة الوسط للمجموعتين اللتين تتم مقارنتهما، وk عدد المجموعات (4 في هذا المثال)، وN حجم العينة الكلي (80 في هذا المثال)، و n_u عدد الأشخاص في المجموعة الأولى التي تتم مقارنته (عدد العناصر جميع المجموعات هو ذاته في هذا المثال ويساوي 20) و n_v عدد الأشخاص في المجموعة الثانية التي تتم مقارنتها (ويساوي 20 في هذا المثال). الحد الأخير الذي نحتاجه هو $z_{\alpha/k(k-1)}$ ولكي نحصل على قيمته نحن بحاجة لتحديد مستوى الدلالة α الذي نريد العمل عنده (ويساوي 0.05). ونحسب بعد ذلك الحد k(k-1) من أجل هذه البيانات ويساوي 12=(4-1)4. لذلك تكون قيمة $\alpha/k(k-1)$ =0.05/12=0.00417. وهكذا فإن $z_{\alpha/k(k-1)}$ تعني "قيمة z التي من أجلها تكون $\alpha/k(k-1)$ قيمة فقط من قيم z الأخرى هي أكبر". وبشكل عملي فإن ذلك يعني أن نبحث في العمود المسمى القسم الأصغر Smaller Portion من الجدول في الملحق A1 عن القيمة 0.00417 (أو أقرب قيمة إليها، وهي 0.00415 في الجدول) ثم نبحث في نفس الصف عن قيمة z في العمود المسمى z (حيث نجد z=2.64). بعد ذلك نحسب الحد الأيمن من المتراجحة (13-2):

$$\text{الفرق الحرج} = z_{\alpha/k(k-1)}\sqrt{\frac{N(N+1)}{12}\left(\frac{1}{n_u}+\frac{1}{n_v}\right)}$$

$$= 2.64\sqrt{\frac{80(8+1)}{12}\left(\frac{1}{20}+\frac{1}{20}\right)}$$

$$= 19.40$$

No soya vs. 1 meal per week

Test Statistics[b]

	Sperm Count (Millions)
Mann-Whitney U	191.000
Wilcoxon W	401.000
Z	-.243
Asymp. Sig. (2-tailed)	.808
Exact Sig. [2*(1-tailed Sig.)]	.820[a]

a. Not corrected for ties.

b. Grouping Variable: Number of Soya Meals Per Week

No soya vs. 4 meals per week

Test Statistics[b]

	Sperm Count (Millions)
Mann-Whitney U	188.000
Wilcoxon W	398.000
Z	-.325
Asymp. Sig. (2-tailed)	.745
Exact Sig. [2*(1-tailed Sig.)]	.758[a]

a. Not corrected for ties.

b. Grouping Variable: Number of Soya Meals Per Week

No soya vs. 7 meals per week

Test Statistics[b]

	Sperm Count (Millions)
Mann-Whitney U	104.000
Wilcoxon W	314.000
Z	-2.597
Asymp. Sig. (2-tailed)	.009
Exact Sig. [2*(1-tailed Sig.)]	.009[a]

a. Not corrected for ties.

b. Grouping Variable: Number of Soya Meals Per Week

الخرج 10.13

فمن أجل هذا المثال، ولأن حجم العينة لمختلف المجموعات هو ذاته فإنه يمكننا استخدام هذا الفرق الحرج من أجل جميع المقارنات. أما عندما تكون أحجام العينات مختلفة بين المجموعات فيجب حساب الفرق الحرج من أجل كل مقارنة. الخطوة التالية هي حساب جميع الفروق بين مرتبات المتوسط لجميع المجموعات (والتي يمكن إيجادها في الخرج 8.13) كما في الجدول 4.13.

$\lvert\bar{R}_u - \bar{R}_v\rvert$	$\bar{R}_u - \bar{R}_v$	$\bar{R}_v$	$\bar{R}_u$	المقارنة
2.20	2.20	44.15	46.35	بدون صويا - وجبة واحدة
2.20	2.20	44.15	46.35	بدون صويا - 4 وجبات
19.00	19.00	27.35	46.35	بدون صويا - 7 وجبات
0.00	0.00	44.15	44.15	وجبة واحدة - 4 وجبات
16.80	16.80	27.35	44.15	وجبة واحدة – 7 وجبات
16.80	16.80	27.35	44.15	4 وجبات - 7 وجبات

الجدول 4.13 الفروق بين مرتبات المتوسط لبيانات مثال الصويا

وتعني المعادلة (2.13) بشكل أساسي أنه إذا كانت الفروق بين مرتبات المتوسط أكبر من أو تساوي الفرق الحرج للمقارنة فإن هذا الفرق مهم. في هذه الحالة، ولأن لدينا فرقاً واحداً فهذا يعني أنه إذا كان الفرق أكبر من 19.40 فإنه يكون مهماً. وكما نرى فإن جميع الفروق هي أصغر من

هذا الفرق الحرج، لذلك علينا أن نستنتج عدم وجود مجموعات مختلفة. وهذا يتعارض مع النتيجة السابقة حيث بيّن اختبار Mann-Whitney وجود فرق بين المجموعة التي يتناول عناصرها 7 وجبات صويا أسبوعياً ومجموعة المراقبة. ما سبب هذا التعارض؟ حسناً، من أجل اختبارات Mann-Whitney فقد قمنا بثلاثة اختبارات فقط ولذلك تم تصحيح قيمة الدلالة لهذه الاختبارات الثلاثة (0.05/3=0.0167). وقد قلنا سابقاً في هذه الفقرة أنه إذا قارنّا جميع المجموعات مع بعضها البعض سيكون لدينا 6 مقارنات، ولذلك علينا أن نقبل الفرق كفرق هام إذا كانت قيمة الدلالة أقل من (0.05/6=0.0083). إذا عدنا إلى اختبارMann-Whitney الوحيد (الخرج 10.13) فإن قيمة الدلالة كانت 0.009، ولذلك إذا نفذنا 6 مقارنات فإن هذا الفرق سيكون عديم الدلالة (لأن 0.009>0.0083). وهذا يوضح فائدة ما قلناه سابقاً عن اختيار مقارنات مركّزة.

6.4.13 اختبار المناحي: اختبار Jonckheere-Terpstra

يقوم هذا الاختبار باختبار الفرق بين قيم الوسط للمجموعات مع تضمين معلومات حول أهمية ترتيب المجموعات. لذلك يجب استخدام هذا الاختبار عندما نتوقع أن تعطي المجموعات التي تتم مقارنتها ترتيباً مهماً لقيم الوسط. في المثال الحالي نتوقع أن تناول المزيد من الصويا سينخفض عدد الحيوانات المنوية. لذلك فإن مجموعة المراقبة ستحوي العدد الأكبر من الحيوانات المنوية، أما في المجموعة التي يتناول عناصرها وجبة واحدة من الصويا أسبوعياً فإن عدد الحيوانات المنوية أقل، وينخفض هذا العدد في المجموعة التي يتناول عناصرها 4 وجبات من الصويا أسبوعياً، وينخفض بشكل أكبر في المجموعة التي يتناول عناصرها 7 وجبات من الصويا أسبوعياً. لذلك فإن هناك ترتيب لقيم الوسط، إذا أنه ينخفض عبر المجموعات. وهناك حالات نتوقع فيها زيادة قيم الوسط، إذ تستخدم شركات الإنتاج الموسيقية ذلك للحصول على أثر جيد حيث تقوم ببث الأغاني الجديدة لفترة شهرين في الإذاعة قبل طرح الأسطوانة الجديدة في الأسواق. فإذا أخذنا 3 مجموعات وأسمعناها الأغنية 10 مرات و20 مرة و30 مرة ثم أحصينا عدد الأشخاص الذين أحبوا الأغنية، فإننا نتوقع زيادة الوسط. فالأشخاص الذي استمعوا 10 مرات للأغنية سيحبونها قليلاً، والذين استمعوا 20 مرة سيحبونها أكثر، أما الذين استمعوا 30 مرة فإنهم سيعشقون الأغنية. تم تصميم اختبار Jonckheere-Terpstra لمثل هذه الحالات. ويعمل برنامج SPSS على مبدأ أن متحول الترميز (الذي يعرّف المجموعات) يحدد الترتيب الذي نتوقع فيه تغير الوسط. فمن أجل المثال الحالي، قمنا بترميز مجموعة المراقبة بالرقم 1، ومجموعة الوجبة الواحدة بالرقم 2، ومجموعة 4 وجبات بالرقم 3، ومجموعة 7 وجبات بالرقم 4، ولذلك سيختبر فيما إذا كان عدد الحيوانات المنوية الوسطي سيزداد أم يتناقص بين المجموعات وفق الترتيب المحدد. يمكننا طبعاً تغيير مخطط الترميز إذا كان ترتيب الوسط مختلفاً. يحوي الملحق A.7 وصفاً لآلية عمل هذا الاختبار، ولكن يمكنك استخدام الاختبار دون معرفة آلية عمله، بشرط أن تعرف أن قيم الوسط تزداد أو تتناقص وفق الترتيب المحدد بمتحول الترميز.

رأينا كيفية تحديد الاختبار في الفقرة 3.4.13، ويعرض الخرج 11.13 الخرج الناتج عن الاختبارات لبيانات الصويا. يعطي هذا الجدول عدد المجموعات التي تتم مقارنتها. كما يعطي قيمة إحصائية الاختبار J التي تساوي 912. في العينات الكبيرة (أكثر من 8 عناصر في المجموعة) فإن لإحصائية الاختبار توزيعاً طبيعياً لأخذ العينات ويمكن حساب قيمة المتوسط والانحراف المعياري (وهي 1200 و116.33 على الترتيب). بمعرفة هذه القيم يمكننا التحويل لعلامة z: (z=(912-1200)/116.33=-2.476). يمكن بعد ذلك مقارنة العلامة z مع قيم التوزيع الطبيعي، ونظراً لأن اختبار Jonckheere يجب أن يكون وحيد الطرف دائماً (لأننا نحدد ترتيب الوسط قبل التجربة) فإننا نبحث عن قيمة أكبر من 1.65 (بعد إهمال الإشارة). ولذلك فإن القيمة 2.476 ذات دلالة. وتدلنا إشارة القيمة z إذا كانت موجبة على وسط تصاعدي (أي أن قيم الوسط تصبح أكبر عندما تصبح قيم متحول الترميز أكبر) وإذا كانت سالبة فإنها تدل على وسط تنازلي (أي أن قيم الوسط تصبح أصغر عندما تصبح قيم متحول الترميز أكبر) وهي الحالة التي نجدها في هذا المثال.

يحوي الجدول أيضاً قيم الدلالة ثنائية الطرف ووحيدة الطرف المقدرة باستخدام طرق مونت كارلو. وتظهر هذه القيم لأننا حددنا هذا الخيار من أجل اختبار Kruskal-Wallis. وهذا ما وجدناه سابقاً.

Jonckheere-Terpstra Test[b]

			Sperm Count (Millions)
Number of Levels in Number of Soya Meals Per Week			4
N			80
Observed J-T Statistic			912.000
Mean J-T Statistic			1200.000
Std. Deviation of J-T Statistic			116.333
Std. J-T Statistic			-2.476
Asymp. Sig. (2-tailed)			.013
Monte Carlo Sig. (2-tailed)	Sig.		.012[a]
	99% Confidence Interval	Lower Bound	.009
		Upper Bound	.015
Monte Carlo Sig. (1-tailed)	Sig.		.006[a]
	99% Confidence Interval	Lower Bound	.004
		Upper Bound	.008

a. Based on 10000 sampled tables with starting seed 2000000.

b. Grouping Variable: Number of Soya Meals Per Week

الخرج 11.13

7.4.13 حساب حجم الأثر

لسوء الحظ ليست هناك طريقة سهلة لتحويل إحصائية كاي مربع التي لها أكثر من درجة حرية واحدة إلى حجم أثر r. يجب استخدام قيمة الدلالة لإحصائية اختبار Kruskal-Wallis لإيجاد قيمة z من جدول قيم الاحتمال للتوزيع الطبيعي (مثل الملحق A1). حيث يمكننا استخدام هذه القيمة في

معادلة التحويل التي استخدمناها في الفقرة 5.2.13 للحصول على حجم الأثر r. على كل حال، نادراً ما يكون هذا النوع من حجم الأثر مفيداً (لأن يلخص أثراً عاماً). وفي معظم الحالات يكون من المفيد معرفة حجم الأثر لمقارنة مركّزة (كالحالة التي نقارن فيها عنصرين فقط). ولهذا السبب نقترح حساب حجم الأثر لاختبارات Mann-Whitney التي استخدمناها بعد التحليل الأساسي مباشرة.

من أجل المقارنة الأولى (بدون صويا مقابل وجبة واحدة) يبين الخرج 10.13 أن قيمة z هي 0.243-، ولأنها تعتمد على مقارنة مجموعتين تحوي كل منهما 20 مشتركاً فإن عدد المشاهدات الكلي يساوي 40. ولذلك يكون حجم الأثر:

$$r_{\text{No Soya vs. 1 Meal}} = \frac{-0.243}{\sqrt{40}} = -0.04$$

ويمثل أثراً صغيراً جداً لأن القيمة قريبة من الصفر، ويدلنا ذلك على أن أثر تناول وجبة واحدة من الصويا أسبوعياً مهمل مقارنة بتناول الوجبات الخالية من الصويا.

من أجل المقارنة الثانية (بدون صويا مقابل 4 وجبات) يبين الخرج 10.13 أن قيمة z هي 0.325-، ولأن عدد المشاهدات الكلي يساوي 40 فإن حجم الأثر:

$$r_{\text{No Soya vs. 4 Meals}} = \frac{-0.325}{\sqrt{40}} = -0.05$$

ويمثل أثراً مهملاً لأن القيمة قريبة من الصفر، ويدلنا على أن أثر تناول 4 وجبات من الصويا أسبوعياً مهمل مقارنة بتناول الوجبات الخالية من الصويا.

ومن أجل المقارنة الأخيرة (بدون صويا مقابل 7 وجبات) يبين الخرج 10.13 أن قيمة z هي 2.597- ولأن عدد المشاهدات الكلي يساوي 40 فإن حجم الأثر:

$$r_{\text{No Soya vs. 7 Meals}} = \frac{-2.597}{\sqrt{40}} = -0.41$$

ويمثل أثراً متوسط الحجم، ويدلنا ذلك على أن أثر تناول 7 وجبات من الصويا أسبوعياً موجود عملياً مقارنة بتناول الوجبات الخالية من الصويا.

يمكننا أيضاً أن نحسب حجم الأثر من أجل اختبار Jonckheere وذلك باستخدام نفس المعادلة. يشمل هذا الاختبار جميع البيانات، لذلك يكون عدد المشاهدات الكلي 80:

$$r_{\text{Jonckheere}} = \frac{-2.476}{\sqrt{80}} = -0.28$$

8.4.13 كتابة النتائج وتفسيرها

من أجل اختبار Kruskal-Wallis علينا تقديم إحصائية الاختبار H وعدد درجات الحرية وقيمة الدلالة. لذلك يمكننا تقديم النتائج بالشكل:

✓ يتأثر عدد الحيوانات المنوية بشكل كبير بتناول وجبات الصويا، H(3)=8.66, p<0.05.

كما يمكننا تقديم الاختبارات اللاحقة (التي تتضمن حجم الأثر):

✓ يتأثر عدد الحيوانات المنوية بشكل كبير بتناول وجبات الصويا، H(3)=8.66, p<0.05. وقد استُخدمت اختبارات Mann-Whitney لمواصلة البحث في هذه النتيجة. تم تطبيق تصحيح Bonferroni ولذلك تم تقديم الآثار عند مستوى الدلالة 0.0167. ويظهر أن عدد الحيوانات المنوية ليست مختلفاً بين تناول وجبة واحدة من الصويا أسبوعياً U=191, r=-0.41 أو 4 وجبات من الصويا أسبوعياً U=188, r=-0.05 مقارنة مع عدم تناول الصويا. أما عدد الحيوانات المنوية في حالة تناول 7 وجبات صويا أسبوعياً فقد كان أدنى بكثير من تناول الوجبات الخالية من الصويا U=104, r=-0.41. ويمكننا أن نستنتج أنه إذا تم تناول الصويا يومياً فإنها تقلل عدد الحيوانات المنوية بشكل كبير مقارنة مع تناول الوجبات الخالية من الصويا، أما تناول الصويا بمعدل أقل فليس له أثر كبير على عدد الحيوانات المنوية.

كما يمكننا تقديم المنحى بالشكل:

✓ تم تقديم جميع الآثار عند مستوى p<0.05. ويتأثر عدد الحيوانات المنوية بتناول وجبات الصويا H(3)=8.66. وقد كشف اختبار Jonckheere عن منحى مهم في هذه البيانات: كلما ازداد عدد وجبات الصويا التي يتم تناولها تنخفض قيمة الوسط لعدد الحيوانات المنوية، J=912, z=-2.48, r=-0.28.

أفكار مهمة

- يقارن اختبار Kruskal-Wallis عدة حالات تجريبية عندما يشترك مشتركون مختلفون في كل حالة تجريبية وتكون البيانات الناتجة موزعة بشكل غير طبيعي أو أنها تخرق فرضية ANOVA وحيد الاتجاه المستقل.
- انظر إلى الصف المسمى Asymp. Sig. فإذا كانت القيمة أقل من 0.05 فإن المجموعات مختلفة بشكل كبير.
- يمكنك متابعة التحليل الأساسي بتنفيذ اختبارات Mann-Whitney بين زوجين من الحالات، ونقبلها بأنها ذات دلالة إذا كانت قيمة دلالتها أقل من ناتج قسمة 0.05 على عدد الاختبارات.
- إذا توقعت أن تزداد قيم المتوسط أو تنقص عبر المجموعات وفق ترتيب معين فيجب تنفيذ اختبار Jonckheere.
- يتم تقديم إحصائية H وعدد درجات الحرية وقيمة الدلالة للتحليل الأساسي. ومن أجل اختبارات post hoc، يتم تقديم الإحصائية U وحجم الأثر وقيمة z الموافقة وقيمة الدلالة إذا كان ذلك ممكناً. يمكنك تقديم قيم الوسط ومجالاتها الموافقة.

5.13 الفروق بين عدة مجموعات مرتبطة: Friedman's ANOVA

اكتشفنا في الفصل 11 تقنية تدعى ANOVA وحيدة الاتجاه المرتبطة، يمكن استخدامها لاختبار الفرق بين عدة مجموعات مرتبطة. ومع أن ANOVA مقاومة لخرق فرضياتها، فإن هناك طريقة بديلة في حالة القياسات المكررة هي Friedman's ANOVA. وتُستخدم لاختبار الفروق بين الحالات التجريبية عندما تكون لدينا ثلاث حالات على الأقل وتم استخدام نفس المشتركين في جميع الحالات (يساهم كل مشترك بعدة علامات في البيانات). إذا كانت البيانات موزعة بشكل غير طبيعي أو أنها تخرق بعض الفرضيات الأخرى فإنه يمكن استخدام هذا الاختبار كطريقة مفيدة لحل المشكلة.

يهتم الشباب (وخاصة الفتيات) بوزن الجسم والحمية، ولأن وسائل الإعلام تركز دائماً على نشر صور المشاهير نحيفي الجسم، وتقوم بغسل أدمغة الشباب لتركيز فكرة أن هذه الأجسام مثالية وجذابة فعلاً، ينتهي الأمر بإحباط الشباب لأن أجسادهم ليست مثالية. وتنتهز بعض الشركات الطفيلية ذلك باستغلال الناس وتقديم أنواع من الحمية بغية الوصول إلى جسم رائع. وقد طرح أحد الباحثين حمية دون استغلال الناس تعتمد على تناول اللحم والإكثار من شاي Darjeeling وتناول الجبن الأوروبي والخبز الطازج والمعكرونة والشوكولا، وممارسة الألعاب الرياضية مرتين في الأسبوع على الأقل، وممارسة الهوايات المختلفة. ولاختبار فعالية هذه الحمية فقد طلب من 10 نساء ممن يعتبرن أنفسهن بحاجة لتخفيف الوزن إتباع هذه الحمية لمدة شهرين. وقد تم قياس الوزن في بداية الحمية وبعد شهر وكذلك بعد شهرين.

1.5.13 نظرية Friedman's ANOVA

إن نظرية Friedman's ANOVA مماثلة للاختبارات الأخرى التي رأيناها في هذا الفصل، فهي تعتمد على البيانات المرتبة. ونبدأ بوضع البيانات للحالات المختلفة في أعمدة مختلفة (في هذا المثال لدينا 3 حالات تجريبية لذلك لدينا 3 أعمدة). يحوي الجدول 5.13 البيانات لمثال الحمية، لاحظ وجود البيانات في أعمدة مختلفة حيث يمثل كل صف البيانات لشخص مختلف. لاحظ أيضاً ترتيب البيانات لكل شخص. نبدأ مع الشخص 1 وننظر إلى علاماته (في هذه الحالة الوزن عند بداية الحمية 63.75 كغ، وبعد شهر واحد 65.38 كغ، وبعد شهرين 81.34 كغ) ثم نعطي الوزن الأدنى المرتبة 1 والوزن الأعلى منه المرتبة 2 والوزن الأعلى المرتبة 3. بعد الانتهاء من ترتيب البيانات للشخص 1 ننتقل إلى الشخص 2 ونكرر العملية السابقة. ثم نكرر العملية لبقية الأشخاص. نقوم بعد ذلك بجمع المراتب لكل حالة (R_i حيث i رقم الحالة التجريبية). يعرض الجدول 5.13 بيانات هذا المثال مع مراتبها.

	الـوزن			الـوزن		
	البداية	بعد شهر	بعد شهرين	البداية (المراتب)	بعد شهر (المراتب)	بعد شهرين (المراتب)
الشخص 1	63.75	65.38	81.34	1	2	3
الشخص 2	62.98	66.24	69.31	1	2	3
الشخص 3	65.98	67.7	77.89	1	2	3
الشخص 4	107.27	102.72	91.33	3	2	1
الشخص 5	66.58	69.45	72.87	1	2	3
الشخص 6	120.46	119.96	114.26	3	2	1
الشخص 7	62.01	66.09	68.01	1	3	2
الشخص 8	71.87	73.62	55.43	2	3	1
الشخص 9	83.01	75.81	71.63	3	2	1
الشخص 10	76.62	67.66	68.6	3	1	2
			المجموع R_i	19	20	21

الجدول 5.13 البيانات لمثال الحمية مع مراتبها

بعد حساب مجموع المراتب لكل مجموعة، يتم حساب إحصائية الاختبار F_r كما في المعادلة (3.13):

$$F_r = \left[\frac{12}{N \cdot k \cdot (k+1)} \sum_{i=1}^{k} R_i^2\right] - 3N(k+1) \qquad (3.13)$$

في هذه المعادلة، يمثل R_i مجموع المراتب للمجموعة i، و N حجم العينة الكلي (ويساوي 10 في هذه الحالة)، و k عدد الحالات التجريبية (k=3). وهذه المعادلة شبيهة جداً بمعادلة اختبار Kruskal-Wallis (المعادلة (1.13)). بتعويض القيم في المعادلة (3.13) نجد:

$$F_r = \left[\frac{12}{10 \times 3 \times (3+1)} (19^2 + 20^2 + 21^2)\right] - 3 \times 10 \times (3+1)$$

$$F_r = 0.2$$

عندما يكون عدد المشتركين كبيراً (أكثر من 10) فإن لهذه الإحصائية توزيع كاي مربع (انظر الفصل 16) وهناك قيمة واحدة لدرجات الحرية تساوي k-1، وفي هذا المثال 2=1-3.

2.5.13 إدخال البيانات والتحليل المؤقت

عند جمع البيانات من نفس المشتركين في كل حالة فإنه يتم إدخال البيانات في أعمدة مختلفة. لذلك يكون لمجرر البيانات 3 أعمدة، حيث يحوي العمود الأول البيانات في بداية الحمية (المتحول start)، والعمود الثاني البيانات بعد شهر واحد (المتحول month1)، والعمود الأخير البيانات بعد شهرين (المتحول month2). ويحوي الملف Diet.sav هذه البيانات.

نقوم أولاً بتنفيذ تحاليل استكشافية (انظر الفصل 3) ونحصل على الخرج 12.13 الذي يبين أن اختبار K-S (انظر الفقرة 5.3) لم يكن ذا دلالة من أجل الأوزان في بداية الحمية D(10)=0.23, p>0.05، ولكن اختبار Shapiro-Wilk ذو دلالة وهو أكثر دقة من اختبار K-S (انظر الفصل 3). أما النتائج بعد شهر واحد من بداية الحمية فهي مختلفة جداً عن الطبيعية D(10)=0.34, p<0.01، غير أن النتائج بعد شهرين من بداية الحمية تبدو طبيعية D(10)=0.20, p>0.05. إن بعض هذه البيانات موزع بشكل غير طبيعي ولذلك علينا استخدام اختبار لابارامتري.

Tests of Normality

	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
Weight at Start (Kg)	.228	10	.149	.784	10	.009
Weight after 1 month (Kg)	.335	10	.002	.885	10	.001
Weight after 2 month (Kg)	.203	10	.200*	.877	10	.121

*. This is a lower bound of the true significance.

a. Lilliefors Significance Correction

الخرج 12.13

3.5.13 تنفيذ Friedman's ANOVA في برنامج SPSS

نفتح أولاً مربع الحوار الرئيسي باستخدام أمر القائمة Analyze ⇒ Nonparametric Tests ⇒ K Related Samples... (انظر الشكل 8.13). نختار بعد ذلك المتحولات التابعة (start وmonth1 وmonth2) وننقلها إلى الحيز المسمى Test Variables. إذا نقرنا الزر...Exact فإننا نحصل على مربع الحوار الخاص باختيار قيم الدلالة الدقيقة من أجل Friedman's ANOVA (انظر الفقرة 3.2.13). تذكر أنه عندما يكون حجم العينة كبيراً فإننا نختار طريقة مونت كارلو أما في حالة العينات الصغيرة فإننا نختار الاختبار الدقيق (وهي الحالة المناسبة لهذا المثال). ننقر أخيراً الزر...Statistics لتحديد بعض الإحصائيات الوصفية. نعود إلى مربع الحوار الرئيسي وننقر الزر OK لتنفيذ التحليل. يمكنك أيضاً تنفيذ بعض الاختبارات الأخرى من خلال مربع الحوار الرئيسي (انظر المربع 5.13).

المربع 5.13 الخيارات الأخرى

يحوي مربع الحوار الرئيسي بعض الاختبارات الأخرى التي يمكن تنفيذها:

- **اختبار Kendall's W:** ويشبه Friedman's ANOVA ولكنه يُستخدم بشكل خاص للبحث عن التوافق بين الأشخاص الذين ينفذون التقييم. فعلى سبيل المثال إذا طلبنا من 10 نساء أن يقيّموا جاذبية دايفيد بيكهام وطوني بلير فإنه يمكننا استخدام هذا الاختبار لمعرفة مدى التوافق بين المشتركات. وهذا الاختبار مفيد خاصة أنه ذو مجال محدد يتراوح بين 0 (عدم توافق بين الحكام) و 1 (توافق تام بين الحكام) مثل عامل الارتباط تماماً.

- **اختبار Cochran's Q:** توسيع لاختبار McNemar (انظر المربع 3.13)، وهو اختبار Friedman في حالة البيانات الثنائية. تخيل أننا طلبنا من 10 نساء الإجابة على سؤال معين بنعم أو لا. إذا رمزنا للإجابة لا بالقيمة 0 وللإجابة نعم بالقيمة 1 فإنه يمكننا تطبيق اختبار Cochran على هذه البيانات.

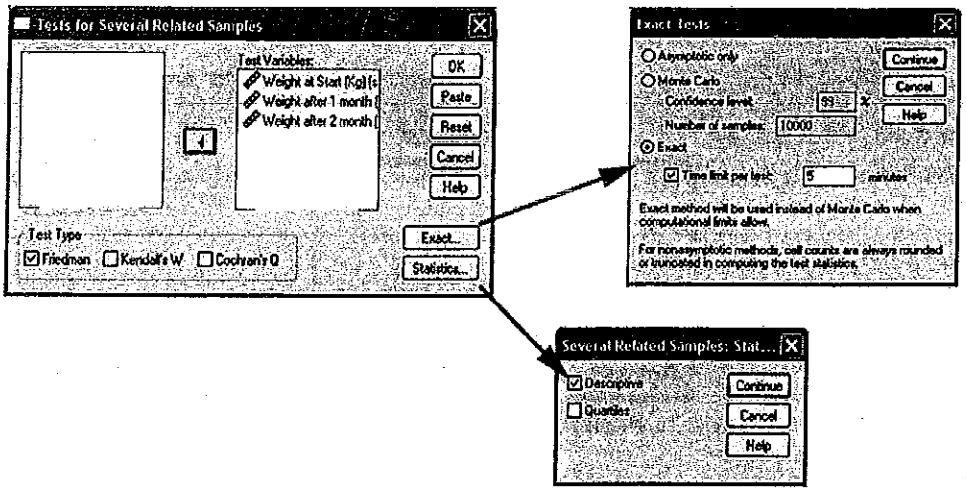

الشكل 8.13 مربعات الحوار من أجل Friedman's ANOVA

4.5.13 الخرج من Friedman's ANOVA

كما رأينا فإن Friedman's ANOVA كبقية الاختبارات اللابارامترية في هذا الفصل، يعتمد على المراتب وليس على العلامات الفعلية. لذلك يبين الخرج 13.13 مرتبة المتوسط في كل حالة تجريبية. وهذه القيم هامة جداً لتفسير الآثار، فهي تبين أن المراتب كانت متشابهة بين الحالات التجريبية.

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum	Percentiles 25th	50th (Median)	75th
Weight at Start (Kg)	10	78.0543	20.23008	62.01	120.46	63.5549	69.2288	89.0709
Weight after1 month (Kg)	10	77.4635	18.61502	65.38	119.96	66.2065	68.5728	82.5385
Weight after2 month (Kg)	10	77.0668	16.10612	55.43	114.26	66.4525	72.2493	83.8365

Ranks

	Mean Rank
Weight at Start (Kg)	1.90
Weight after1 month (Kg)	2.00
Weight after2 month (Kg)	2.10

الخرج 13.13

يعرض الخرج 14.13 إحصائية الاختبار (يسمي برنامج SPSS هذه الإحصائية Chi-Square بدلاً من F وذلك لأن F تملك توزيع كاي مربع) وتبلغ قيمتها 0.2 وهي القيمة التي حسبناها سابقاً. كما يعرض عدد درجات الحرية لإحصائية الاختبار k-1=3-1=2، وقيمة الدلالة. إذا طلبنا القيمة الدقيقة للدلالة فإننا نحصل عليها في هذا الجدول أيضاً. تبلغ قيمة الدلالة 0.905 (والقيمة الدقيقة 0.974) وهي أعلى من 0.05، لذلك يمكننا أن نستنتج أنه ليس للحمية المقترحة أي أثر، فالأوزان لم تتغير بشكل كبير خلال هذه الحمية.

Test Statistics[a]

N	10
Chi-Square	.200
df	2
Asymp. Sig.	.905
Exact Sig.	.974
Point Probability	.143

a. Friedman Test

الخرج 14.13

5.5.13 اختبارات post hoc من أجل Friedman's ANOVA

كما في حالة اختبار Kruskal-Wallis، هناك طريقتان لتنفيذ إجرائيات post hoc اللابارامترية. تتم الأولى باستخدام (اختبارات Wilcoxon للمرتبة ذات الإشارة (انظر الفقرة 13.13) ولكن مع تصحيح قيمة الدلالة حسب عدد الاختبارات (انظر الفقرات 1.2.8 و 5.4.13)، حيث نقبل الاختبار على أنه ذو دلالة إذا كانت قيمة الدلالة أصغر من ناتج قسمة 0.05 على عدد المقارنات المنفّذة (تصحيح Bonferroni). وفي هذا المثال لدينا 3 مجموعات فقط، فإذا قارنّا جميع المجموعات مع بعضها البعض فإننا نحصل على 3 مقارنات هي:

- الاختبار 1: يقارن الوزن في بداية الحمية مع الوزن في نهاية الشهر الأول.
- الاختبار 2: يقارن الوزن في بداية الحمية مع الوزن في نهاية الشهر الثاني.
- الاختبار 3: يقارن الوزن في نهاية الشهر الأول مع الوزن في نهاية الشهر الثاني.

ولذلك نستخدم قيمة الدلالة (0.05/3=0.0167) كمستوى حرج للدلالة بدلاً من القيمة (0.05). في الحقيقة، لن نشغل أنفسنا باختبارات post hoc لهذا المثال لأن ANOVA الأساسي لم يكن ذا دلالة، ولكننا سنتابع خطوات العمل للتوضيح فقط. يمكننا تنفيذ اختبارات Wilcoxon باختيار أزواج المتحولات لكل مقارنة على حدا ونقلها إلى الحيز المسمى Test Pair(s)List (انظر الشكل 4.13).

يعرض الخرج 15.13 إحصائيات الاختبار الناتجة عن تنفيذ اختبارات Wilcoxon للمرتبة ذات الإشارة على المقارنات الثلاث. تذكر أننا نستخدم القيمة الحرجة 0.0167 كمعيار للدلالة، وهكذا نجد أن جميع المقارنات بدون دلالة عندما نستخدم قيم الدلالة وحيدة الطرف وذلك لأن قيمها هي 0.500 و 0.423 و 0.461 (وهذا متوقع لأن التحليل الأساسي كان بدون دلالة).

الطريقة الثانية لتنفيذ اختبارات post hoc مماثلة لما فعلناه من أجل اختبار Kruskal-Wallis في الفقرة 5.4.13. نأخذ الفرق بين مراتب المتوسط للمجموعات المختلفة ونقارن هذه الفروق مع قيمة تستند إلى قيمة z (المصححة من أجل عدد المقارنات المنفّذة) وثابت يعتمد على حجم العينة الكلي N (ويساوي 10 في هذا المثال) وعدد الحالات التجريبية k (ويساوي 3 في هذا المثال). المتراجحة هي:

$$\left|\overline{R}_u - \overline{R}_v\right| \geq z_{\alpha/k(k-1)}\sqrt{\frac{k(k+1)}{6N}} \qquad (4.13)$$

يمثل الحد الأيسر من المتراجحة القيمة المطلقة للفرق بين مرتبة المتوسط للمجموعتين اللتين تتم مقارنتهما. علينا معرفة قيمة الحد zα/k(k-1). إذا استخدمنا القيمة التقليدية للدلالة (α=0.05) فإننا نجد α/k(k-1)=0.00833. لذلك فإن الحد zα/k(k-1) يعني "قيمة z التي تكون من أجلها α/k(k-1) قيمة فقط من قيم z الأخرى أكبر". نبحث في العمود المسمى Smaller Portion من الجدول في الملحق A1 عن القيمة 0.00833 ونأخذ قيمة z الموجودة في نفس الصف من العمود المسمى z. في هذه الحالة لدينا القيمتان 0.00842 و 0.00820 اللتان تعطيان قيم z التالية 2.39 و 2.40، وبما أن القيمة 0.00833 تقع في منتصف المسافة بين هاتين القيمتين فإن قيمة z الموافقة تكون 2.395، ولكننا نلتزم جانب الأمان ونأخذ القيمة 2.40. نحسب الحد الأيمن من المتراجحة:

$$\text{الفرق الحرج} = z_{\alpha/k(k-1)}\sqrt{\frac{k(k+1)}{6N}}$$

$$= 2.40\sqrt{\frac{3\times(3+1)}{6\times10}}$$

$$= 1.07$$

Ranks

		N	Mean Rank	Sum of Ranks
Weight after 1 month (Kg) - Weight at Start (Kg)	Negative Ranks	4[a]	7.00	28.00
	Positive Ranks	6[b]	4.50	27.00
	Ties	0[c]		
	Total	10		
Weight after 2 month (Kg) - Weight at Start (Kg)	Negative Ranks	5[d]	6.00	30.00
	Positive Ranks	5[e]	5.00	25.00
	Ties	0[f]		
	Total	10		
Weight after 2 month (Kg) - Weight after 1 month (Kg)	Negative Ranks	4[g]	7.25	29.00
	Positive Ranks	6[h]	4.33	26.00
	Ties	0[i]		
	Total	10		

a. Weight after 1 month (Kg) < Weight at Start (Kg)

b. Weight after 1 month (Kg) > Weight at Start (Kg)

c. Weight after 1 month (Kg) = Weight at Start (Kg)

d. Weight after 2 month (Kg) < Weight at Start (Kg)

e. Weight after 2 month (Kg) > Weight at Start (Kg)

f. Weight after 2 month (Kg) = Weight at Start (Kg)

g. Weight after 2 month (Kg) < Weight after 1 month (Kg)

h. Weight after 2 month (Kg) > Weight after 1 month (Kg)

i. Weight after 2 month (Kg) = Weight after 1 month (Kg)

Test Statistics[b]

	Weight after 1 month (Kg) - Weight at Start (Kg)	Weight after 2 month (Kg) - Weight at Start (Kg)	Weight after 2 month (Kg) - Weight after 1 month (Kg)
Z	-.051[a]	-.255[a]	-.153[a]
Asymp. Sig. (2-tailed)	.959	.799	.878
Exact Sig. (2-tailed)	1.000	.846	.922
Exact Sig. (1-tailed)	.500	.423	.461
Point Probability	.039	.038	.038

a. Based on positive ranks.

b. Wilcoxon Signed Ranks Test

الخرج 15.13

وبما أنه يتم استخدام نفس المشتركين فإنه يمكننا استخدام الفرق الخرج من أجل جميع المقارنات. الخطوة التالية هي حساب جميع الفروق بين مراتب المتوسط لجميع المجموعات (يمكن إيجاد مراتب المتوسط في الخرج 13.13) ووضعهما في الجدول 6.13.

المقارنة	$\bar{R}_u$	$\bar{R}_v$	$\bar{R}_u - \bar{R}_v$	$\lvert\bar{R}_u - \bar{R}_v\rvert$
شهر واحد- البداية	1.90	2.00	-0.10	0.10
شهرين- البداية	1.90	2.10	-0.20	0.20
شهرين- شهر واحد	2.00	2.10	-0.10	0.10

الجدول 6.13 الفروق بين مراتب المتوسط لبيانات مثال الحمية

وتعني المتراجحة (4.13) أنه إذا كانت الفروق بين مراتب المتوسط أكبر من أو تساوي الفرق الحرج فإن ذلك الفرق مهم. وفي هذه الحالة تعني أنه إذا كان أحد الفروق أكبر من 1.07 فإنه يكون ذا دلالة. ولكن جميع الفروق هي أصغر من الفرق الحرج (انظر الجدول 6.13) لذلك نستنتج عدم وجود مجموعات مختلفة بشكل كبير وهذا ينسجم مع عدم الدلالة للتحليل الأولي للتباين.

6.5.13 حساب حجم الأثر

ذكرنا سابقاً أنه لا توجد طريقة سهلة لتحويل إحصائية كاي مربع التي لها أكثر من درجة حرية واحدة إلى حجم أثر r، كما أنه ليس مفيداً دائماً حساب حجم الأثر لأثر عام كالذي يتم اختباره بواسطة Friedman's ANOVA. لذلك يكون من المفيد حساب حجم الأثر للمقارنات التي تم تنفيذها بعد ANOVA. وكما رأينا في الفقرة 5.3.13 فهناك طريقة مباشرة وسهلة للحصول على حجم الأثر r من اختبار Wilcoxon للمرتبة ذات الإشارة. كما يمكن حساب حجم الأثر لاختبارات Wilcoxon التي تم استخدامها بعد التحليل الأساسي. وهذه القيم ستكون مفيدة بحد ذاتها.

من أجل المقارنة الأولى (البداية مقابل شهر واحد)، يبين الخرج 15.13 أن قيمة z هي 0.051-، وبما أنها مستندة على مقارنة مجموعتين تحوي كل منهما 10 عناصر فإن العدد الكلي للمشاهدات هو 20 ويكون حجم الأثر:

$$r_{Start-1\,month} = \frac{-0.051}{\sqrt{20}} = -0.01$$

ومن أجل المقارنة الثانية (البداية مقابل شهرين)، يبين الخرج 15.13 أن قيمة z هي 0.225- وهي مستندة على 20 مشاهدة ولذلك يكون حجم الأثر:

$$r_{Start-2\,months} = \frac{-0.225}{\sqrt{20}} = -0.06$$

ومن أجل المقارنة الأخيرة (شهر مقابل شهرين)، يبين الخرج 15.13 أن قيمة z هي 0.153- وهي مستندة على 20 مشاهدة ولذلك يكون حجم الأثر:

$$r_{1\,month-2\,months} = \frac{-0.153}{\sqrt{20}} = -0.03$$

ونظراً لانعدام الدلالة لاختبارات Wilcoxon فإن جميع الآثار الناتجة شبه معدومة لأن حجم الأثر قريب جداً من الصفر.

7.5.13 كتابة النتائج وتفسيرها

من أجل Friedman's ANOVA، ينبغي علينا تقديم إحصائية الاختبار χ^2 وعدد درجات الحرية ودلالتها. ويمكن أن يتم ذلك بالشكل:

✓ لم يتغير وزن المشتركات بشكل كبير خلال شهرين من الحمية $\chi^2(2)=0.20, p<0.05$.

وبما أن التحليل الأولي بدون دلالة فإنه يمكننا عدم تقديم اختبارات post hoc لهذه البيانات، ولكن إذا أردت في حالة معينة تقديم هذه الاختبارات فإنه يمكنك تقديم ذلك بالشكل التالي (تذكر أن إحصائية الاختبار T هي القيمة الأصغر بين مجموعي المراتب لكل اختبار، وهي مبينة في الخرج 15.13):

✓ لم يتغير وزن المشتركات بشكل كبير خلال شهرين من الحمية $\chi^2(2)=0.20, p<0.05$. وتم استخدام اختبارات Wilcoxon لمتابعة البحث في هذه النتيجة. وقد تم تطبيق تصحيح Bonferroni بحيث أصبحت قيمة الدلالة الحرجة هي0.0167. وقد تبين أن وزن المشتركات لم يتغير بشكل كبير من بداية الحمية حتى نهاية الشهر الأول T=27, r=-0.10، أو من بداية الحمية حتى نهاية الشهر الثاني T=25, r=-0.06، أو من نهاية الشهر الأول حتى نهاية الشهر الثاني T=26, r=-0.03. ويمكننا أن نستنتج أن هذه الحمية فاشلة.

أفكار مهمة

- يقارن Friedman's ANOVA عدة حالات تجريبية عندما يشارك نفس المشتركين في جميع الحالات وتكون البيانات الناتجة موزعة بشكل غير طبيعي أو أنها تخرق فرضية ANOVA وحيد الاتجاه للقياسات المكررة.
- ابحث عن قيمة الدلالة في الصف المسمى Asymp. Sig. فإذا كانت أقل من 0.05 فإن الحالات مختلفة بشكل كبير.
- يمكنك متابعة التحليل الأساسي باختبارات Wilcoxon للمرتبة ذات الإشارة بين كل حالتين من الحالات التجريبية، ويكون الاختبار ذا دلالة إذا كانت قيمة الدلالة أصغر من ناتج قسمة 0.05 على عدد الاختبارات.
- يتم تقديم إحصائية $\chi 2$ مع درجات حريتها ودلالتها. ومن أجل اختبارات post hoc يتم تقديم الإحصائية T وحجم الأثر. كما يمكنك تقديم العلامة z مع قيمة دلالتها، وتقديم قيم الوسط مع مجالاتها الموافقة.

6.13 ما الذي اكتشفناه عن الإحصاء؟

يمكن أن تكون الاختبارات مثل اختبار t و ANOVA صامدة لخرق الفرضيات، ويمكن إجراء التصحيحات للتأكد من أن هذه الاختبارات البارامترية دقيقة عند انهيار الفرضيات. وقد تعاملنا هذا الفصل مع حل بديل لخرق فرضيات البارامترية، وهو استخدام اختبارات تعتمد على ترتيب البيانات. وبدأنا مع اختبار Wilcoxon لمجموع المراتب واختبار Mann-Whitney، اللذين يتم استخدامهما لمقارنة مجموعتين مستقلتين. وقد سمح لنا التعامل مع هذين الاختبارين بالتعرف على تفاصيل عملية ترتيب البيانات. انتقلنا بعد ذلك إلى اختبار Wilcoxon للمرتبة ذات الإشارة الذي يستخدم لمقارنة حالتين مرتبطتين. وقد اختبرنا أوضاعاً معقدة تحوي عدة حالات تجريبية (اختبار Kruskal-Wallis للحالات المستقلة، و Friedman's ANOVA للحالات المرتبطة). وقد عرضنا نظرية الاختبار لكل من هذه الاختبارات، ثم ركزنا على كيفية تنفيذ الاختبارات في برنامج SPSS، وتفسير النتائج وتقديم نتائج الاختبار.

7.13 المصطلحات الأساسية التي اكتشفناها

اختبار Cochran's Q	(Cochran's Q)
إجرائية Friedman's ANOVA	(Friedman's ANOVA)
اختبار Jonckheere-Terpstra	(Jonckheere-Terpstra test)
إحصائية Kendall's W	(Kendall's W)
اختبار Kolmogorov-Smirnov Z	(Kolmogorov-Smirnov Z)
اختبار Kruskal-Wallis	(Kruskal-Wallis test)
اختبار Mann-Whitney	(Mann-Whitney test)
اختبار McNemar	(McNemar test)
اختبار الوسط	(Median test)
طريقة مونت كارلو	(Monte Carlo method)
الاختبارات اللابارامترية	(Non-parametric tests)
الترتيب	(Ranking)
اختبار الإشارة	(Sign test)
سلاسل Wald-Wolfowitz	(Wald-Wolfowitz runs)

اختبار Wilcoxon لمجموع المراتب (Wilcoxon rank-sum test)

اختبار Wilcoxon للمرتبة ذات الإشارة (Wilcoxon signed-rank test)

8.13 مهمات يجب تنفيذها

- **المهمة الأولى:** اهتم أحد علماء النفس بالفروق بين الرجال والكلاب، وراقب مجموعة من الكلاب ومجموعة من الرجال في أوضاع طبيعية. وقد قام بتصنيف عدة سلوكيات على أنها تصرفات شبيهة بتصرفات الكلاب (كالتبول بجانب الأشجار، وملاحقة الإناث، وغيرها). وأحصى عدد هذه التصرفات لكل رجل من الرجال ولكل كلب من الكلاب خلال مدة 24 ساعة. وقد افترض أن الكلاب تظهر تصرفات"شبيهة بتصرفات الكلاب" أكثر من الرجال. يحوي الملف MenLikeDogs.sav هذه البيانات، وعليك تحليلها باستخدام اختبار Mann-Whitney.

- **المهمة الثانية:** كثر النقاش في السنوات الماضية حول تأثير الرسائل المخفية في الأغاني على المستمعين. وقد اهتم أحد علماء النفس بهذا الموضوع، وقام بإعداد نسخة من أغنية Baby one more time للمغنية Britney Spears فوضع فيها رسالة "سلم روحك لملك الظلام" بحيث يكررها الكورس. ثم أخذ الأغنية الأصلية مع النسخة المعدّلة، وطلب من مجموعة مؤلفة من 32 شخصاً الاستماع إلى إحدى النسختين (بشكل عشوائي). وبعد 6 أشهر طلب من نفس المجموعة الاستماع إلى النسخة الثانية (التي لم تسمعها في المرة الأولى). وبذلك يكون كل مشترك قد استمع إلى النسختين ولكن بفارق زمني 6 أشهر. وقد أحصى عالم النفس عدد الماعز التي تم تضحيتها في الأسبوع الذي تلى الاستماع إلى كل نسخة. وقد افترض أن الرسالة المخفية ستقود إلى تضحية عدد أكبر من الماعز. يحوي الملف DarkLord.sav هذه البيانات، وعليك تحليلها باستخدام اختبار Wilcoxon للمرتبة ذات الإشارة.

- **المهمة الثالثة:** اهتم أحد علماء النفس بآثار برامج التلفزيون على الحياة العائلية. وافترض أنه من خلال التعلم بالمشاهدة فإن بعض البرامج تشجع الناس على تقليد سلوك الشخصيات فيها. ويمكن أن يؤثر ذلك بدوره على علاقات المشاهدين الشخصية. لذلك فقد أخذ عدة حلقات من برامج التلفزيون الشعبية وعرضها على 54 عائلة مكونة من شخصين، ثم ترك كل عائلة لمدة ساعة في الغرفة بعد مشاهدة العرض، وأحصى عدد المرات التي تجادل أو تشاجر فيها أفراد العائلة. وقد شاهدت جميع الأسر البرامج الثلاثة بفاصل أسبوع واحد بين البرنامجين. والبرامج المنتقاة هي مسلسل Eastenders (الذي يصور حياة البؤس المليئة بالمشاجرات والكذب والخيانة الزوجية وغيرها). ومسلسل Friends (الذي يصور مجموعة من الأصدقاء المحبين جداً)، وبرنامجاً عن الحيتان من قناة National Geographic (الذي يمكن اعتباره كمجموعة مراقبة). يحوي الملف Eastenders.sav البيانات لهذه المهمة، وعليك تحليلها بتنفيذ Friedman's ANOVA.

- **المهمة الرابعة:** اهتم أحد الباحثين بمحاولة منع ظاهرة الخوف من المهرجين (Coulrophobia) عند الأطفال. وقرر إجراء تجربة يعرّض فيها مجموعات مختلفة من الأطفال (15 طفلاً في كل مجموعة) لأشكال مختلفة من المعلومات الإيجابية عن المهرجين. وهكذا استمتعت المجموعة الأولى بمشاهدة مجموعة من إعلانات McDonald's التي تُظهر Ronald مع الأطفال يعلمهم حب أمهاتهم. واستمتعت المجموعة الثانية إلى قصة المهرج الذي يساعد الأطفال التائهين في الغابة. بينما استمتعت المجموعة الثالثة بمشاهدة مهرج حقيقي يقوم بصنع الحيوانات من البالونات في قاعة الصف. أما المجموعة الرابعة فكانت مجموعة المراقبة ولم تشاهد أو تشارك بأي شيء. قام الباحث بعد ذلك بتقييم شخصي لمدى حب الأطفال للمهرجين تنتج عنه علامة تتراوح بين 0 (عدم الخوف من المهرجين أبداً) و5 (خوف تام من المهرجين). يحوي الملف Coulrophobia.sav البيانات لهذه المهمة، وعليك تحليلها باستخدام اختبار Kruskal-Wallis.

يحوي الملف Answers(Chapter 13).pdf الإجابات على هذه الأسئلة.

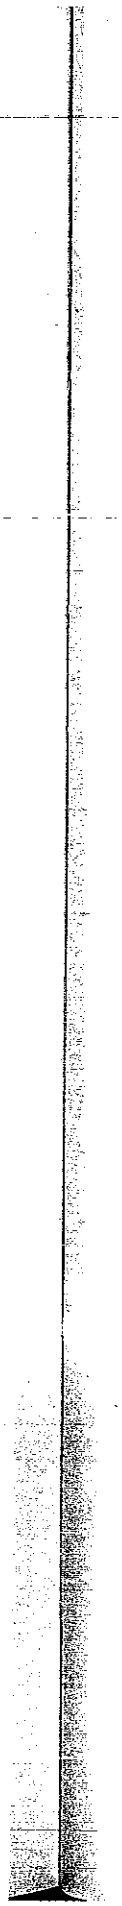

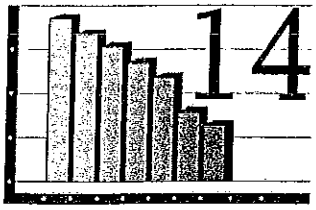

التحليل متعدد المتغيرات للتباين (MANOVA)

1.14 بماذا يخبرنا هذا الفصل؟

رأينا في الفصول الخمسة السابقة كيف يمكن استخدام النموذج الخطي العام (GLM) لاكتشاف الفروق بين المجموعات في حالة متحول تابع وحيد. على كل حال، هناك بعض الحالات التي نهتم فيها بعدة متحولات تابعة، وعندها يصبح نموذج ANOVA البسيط غير مناسب. وبدلاً من ذلك يمكننا أن نستخدم توسيعاً لهذه التقنية يدعى التحليل متعدد المتغيرات للتباين (أو MANOVA) ويمكن النظر إليه على أنه ANOVA في الحالات التي تحوي عدة متحولات تابعة. وتنطبق مبادئ ANOVA على MANOVA بحيث يمكننا استخدام MANOVA عند وجود متحول مستقل وحيد أو عدة متحولات مستقلة، كما يمكننا النظر إلى التفاعلات بين المتحولات المستقلة، وإجراء المقارنات لمعرفة المجموعة المختلفة عن بقية المجموعات. يمكن استخدام ANOVA في الحالات التي يوجد فيها متحول تابع وحيد (أو نتيجة واحدة) فقط ولذلك يدعى بالاختبار وحيد المتغير Univariate test (Univariate تعني متحولاً واحداً)، أما MANOVA فهو مصمم للنظر إلى عدة متحولات تابعة (أو نتائج) بآن واحد ولذلك يدعى بالاختبار متعدد المتغيرات Multivariate test (Multivariate تعني عدة متحولات). سيشرح هذا الفصل بعض أسس MANOVA. كما سيحوي فقرة نظرية مطوّلة لشرح آلية عمل MANOVA. ننتقل بعدها لعرض مثال باستخدام برنامج SPSS وتفسير الخرج الناتج عن MANOVA. ويقودنا ذلك للنظر إلى اختبار إحصائي آخر يُعرف باسم تحليل التابع المميز (discriminant function analysis).

2.14 مدخل: نقاط التشابه والاختلاف مع ANOVA

إذا جمعنا البيانات عن عدة متحولات تابعة فإنه يمكننا ببساطة تنفيذ ANOVA منفصل لكل متحول تابع على حدا. وبالعودة إلى الفصل 8 نتذكر أننا طرحنا سؤالاً مشابهاً حول تفضيل استخدام ANOVA على عدة اختبارات t. والجواب على السؤال التالي: لماذا نستخدم MANOVA بدلاً من عدة عمليات ANOVA هو ذاته، فكلما زاد عدد الاختبارات المنفذة على نفس البيانات تضخم معدل الخطأ حسب العائلة (أنظر الفقرة 1.2.8). إذاً كلما زاد عدد المتحولات التابعة التي يتم

قياسها، زاد عدد عمليات ANOVA المطلوب تنفيذها، وكان احتمال ارتكاب الخطأ من النوع الأول أكبر.

وعلى كل حال، هناك أسباب أخرى لتفضيل MANOVA على عدة عمليات ANOVA، إذ أن هناك معلومات إضافية هامة يمكن الحصول عليها من MANOVA. إذا تم تنفيذ ANOVA لكل متحول تابع فإن أي علاقة بين المتحولات التابعة تصبح مهملة. وهكذا نفقد المعلومات عن أي ارتباط يمكن أن يكون موجوداً بين المتحولات التابعة. أما MANOVA الذي يشمل جميع المتحولات التابعة في نفس التحليل، فإنه يأخذ بعين الاعتبار العلاقات بين متحولات النتيجة. وبخصوص هذه النقطة فإن ANOVA يدلنا عما إذا كانت المجموعات مختلفة وفق بُعد واحد، بينما يملك MANOVA القدرة على اكتشاف الاختلاف بين المجموعات وفق تركيب من الأبعاد. فعلى سبيل المثال، يدلنا ANOVA عن كيفية التمييز بين مجموعات المشتركين من خلال العلامات لمتحول تابع وحيد (فعلى سبيل المثال يمكننا أن نميز بين السائقين، وغير السائقين، والسائقين المخمورين من خلال عدد ضحاياهم من المشاة). أما MANOVA فيشمل معلومات عن عدة قياسات للنتيجة ولذلك يخبرنا عما إذا كان ممكناً التمييز بين مجموعات المشتركين من خلال تركيب من العلامات لعدة متحولات تابعة. فعلى سبيل المثال، قد لا يكون ممكناً التمييز بين السائقين، وغير السائقين، والسائقين المخمورين من خلال عدد الضحايا من المشاة فقط، ولكن يمكن التمييز من خلال تركيب من عدد الضحايا من المشاة، وعدد أعمدة المصابيح الكهربائية التي يصدمونها، وعدد الحوادث مع السيارات الأخرى. لذلك يكون MANOVA أكثر قدرة على اكتشاف أثر ما، لأنه يستطيع اكتشاف فيما إذا كانت المجموعات تختلف وفق تركيب من المتحولات، بينما يستطيع ANOVA اكتشاف الاختلاف بين المجموعات وفق متحول وحيد. ولهذه الأسباب يكون MANOVA مفضلاً على تنفيذ عدة عمليات ANOVA.

1.2.14 تحذير

من خلال الوصف الذي قدمناه حول MANOVA قد يتخيل البعض أنه اختبار بسيط يسمح بقياس المئات من المتحولات التابعة ثم وضعها في التحليل. إن هذا غير صحيح. ولا ننصح بوضع جميع المتحولات التابعة في MANOVA ما لم تكن هناك أسس نظرية أو عملية تبرر ذلك. وقد ذكرنا في بداية الكتاب أن الإجرائيات الإحصائية هي طرق للتعامل مع الأرقام، فإذا وضعت ما تريد من الأرقام فإنك ستحصل على نتائج ذات معنى إحصائياً، ولكن من غير المحتمل أن تكون ذات معنى عملياً أو فعلياً. وفي الحالات التي تتوافر فيها أسس نظرية جيدة لتضمين بعض (وليس كل) المتحولات التابعة، يجب عليك تنفيذ عمليات تحليل منفصلة: إحداها للمتحولات المختبرة تجريبياً، وأخرى للمتحولات ذات المعنى نظرياً. والمهم هنا هو عدم تضمين مجموعة كبيرة من المتحولات التابعة في MANOVA لأنك فقط قمت بقياسها.

2.2.14 نقاط الجدل الحالية

يعتبر MANOVA، مثل ANOVA، اختباراً ثنائي المرحلة يتم فيه أولاً تنفيذ اختبار إجمالي قبل تطبيق إجرائيات محددة للتعامل مع الفروق بين المجموعات. ومازالت هناك نقاشات حول مرحلتي الإجرائية MANOVA. فمن أجل التحليل الأساسي هناك 4 طرق شائعة الاستخدام لتقييم الدلالة الكلية لـــ MANOVA، وتتمحور النقاشات حول أفضل طريقة من حيث القدرة وحجم العينة. إضافة لذلك هناك جدل حول مدى أفضلية التحليل وتفسير فروقات المجموعات عندما يكون MANOVA الإجمالي ذو دلالة. وهناك مقاربتان أساسيتان لمتابعة التحليل: ANOVA وحيد المتغير وتحليل المميز.

وهناك جدل أيضاً يحيط بقدرة MANOVA (قدرة MANOVA على اكتشاف أثر موجود فعلياً). وقد ذكرنا في الفقرة السابقة أن MANOVA يتمتع بقدرة أكبر من ANOVA على اكتشاف الآثار لأنه يأخذ الارتباط بين المتحولات التابعة بعين الاعتبار. على كل حال، إن موضوع القدرة أكثر تعقيداً من التلميح إليه بعبارة بسيطة. فقد وجد Ramsey (1982) أنه مع ازدياد الارتباط بين المتحولات التابعة تنخفض قدرة MANOVA. وقاد ذلك Tabachnick & Fidell (2001) للقول بأن MANOVA يعمل بشكل أفضل عندما تكون المتحولات التابعة ذات ارتباط عكسي مرتفع، وبشكل مقبول عند ارتباط المتحولات التابعة بشكل معتدل في أحد الاتجاهين (طردياً أو عكسياً)، وأن MANOVA عديم الفائدة عندما تكون المتحولات التابعة غير مرتبطة. وفي المقابل، أظهرت دراسة Stevens (1980) لأثر ارتباط المتحولات التابعة على قدرة الاختبار أن "القدرة في حالة الارتباط الداخلي القوي هي في معظم الحالات أعلى منها في حالة الارتباط الداخلي المعتدل، وفي بعض الحالات أعلى بكثير". إن هذه النتائج متعارضة نوعاً ما، وتتركنا في حيرة حول طبيعة العلاقة بين القدرة والارتباط الداخلي بين المتحولات التابعة. ولحسن الحظ فقد قام Cole et al. (1994) بعمل رائع لتوضيح هذه العلاقة، ووجدوا أن قدرة MANOVA تعتمد على تركيب من الارتباط بين المتحولات التابعة وحجم الأثر. وباختصار، إذا كنا نتوقع أن نجد أثراً فإن MANOVA سيملك قدرة أكبر إذا كانت القياسات مختلفة نوعاً ما (وحتى إذا كانت مرتبطة عكسياً)، وإذا كانت فروق المجموعات في نفس الاتجاه من أجل كل قياس. إذا كان لدينا متحولان تابعان، يُظهر أحدهما فرقاً كبيراً للمجموعات، ويُظهر الآخر فرقاً صغيراً أو عدم وجود فرق، فإن القدرة سترداد إذا كان هذان المتحولان مرتبطين بشكل قوي. وقد اقتصرت دراسة Cole et al. على مقارنة مجموعتين فقط، ولذلك فإن اعتبارات القدرة أكثر تعقيداً في حالات المجموعات المتعددة.

3.2.14 المثال لهذا الفصل

سنستخدم مثالاً وحيداً في القسم المتبقي من هذا الفصل للتعرف على آلية عمل MANOVA وطريقة تنفيذه في برنامج SPSS. تخيّل أننا نهتم بآثار علاج السلوك الإدراكي على الاضطراب القاهر

الهوَسي (Obsessive Compulsive Disorder OCD). يمكننا أن نقارن مجموعة من الأشخاص الذين يعانون من OCD وقد تمت معالجتهم بعلاج السلوك الإدراكي (CBT) وبعد علاجهم بالعلاج السلوكي (BT) مع مجموعة من الأشخاص الذين ما زالوا يعانون من OCD ولم يتلقوا أي علاج (NT). فعلى سبيل المثال، في حالة OCD إذا كان أحد الأشخاص مهووساً بالجراثيم والعدوى، فإن هذا الاضطراب يُظهر نفسه في غسل اليدين الهوسي، وهذا يؤثر على عدد مرات غسيل اليدين فعلياً (السلوك) وعدد مرات التفكير بغسل اليدين (الإدراك). وإذا كنا نهتم بمعرفة مدى نجاح العلاج، فلا يكفي أن ننظر فقط إلى النتائج السلوكية (انخفاض التصرفات الهوسية مثلاً) وإنما يجب أن نعرف فيما إذا كان الإدراك قد تغير أيضاً. لذلك وفي هذا المثال، فقد تم قياس متحولين تابعين اثنين: حدوث التصرفات المرتبطة بالهوس (actions) وحدوث التفكير المرتبط بالهوس (thoughts)، وذلك في يوم عادي واحد.

يبين الجدول 1.14 البيانات لهذا المثال، ويمكن إيجادها في الملف OCD.sav أيضاً. ينتمي المشتركون إلى المجموعة 1 (CBT) والمجموعة 2 (BT) والمجموعة 3 (NT)، وتم قياس المتحولين لجميع المشتركين ضمن هذه المجموعات.

	المتحول التابع الأول: Actions			المتحول التابع الثاني: Thoughts		
المجموعة	المجموعة 1 CBT	المجموعة 2 BT	المجموعة 3 NT	المجموعة 1 CBT	المجموعة 2 BT	المجموعة 3 NT
	5	4	4	14	14	13
	5	4	5	11	15	15
	4	1	5	16	13	14
	4	1	4	13	14	14
	5	4	6	12	15	13
	3	6	4	14	19	20
	7	5	7	12	13	13
	6	5	4	15	18	16
	6	2	6	16	14	14
	4	5	5	11	17	18
المتوسط	4.90	3.70	5.00	13.40	15.20	15.00
الانحراف المعياري	1.20	1.77	1.05	1.90	2.10	2.36
التباين	1.43	3.12	1.11	3.60	4.40	5.56
المتوسط الكلي	$\bar{X}_{grand(Actions)} = 4.53$			$\bar{X}_{grand(Thoughts)} = 14.53$		
التباين الكلي	$S^2_{grand(Actions)} = 2.1195$			$S^2_{grand(thoughts)} = 4.8780$		

الجدول 1.14 البيانات للمثال OCD

3.14 نظرية MANOVA

إن نظرية MANOVA صعبة الفهم دون معرفة جبر المصفوفات (وهذا يتخطى نطاق الكتاب). لذلك سنقدم أسس MANOVA باستخدام المصفوفات دون أن يتطلب ذلك فهم كيفية استخدام المصفوفات بالضبط.

1.3.14 مدخل إلى المصفوفات

المصفوفة (matrix) هي مجموعة من الأرقام المرتبة في أسطر وأعمدة. وقد استخدمنا مصفوفة في هذا الكتاب دون الإشارة إلى ذلك، إنه محرر البيانات في برنامج SPSS. ففي محرر البيانات لدينا مجموعة من الأرقام مرتبة في أسطر وأعمدة. وتملك المصفوفة عدداً من الأسطر وعدداً من الأعمدة، وعادة نحدد أبعاد المصفوفة باستخدام الأرقام. فإذا قلنا مصفوفة 2×3 فهذا يعني أنها مصفوفة ذات سطرين و 3 أعمدة، ومصفوفة 5×4 فهذا يعني أنها مصفوفة ذات 5 أسطر و 4 أعمدة، ونكتب:

$$\begin{pmatrix} 2 & 5 & 6 \\ 3 & 5 & 8 \end{pmatrix} \qquad \begin{pmatrix} 2 & 4 & 6 & 8 \\ 3 & 4 & 6 & 7 \\ 4 & 3 & 5 & 8 \\ 2 & 5 & 7 & 9 \\ 4 & 6 & 6 & 9 \end{pmatrix}$$

مصفوفة 2×3 مصفوفة 5×4

ويمكن التفكير بالمصفوفات من حيث أن كل سطر يمثل البيانات لمشترك واحد، وكل عمود يمثل البيانات المتعلقة بمتحول معين. لذلك من أجل المصفوفة 5×4 يمكننا أن نتخيل حالةً حيث تم اختبار 5 مشتركين في 4 متحولات، وهكذا تكون علامات المشترك الأول هي 2 للمتحول الأول، و 6 للمتحول الثالث. تدعى القيم ضمن المصفوفة عادة بالمكونات أو العناصر.

المصفوفة المربعة (Square matrix) هي مصفوفة فيها عدد الأسطر يساوي عدد الأعمدة. وفي هذا النوع من المصفوفات يكون من المفيد التمييز بين العناصر القطرية (العناصر الواقعة على الخط القطري الواصل بين العنصر العلوي الأيسر والعنصر السفلي الأيمن) والعناصر غير القطرية (العناصر التي لاتقع على القطر الرئيسي). وفي المصفوفة المربعة الموضحة فإن العناصر القطرية هي 5 و 12 و 2 و6 أما العناصر غير القطرية فهي بقية العناصر:

$$\begin{pmatrix} 5 & 3 & 6 & 10 \\ 3 & 12 & 4 & 6 \\ 6 & 4 & 2 & 7 \\ 10 & 6 & 7 & 6 \end{pmatrix}$$

مصفوفة مربعة

إذا كانت جميع العناصر القطرية تساوي 1، والعناصر غير القطرية تساوي 0 فإن المصفوفة تدعى بالمصفوفة المحايدة (identity matrix):

$$\begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

مصفوفة محايدة

هناك حالة خاصة من المصفوفات حيث تكون البيانات قادمة من شخص واحد فقط وهي تعرف باسم شعاع السطر (row vector). أما إذا كان هناك عمود واحد في المصفوفة فتدعى عندئذ بشعاع العمود (column vector). في الأمثلة التالية يمكن التفكير بشعاع السطر على أنه يمثلً علاقات شخص واحد من أجل 4 متحولات مختلفة، أما شعاع العمود فيمكن أن يمثل العلامات لخمسة مشتركين من أجل متحول واحد:

$$(2 \quad 6 \quad 4 \quad 8) \qquad \begin{pmatrix} 5 \\ 6 \\ 10 \\ 15 \\ 6 \end{pmatrix}$$

شعاع السطر شعاع العمود

ومع هذه المعرفة البسيطة بالمصفوفات يمكننا الانتقال لإلقاء نظرة بسيطة على استخدامها في تنفيذ MANOVA.

2.3.14 بعض المصفوفات الهامة

كما في حالة ANOVA فإننا نهتم بشكل أساسي بمعرفة مقدار التباين الذي يمكن تبريره بالتلاعب التجريبي. لذلك نريد معرفة مجموع المربعات العائد لمتحول التجميع (التغاير المنهجي SS_M)، ومجموع المربعات العائد للفروق الطبيعية بين المشتركين (التغاير المتبقي SS_R)، وطبعاً المقدار الكلي للتغاير المطلوب تبريره (SS_T)، ولمزيد من التفاصيل عن مصادر هذه التغايرات عليك قراءة الفصلين 5 و8 مرة أخرى. وقد ذكرنا سابقاً أن MANOVA يأخذ بعين الاعتبار عدة متحولات تابعة بآن واحد، ويقوم بذلك عن طريق المصفوفة التي تحوي المعلومات عن التباين الذي يساهم به كل من المتحولات التابعة.

من أجل اختبار F وحيد المتغير (مثل ANOVA) قمنا بحساب نسبة التباين المنهجي إلى التباين اللامنهجي من أجل متحول تابع وحيد. في MANOVA يتم اشتقاق إحصائية الاختبار بمقارنة نسبة التباين المنهجي إلى التباين اللامنهجي لعدة متحولات تابعة. وتتم هذه المقارنة باستخدام نسبة المصفوفة التي تمثل التباين المنهجي لجميع المتحولات التابعة إلى المصفوفة التي تمثل التباين اللامنهجي لجميع المتحولات التابعة. تدعى المصفوفة التي تمثل التباين المنهجي (مجموع المربعات للنموذج من أجل جميع المتحولات) بمصفوفة مجموع المربعات والجداء المتصالب الافتراضي (hypothesis SSCP)

ويرمز لها بالرمز H. وتدعى المصفوفة التي تمثل التباين اللامنهجي (مجموع المربعات للبواقي من أجل جميع المتحولات) بمصفوفة مجموع المربعات والجداء المتصالب للخطأ (error SSCP) ويرمز لها بالرمز E. وأخيراً تدعى المصفوفة التي تمثل المقدار الكلي للتباين الموجود من أجل كل متحول تابع (مجموع المربعات الكلي لكل متحول تابع) بمصفوفة مجموع المربعات والجداء المتصالب الكلي (total SSCP) ويرمز لها بالرمز T.

سنبين لاحقاً كيفية استخدام هذه المصفوفات بنفس طريقة مجاميع المربعات البسيطة (SS_T وSS_R وSS_M) في ANOVA لاشتقاق إحصائية اختبار تمثل نسبة التباين المنهجي إلى التباين غير المنهجي في النموذج. ربما لاحظتَ التسمية مجموع المربعات والجداء المتصالب (SSCP) للمصفوفات. من البديهي تسمية هذه المصفوفات بمصفوفات مجموع المربعات، ولكن لماذا هناك إشارة للجداء المتصالب في التسمية؟ لقد تعرفنا على انحرافات الجداء المتصالب في الفصل 4 ورأينا أنها تمثل القيمة الكلية للخطأ المركب بين متحولين (فهي تمثل تقديراً غير قياسي للارتباط الكلي بين متحولين). فبينما يكون مجموع المربعات لمتحول ما هو مجموع مربعات الفروق بين القيم المشاهدة وقيمة المتوسط فإن الجداء المتصالب هو الخطأ المركب الكلي بين متحولين. وقد ذكرنا سابقاً أن MANOVA يملك القدرة للمساهمة بأي ارتباط بين المتحولات التابعة ويقوم بذلك عن طريق هذه الجداءات المتصالبة.

3.3.14 حساب MANOVA يدوياً

لنبدأ بتنفيذ ANOVA وحيد المتغير على كل من المتحولين التابعين في مثال OCD (أنظر الجدول 1.14). يمكن العودة للفصل 8 (وخاصة الفقرتين 4.2.8 و 8.2.8) للتعرف على نموذج ANOVA.

1.3.3.14 ANOVA وحيد المتغير من أجل المتحول الأول (Actions)

هناك 3 مجاميع للمربعات ينبغي حسابها. علينا أولاً تقييم مقدار التغايرية المطلوب تبريرها ضمن البيانات (SS_T) ، بعد ذلك علينا معرفة الجزء من هذه التغايرية التي يمكن تبريرها من قبل النموذج (SS_M) وأخيراً علينا تقييم مقدار الخطأ في النموذج (SS_R). وبمساعدة الفصل 8 يمكننا حساب هذه القيم.

- **المقدار $SS_{T(Actions)}$:** يتم الحصول على المجموع الكلي للمربعات بحساب الفرق بين كل من العلامات التي يبلغ عددها 20 وقيمة المتوسط لهذه العلامات، ثم تربيع هذه الفروق، وجمع المربعات معاً. أو يمكن أن نطلب من برنامج SPSS حساب التباين لهذه البيانات (بغض النظر عن المجموعة التي تنتمي إليها العلامة) ثم ضرب هذه القيمة بعدد يساوي أقل بواحد من عدد العلامات:

$$SS_T = s^2_{grand}(n-1)$$
$$= 2.1195(30-1)$$
$$= 61.47$$

- **المقدار $SS_{M(Actions)}$:** يتم حساب هذه القيمة بأخذ الفرق بين المتوسط لكل مجموعة والمتوسط الكلي ثم تربيع هذه الفروق، وضرب القيم الناتجة بعدد العلامات في المجموعة وجمعها معاً:

$$SS_M = 10 \times (4.90 - 4.53)^2 + 10 \times (3.70 - 4.53)^2 + 10 \times (5.00 - 4.53)^2$$
$$= 10.47$$

- **المقدار $SS_{R(Actions)}$:** يتم حساب هذه القيمة بأخذ الفرق بين كل علامة ومتوسط المجموعة التي تنتمي إليها، ثم تربيع هذه الفروق وجمعها معاً، أو يمكن أن نطلب من برنامج SPSS حساب التباين ضمن كل مجموعة، وضرب هذه القيمة لكل مجموعة بعدد يساوي أقل بواحد من عدد العلامات ثم جمع هذه القيم معاً:

$$SS_R = s^2_{CBT}(n_{CBT} - 1) + s^2_{BT}(n_{BT} - 1) + s^2_{NT}(n_{NT} - 1)$$
$$= (1.433)(10 - 1) + (3.122)(10 - 1) + (1.111)(10 - 1)$$
$$= 51.00$$

الخطوة التالية هي حساب متوسط مجموع المربعات (متوسط المربعات) وذلك بتقسيم مجموع المربعات على عدد درجات الحرية (أنظر الفقرة 7.2.8):

مجموع المربعات SS	عدد درجات الحرية df	متوسط المربعات MS
$SS_{M(Actions)}$=10.47	2	5.235
$SS_{R(Actions)}$=51.00	27	1.889

المرحلة الأخيرة هي حساب F بتقسيم متوسط المربعات للنموذج MS_M على متوسط المربعات للخطأ في النموذج MS_R:

$$F = \frac{MS_M}{MS_R} = \frac{5.235}{1.889} = 2.771$$

ويمكن تقييم هذه القيمة بمقارنتها مع القيم الحرجة للنسبة F.

2.3.3.14 ANOVA وحيد المتغير من أجل المتحول الثاني (Thoughts)

كما في حالة المتحول التابع الأول، هناك 3 مجاميع للمربعات ينبغي حسابها بنفس الطريقة السابقة:

- **المقدار $SS_{T(Thoughts)}$:**

$$SS_T = s^2_{grand}.(n - 1)$$
$$= 4.878 \times (30 - 1)$$
$$= 141.46$$

- **المقدار $SS_{M(Thoughts)}$:**

$$SS_M = 10 \times (13.40 - 14.53)^2 + 10 \times (15.2 - 14.53)^2 + 10 \times (15.0 - 14.53)^2$$
$$= 19.47$$

- **المقدار $SS_{R(Thoughts)}$:**

$$SS_R = s^2_{CBT}(n_{CBT} - 1) + s^2_{BT}(n_{BT} - 1) + s^2_{NT}(n_{NT} - 1)$$
$$= (3.6)(10 - 1) + (4.4)(10 - 1) + (5.56)(10 - 1)$$
$$= 122$$

الخطوة التالية هي حساب متوسط مجموع المربعات (متوسط المربعات) بتقسيم مجموع المربعات على عدد درجات الحرية (أنظر الفقرة 7.2.8):

مجموع المربعات SS	عدد درجات الحرية df	متوسط المربعات MS
$SS_{M(Thoughts)}$=19.47	2	9.735
$SS_{R(Thoughts)}$=122.00	27	4.519

المرحلة الأخيرة هي حساب F بتقسيم متوسط المربعات للنموذج MS_M على متوسط المربعات للخطأ في النموذج MS_R:

$$F = \frac{MS_M}{MS_R} = \frac{9.735}{4.519} = 2.154$$

ويمكن تقييم هذه القيمة بمقارنتها مع القيم الحرجة للنسبة F.

3.3.3.14 العلاقة بين المتحولات التابعة: الجداءات المتصالبة

نعلم مسبقاً أن MANOVA يستخدم نفس مجاميع المربعات مثل ANOVA، وفي الفقرة التالية سترى بالضبط كيفية استخدام هذه القيم. وقد ذكرنا سابقاً أن MANOVA تأخذ بعين الاعتبار العلاقة بين المتحولات التابعة وتقوم بذلك باستخدام الجداءات المتصالبة. ولكي نكون أكثر تحديداً، هناك 3 جداءات متصالبة مختلفة متعلقة بمجاميع المربعات الثلاثة التي حسبناها في حالة ANOVA وحيد المتغير، أي أن هناك جداء متصالب كلي وجداء متصالب عائد للنموذج، وجداء متصالب للباقي.

لنتعرف أولاً على الجداء المتصالب الكلي (CP_T). ذكرنا في الفصل 4 أن الجداء المتصالب هو جداء الفرق بين العلامات والمتوسط في مجموعة ما بالفرق بين العلامات والمتوسط في مجموعة أخرى. في حالة الجداء المتصالب الكلي فإن المتوسط المعني هو المتوسط الكلي لكل متحول تابع (أنظر الجدول 2.14). وهكذا يمكننا أن نعتمد معادلة الجداء المتصالب المبينة في الفصل 4 باستخدام متحولين تابعين بحيث نحصل على معادلة الجداء المتصالب الكلي (المعادلة (1.14)). لذلك ومن أجل كل متحول تابع، نأخذ كل علامة ونطرح منها المتوسط الكلي لذلك المتحول. وتبقى لدينا قيمتان لكل مشترك (واحدة لكل متحول تابع) ويجب أن نضربهما ببعض لنحصل على الجداء المتصالب لكل مشترك. ويمكن أن نحصل على الجداء المتصالب الكلي بجمع الجداءات المتصالبة لجميع المشتركين. يبين الجدول 2.14 هذه العملية.

$$CP_T = \Sigma\left(X_{i(Actions)} - \overline{X}_{grand(Actions)}\right)\left(X_{i(Thoughts)} - \overline{X}_{grand(Thoughts)}\right) \qquad (1.14)$$

$D_1 \times D_2$	$(Thoughts - \bar{X}_{grand(Thoughts)})$ D_2	$(Actions - \bar{X}_{grand(Actions)})$ D_1	Thoughts	Actions	المجموعة
-0.25	-0.53	0.47	14	5	
-1.66	-3.53	0.47	11	5	
-0.78	1.47	-0.53	16	4	
0.81	-1.53	-0.53	13	4	
-1.19	-2.53	0.47	12	5	CBT
0.81	-0.53	-1.53	14	3	
-6.25	-2.53	2.47	12	7	
0.69	0.47	1.47	15	6	
2.16	1.47	1.47	16	6	
1.87	-3.53	-0.53	11	4	
0.28	-0.53	-0.53	14	4	
-0.25	0.47	-0.53	15	4	
5.40	-1.53	-3.53	13	1	
1.87	-0.53	-3.53	14	1	
-0.25	0.47	-0.53	15	4	BT
6.57	4.47	1.47	19	6	
-0.72	-1.53	0.47	13	5	
1.63	3.47	0.47	18	5	
1.34	-0.53	-2.53	14	2	
1.16	2.47	0.47	17	5	
0.81	-1.53	-0.53	13	4	
0.22	0.47	0.47	15	5	
-0.25	-0.53	0.47	14	5	
0.28	-0.53	-0.53	14	4	
-2.25	-1.53	1.47	13	6	NT
-2.90	5.47	-0.53	20	4	
-3.78	-1.53	2.47	13	7	
-0.78	1.47	-0.53	16	4	
-0.78	-0.53	1.47	14	6	
1.63	3.47	0.47	18	5	
CPT=Σ(D1×D2)=5.47			14.53	4.53	$\bar{X}_{grand}$

الجدول 2.14 حساب الجداء المتصالب الكلي (CP_T)

إن الجداء المتصالب الكلي هو مؤشر على العلاقة الكلية بين المتحولين. على كل حال، يهمنا تأثير التلاعب التجريبي على العلاقة بين المتحولات التابعة، ويتم قياس هذه العلاقة بالجداء المتصالب

للنموذج (CP_M). يتم حساب CP_M بطريقة مشابهة لحساب مجموع المربعات للنموذج. يتم أولاً حساب الفرق بين المتوسط لكل مجموعة والمتوسط الكلي لكل متحول تابع، ثم يتم حساب الجداء المتصالب بضرب الفروق المحسوبة لكل مجموعة، ثم ضرب حاصل الجداء بعدد العلامات ضمن المجموعة. وتوضح المعادلة (2.14) مبدأ الحساب، ويبين الجدول 3.14 طريقة الحساب:

$$CP_M = \Sigma n \left[\left(\bar{X}_{group(Actions)} - \bar{X}_{grand(Actions)}\right)\left(\bar{X}_{group(Thoughts)} - \bar{X}_{grand(Thoughts)}\right)\right] \quad (2.14)$$

$N(D_1 \times D_2)$	$D_1 \times D_2$	$\left(\bar{X}_{group} - \bar{X}_{grand}\right)$ D_2	$\bar{X}_{group}$ Thoughts	$\left(\bar{X}_{group} - \bar{X}_{grand}\right)$ D_1	$\bar{X}_{group}$ Actions	المجموعة
-4.18	-0.418	-1.13	13.4	0.37	4.9	CBT
-5.56	-0.556	0.67	15.2	-0.83	3.7	BT
2.21	0.221	0.47	15.0	0.47	5.0	NT
CPM=ΣN(D1×D2)=-7.53			14.53		4.53	$\bar{X}_{grand}$

الجدول 3.14 حساب الجداء المتصالب للنموذج (CP_M)

أخيراً، علينا معرفة تأثير الفروق الفردية في أداء المشتركين على العلاقة بين المتحولين التابعين. يدلنا الجداء المتصالب الباقي (CP_R) على تأثير الفروق الفردية أو الخطأ في النموذج على العلاقة بين المتحولين التابعين. يتم حساب CP_R بطريقة مشابهة لحساب الجداء المتصالب الكلي باستثناء أنه يستخدم متوسطات المجموعات بدلاً من المتوسط الكلي (أنظر المعادلة (3.14)). يبين الجدول 4.14 طريقة الحساب:

$$CP_R = \Sigma\left(X_{i(Actions)} - \bar{X}_{group(Actions)}\right)\left(X_{i(Thoughts)} - \bar{X}_{group(Thoughts)}\right) \quad (3.14)$$

D1×D2	$\left(Thoughts - \bar{X}_{group(Thoughts)}\right)$ D2	Thoughts	$\left(Actions - \bar{X}_{group(Actions)}\right)$ D1	Actions	المجموعة
0.06	0.60	14	0.10	5	
-0.24	-2.40	11	0.10	5	
-2.34	2.60	16	-0.90	4	
0.36	-0.40	13	-0.90	4	
-0.14	-1.40	12	0.10	5	CBT
-1.14	0.60	14	-1.90	3	
-2.94	-1.40	12	2.10	7	
1.76	1.60	15	1.10	6	
2.86	2.60	16	1.10	6	
2.16	-2.40	11	-0.90	4	
0.40		13.4		4.9	$\bar{X}_{CBT}$

D1×D2	$(Thoughts - \bar{X}_{group(Thoughts)})$ D2	Thoughts	$(Actions - \bar{X}_{group(Actions)})$ D1	Actions	المجموعة
-0.36	-1.20	14	0.30	4	
-0.06	-0.20	15	0.30	4	
5.94	-2.20	13	-2.70	1	
3.24	-1.20	14	-2.70	1	
-0.06	-0.20	15	0.30	4	BT
8.74	3.80	19	2.30	6	
-2.86	-2.20	13	1.30	5	
3.64	2.80	18	1.30	5	
2.04	-1.20	14	-1.70	2	
2.34	1.80	17	1.30	5	
22.60		15.2		3.7	$\bar{X}_{BT}$
2.00	-2.00	13	-1.00	4	
0.00	0.00	15	0.00	5	
0.00	-1.00	14	0.00	5	
1.00	-1.00	14	-1.00	4	
-2.00	-2.00	13	1.00	6	NT
-5.00	5.00	20	-1.00	4	
-4.00	-2.00	13	2.00	7	
-1.00	1.00	16	-1.00	4	
-1.00	-1.00	14	1.00	6	
0.00	3.00	18	0.00	5	
-10.00		15		5	$\bar{X}_{NT}$
CPR=Σ(D1×D2)=13					

الجدول 4.14 حساب الجداء المتصالب الباقي (CP_R)

يمكن أن نلاحظ أيضاً أنه يمكن حساب الجداء المتصالب الباقي (CP_R) بطرح الجداء المتصالب للنموذج من الجداء المتصالب الكلي:

$$CP_R = CP_T - CP_M$$
$$= 5.47 - (-7.53)$$
$$= 13$$

على كل حال، من المفيد حساب الجداء المتصالب الباقي يدوياً للتحقق من عدم ارتكاب الأخطاء في حساب الجداءين المتصالبين الآخرين. يمكن أن نستفيد من حقيقة أن مجموع الجداءات المتصالبة للنموذج والباقي يساوي قيمة الجداء المتصالب الكلي لعملية تحقق مضاعفة.

يدلنا كل جداء من الجداءات المتصالبة المختلفة على بعض المعلومات الهامة عن العلاقة بين المتحولين التابعين. وعلى الرغم من أننا استخدمنا سيناريو بسيطاً للمحافظة على بساطة الحسابات الرياضية فإنه يمكننا توسيع هذه المبادئ للحالات الأكثر تعقيداً. فعلى سبيل المثال، إذا قسنا 3 متحولات تابعة فإنه يمكن حساب الجداءات المتصالبة بين كل زوج من المتحولات التابعة (كما فعلنا في هذا المثال) ثم إدخالها في مصفوفة SSCP المناسبة (أنظر الفقرة التالية). وكلما ازداد تعقيد المسألة، ازدادت كمية الحسابات الواجب تنفيذها. وفي هذه الحالات يصبح استخدام البرامج مثل SSPS مفيداً جداً.

4.3.3.14 المصفوفة T (Total SSCP)

في هذا المثال لدينا متحولان تابعان فقط ولذلك تكون أبعاد جميع المصفوفات SSCP هي 2x2. إذا كان لدينا 3 متحولات تابعة فإن أبعاد المصفوفات الناتجة هي 3x3. تحوي المصفوفة T مجموع المربعات الكلي لكل من المتحولين التابعين والجداء المتصالب الكلي بين المتحولين التابعين. يمكن تخيّل العمود الأول والسطر الأول على أنها تمثل أحد المتحولين التابعين، والعمود الثاني والسطر الثاني على أنها تمثل المتحول التابع الآخر:

	العمود الأول Actions	العمود الثاني Thoughts
السطر الأول Actions	$SS_{T(Actions)}$	CP_T
السطر الثاني Thoughts	CP_T	$SS_{T(Thoughts)}$

وقد حسبنا هذه القيم في الفقرات السابقة لذلك نضع القيم في الخلايا المناسبة من المصفوفة:

$$T = \begin{pmatrix} 61.47 & 5.47 \\ 5.47 & 141.47 \end{pmatrix}$$

من القيم في المصفوفة (وما تمثله هذه القيم) نرى بوضوح أن المصفوفة T تمثل المقدار الكلي للتغاير الموجود ضمن البيانات وكذلك التبعية المشتركة الموجودة بين المتحولين التابعين. ويجب أن نلاحظ أن العناصر غير القطرية متساوية (الجداء المتصالب الكلي) لأن هذه القيمة هامة من أجل كلا المتحولين التابعين.

5.3.3.14 المصفوفة E (Residual or Error SSCP)

تحوي المصفوفة E مجموع المربعات للبواقي لكل متحول تابع والجداء المتصالب الباقي بين المتحولين التابعين. وهذه المصفوفة مشابهة للمصفوفة T باستثناء أن المعلومات فيها متعلقة بالخطأ في النموذج:

	العمود الأول Actions	العمود الثاني Thoughts
السطر الأول Actions	$SS_{R(Actions)}$	CP_R
السطر الثاني Thoughts	CP_R	$SS_{R(Thoughts)}$

لقد حسبنا هذه القيم في الفقرات السابقة لذلك نضعها ببساطة في أماكنها المناسبة في المصفوفة:

$$E = \begin{pmatrix} 51 & 13 \\ 13 & 122 \end{pmatrix}$$

من القيم في المصفوفة (وما تمثله هذه القيم) نرى بوضوح أن المصفوفة E تمثل التغاير اللامنهجي الموجود من أجل كل متحول تابع وكذلك التبعية المشتركة الموجودة بين المتحولين التابعين التي تعود لعوامل الصدفة فقط. وكما لاحظنا سابقاً فإن العناصر غير القطرية متساوية (الجداء المتصالب الباقي).

6.3.3.14 المصفوفة H (Model or Hypothesis SSCP)

تحوي المصفوفة H مجموع المربعات للنموذج لكل متحول تابع والجداء المتصالب للنموذج بين المتحولين التابعين:

	العمود الأول Actions	العمود الثاني Thoughts
السطر الأول Actions	$SS_{M(Actions)}$	CP_M
السطر الثاني Thoughts	CP_M	$SS_{M(Thoughts)}$

لقد حسبنا هذه القيم في الفقرات السابقة لذلك نضعها ببساطة في أماكنها المناسبة في المصفوفة:

$$H = \begin{pmatrix} 10.47 & -7.53 \\ -7.53 & 19.47 \end{pmatrix}$$

من القيم في المصفوفة (وما تمثله هذه القيم) نرى بوضوح أن المصفوفة H تمثل التغاير المنهجي الموجود من أجل كل متحول تابع وكذلك التبعية المشتركة الموجودة بين المتحولين التابعين التي تعود للتلاعب التجريبي (أو النموذج). وكما لاحظنا سابقاً فإن العناصر غير القطرية متساوية (الجداء المتصالب للنموذج).

إن المصفوفات قابلة للجمع، وهذا يعني أنه يمكن جمع مصفوفتين (أو طرحهما) وذلك بجمع (أو طرح) العناصر المتوافقة. عندما حسبنا ANOVA وحيد المتغير، رأينا أن مجموع المربعات الكلي هو

ناتج جمع مجموع المربعات للنموذج مع مجموع المربعات للبواقي ($SS_T=SS_M+SS_R$). وهذا صحيح من أجل MANOVA أيضاً باستثناء أننا نقوم هنا بجمع المصفوفات بدلاً من القيم الفردية:

$$T = H + E$$

$$T = \begin{pmatrix} 10.47 & -7.53 \\ -7.53 & 19.47 \end{pmatrix} + \begin{pmatrix} 51 & 13 \\ 13 & 122 \end{pmatrix}$$

$$= \begin{pmatrix} 10.47+51 & -7.53+13 \\ -7.53+13 & 19.47+122 \end{pmatrix}$$

$$= \begin{pmatrix} 61.47 & 5.47 \\ 5.47 & 141.47 \end{pmatrix}$$

4.3.14 مبدأ إحصائية الاختبار MANOVA

في ANOVA وحيد المتغير حسبنا نسبة التباين المنهجي إلى التباين اللامنهجي (حيث قسمنا متوسط المربعات للنموذج على متوسط المربعات للبواقي). والمكافئ في MANOVA سيكون تقسيم المصفوفة H على المصفوفة E. ولكن هناك مشكلة في المصفوفات إذ لا يمكن تقسيم مصفوفة على مصفوفة أخرى. لحسن الحظ هناك عملية مكافئة لعملية القسمة وهي الضرب بما يعرف بمقلوب المصفوفة. لذلك إذا أردنا تقسيم المصفوفة H على المصفوفة E فعلينا ضرب المصفوفة H بمقلوب المصفوفة E (ويرمز لها بالرمز E^{-1}). ولذلك فإن إحصائية الاختبار تعتمد على المصفوفة الناتجة عن جداء مصفوفة SSCP للنموذج (المصفوفة H) بمقلوب مصفوفة SSCP للبواقي(E^{-1})، وتدعى هذه المصفوفة HE^{-1}.

إن حساب مقلوب المصفوفة معقد جداً ولا حاجة لمعرفة كيفية تنفيذه لأن برنامج SPSS سيقوم به. ويحوي الملحق A.8 معلومات عن حساب مقلوب المصفوفة. بتنفيذ الحسابات نحصل على:

$$E^{-1} = \begin{pmatrix} 0.0202 & -0.0021 \\ -0.0021 & 0.0084 \end{pmatrix}$$

$$HE^{-1} = \begin{pmatrix} 0.2273 & -0.0852 \\ -0.1930 & 0.1794 \end{pmatrix}$$

تذكّر أن المصفوفة HE^{-1} تمثل نسبة التباين المنهجي في النموذج إلى التباين اللامنهجي في النموذج، ولذلك فإن المصفوفة الناتجة تكافئ من حيث المبدأ النسبة F في ANOVA وحيد المتغير. ومع ذلك فإن هناك مشكلة أخرى. ففي ANOVA نحصل على قيمة للنسبة F، أما في MANOVA فنحصل على مصفوفة تحوي عدة قيم. في هذا المثال وبسبب وجود متحولين تابعين، فإن المصفوفة تحوي 4 قيم (2×2)، وإذا كان لدينا 3 متحولات فإن عدد القيم في المصفوفة سيكون 9 (3×3). والمشكلة هي كيفية تحويل قيم هذه المصفوفة إلى قيمة وحيدة ذات معنى.

1.4.3.14 متغيرات التابع المميز

يمكن تبسيط مشكلة وجود عدة قيم لتقييم الدلالة الإحصائية وذلك بتحويل المتحولات التابعة إلى عوامل أو أبعاد قاعدية (ستتم مناقشة هذه العملية بالتفصيل في الفصل 15). وقد رأينا في الفصل 5 كيف يعمل التراجع المتعدد على مبدأ ملاءمة نموذج خطي لمجموعة من البيانات من أجل التنبؤ بمتحول النتيجة (أو المتحول التابع حسب مصطلحات ANOVA). وقد تشكّل النموذج الخطي من تركيب من المتحولات التنبؤية (أو المتحولات المستقلة) لكل منها مساهمة وحيدة في النموذج الخطي. يمكننا القيام بعمل مماثل هنا، باستثناء أننا نهتم بالمسألة المعاكسة (أي التنبؤ بالمتحول المستقل من خلال مجموعة من المتحولات التابعة). لذلك فمن الممكن حساب الأبعاد الخطية القاعدية للمتحولات التابعة. تدعى التراكيب الخطية من المتحولات التابعة بالمتغيرات (Variates) (وتدعى أحياناً بالعوامل (factors) أو بالمتحولات المستترة (latent variables)). وضمن هذا الإطار فإننا نرغب باستخدام هذه المتغيرات الخطية للتنبؤ بالمجموعة التي ينتمي إليها شخص ما (أي هل تمت معالجته باستخدام CBT أوBT أم أنه ينتظر العلاج) ولهذا فإننا نستخدمها لتمييز مجموعات من الأشخاص. ولهذا السبب تدعى هذه المتغيرات أحياناً بالتوابع المميزة أو بمتغيرات التابع المميز (Discriminant function Variates). ومع أننا قمنا بمقارنة وتماثل بين هذه التوابع المميزة والنموذج في التراجع الخطي، فما زال هناك فرق بينهما يتمثل بأنه يمكننا استخلاص عدة توابع مميزة من مجموعة من المتحولات التابعة، بينما تكون جميع المتحولات المستقلة مضمنة في نموذج واحد للتراجع المتعدد.

كيف نكتشف هذه التوابع المميزة؟ لن ندخل في التفاصيل كثيراً، ولكننا سنستخدم إجرائية رياضية في الزيادة للحد الأقصى، بحيث يكون التابع المميز الأولي (V_1) هو التركيب الخطي للمتحولات التابعة التي تجعل الفروق بين المجموعات أعظمية.

وينتج عن ذلك أن نسبة التباين المنهجي إلى التباين اللامنهجي(SS_M/SS_R) ستكون أعظمية من أجل المتغير الأول، ولكن المتغيرات التالية ستملك قيماً أصغر من هذه النسبة. تذكر أن هذه النسبة تشبه ما تمثله النسبة F في ANOVA وحيد المتغير، ولهذا نحصل على القيمة العظمى الممكنة للنسبة F عندما ننظر إلى التابع المميز الأول. يمكن كتابة هذا المتغير وفق معادلة التراجع الخطي (لأنه تركيب خطي للمتحولات التابعة):

$$\begin{aligned} Y &= b_0 + b_1.X_1 + b_2.X_2 \\ V_1 &= b_0 + b_1.DV_1 + b_2.DV_2 \\ V_i &= b_0 + b_1.\text{Actions} + b_2.\text{Thoughts} \end{aligned} \qquad (4.14)$$

تبين المعادلة (4.14) معادلة التراجع المتعدد من أجل متحولين تنبؤيين وتوسيع هذه المعادلة لتبين أن شكلاً مماثلاً من هذه المعادلة يمكن أن يصف التوابع المميزة. إن قيم b في هذه المعادلة هي الأثقال (كما في حالة التراجع) التي تدل على مساهمة كل متحول من المتحولات التابعة في المتغير المقصود.

يتم في التراجع الحصول على قيم b بطريقة المربعات الصغرى: أما في تحليل التابع المميز فيتم الحصول على قيم b الأشعة الخاصة (eigenvectors) (أنظر المربع 2.5) للمصفوفة HE^{-1}. وعملياً يمكننا أن نهمل b_0 لأنها تفيد في تحديد موقع المتغير في الفضاء الهندسي فقط، وهذا ليس ضرورياً عندما نستخدمه لتمييز المجموعات.

عندما يكون لدينا متحولان تابعان فقط ومجموعتين للمتحول المستقل فإن هناك متغير واحد فقط. وهذا يجعل السيناريو بسيطاً جداً، فإذا نظرنا إلى التابع المميز للمتحولات التابعة بدلاً من النظر إلى المتحولات التابعة ذاتها، فإننا نحصل على قيمة واحدة للنسبة (SS_M/SS_R) من أجل التابع المميز، ثم نقيّم هذه القيمة من أجل الدلالة. على كل حال، في الحالات الأكثر تعقيداً حيث هناك أكثر من متحولين تابعين أو أكثر من ثلاثة مستويات للمتحول المستقل (كما في المثال الحالي)، سيكون هناك أكثر من متغير واحد. ويكون عدد المتغيرات التي نحصل عليها أقل من عدد المتحولات التابعة (p) أو k-1 (حيث k عدد مستويات المتحول المستقل). في المثال الحالي، لدينا p=2 وكذلك k-1=2 لذلك سنتمكن من إيجاد متغيرين فقط. وقد ذكرنا سابقاً أنه يمكننا الحصول على قيم b التي تصف المتغيرات بحساب الأشعة الخاصة للمصفوفة HE^{-1}، وفي الحقيقة يمكننا اشتقاق شعاعين خاصين من هذه المصفوفة، يمثل أحدهما قيم b للمتغير الأول، ويمثل الآخر قيم b للمتغير الثاني. والأشعة الخاصة من حيث المبدأ هي الأشعة أو المتجهات المرتبطة بمصفوفة معينة والتي لا تتغير عند تحويل هذه المصفوفة إلى مصفوفة قطرية (أنظر المربع 5-2). والمصفوفة القطرية (diagonal matrix) هي مصفوفة عناصرها غير القطرية تساوي 0، وبتحويل المصفوفة HE^{-1} إلى مصفوفة قطرية فإننا نحذف جميع العناصر غير القطرية (وبذلك نخفّض عدد القيم الواجب اعتبارها من أجل اختبار الدلالة). وهكذا بحساب الأشعة الخاصة والقيم الخاصة فإننا نحصل على القيم التي تمثل نسبة التباين المنهجي إلى التباين اللامنهجي (لأنها لا تتغير بعملية التحويل)، ولكن عددها أصبح أقل بكثير. إن حساب الأشعة الخاصة معقد جداً، وبعد تنفيذ الحسابات نحصل على الأشعة الخاصة للمصفوفة HE^{-1}:

$$\text{الشعاع الخاص الأول} = \begin{pmatrix} 0.603 \\ -0.335 \end{pmatrix}$$

$$\text{الشعاع الخاص الثاني} = \begin{pmatrix} 0.425 \\ 0.339 \end{pmatrix}$$

بتعويض هذه القيم في معادلتي المتغيرين (وتذكر أننا نهمل الحد b_0) فإننا نحصل على النماذج المبينة في المعادلات (5.14):

$$V_1 = 0.603 \times \text{Actions} - 0.335 \times \text{Thoughts}$$
$$V_2 = 0.425 \times \text{Actions} + 0.339 \times \text{Thoughts} \qquad (5.14)$$

من الممكن استخدام هذه المعادلات لكل متغير من أجل حساب علامة كل شخص في المتغير. فعلى سبيل المثال، من أجل المشترك الأول في المجموعة CBT الذي يقوم بـــ 5 أفعال هوَسية، و14 تفكيراً هوَسياً، يمكننا حساب المتغيرين الأول والثاني باستخدام المعادلات (5.14):

$$V_1 = 0.603\times5 - 0.335\times14 = -1.675$$

$$V_2 = 0.425\times5 + 0.339\times14 = 6.871$$

إذا حسبنا علامات المتغير لكل مشترك ثم حسبنا المصفوفات SSCP (وهي H و E و T و HE^{-1}) التي استخدمناها سابقاً فإننا نجد أن جميع هذه المصفوفات تملك جداءات متصالبة معدومة، والسبب في ذلك أن المتغيرات الناتجة عن البيانات هي متعامدة، وهذا يعني أنها غير مرتبطة. وباختصار فإن المتغيرات الناتجة هي الأبعاد المستقلة الناتجة عن تركيب خطي للمتحولات التابعة التي تم قياسها.

إن لتخفيض البيانات خاصية مفيدة جداً وهي أنها إذا نظرنا إلى المصفوفة HE^{-1} المحسوبة من علامات المتغير (بدلاً من المتحولات التابعة) فإننا نجد أن جميع العناصر غير القطرية (الجداءات المتصالبة) تساوي 0. أما العناصر القطرية فهي تمثل نسبة التباين المنهجي إلى التباين اللامنهجي (أي SS_M/SS_R) لكل من المتغيرات القاعدية. ومن أجل البيانات في هذا المثال، فإن ذلك يعني أنه بدلاً من وجود 4 قيم لتمثيل نسبة التباين المنهجي إلى التباين اللامنهجي فإن لدينا قيمتان فقط. قد لايبدو هذا التخفيض كبيراً، ولكن بشكل عام إذا كان لدينا p متحول تابع فإننا نحصل عادة على p^2 قيمة لتمثيل نسبة التباين المنهجي إلى التباين اللامنهجي، ولكن استخدام التوابع المميزة يخفض عدد القيم إلى p قيمة فقط. فإذا كان لدينا 4 متحولات تابعة فإننا نحصل على 4 قيم فقط بدلاً من 16 قيمة، وهذا يبرر استخدام هذه العملية.

من أجل البيانات في هذا المثال تصبح المصفوفة HE^{-1} المحسوبة من علامات المتغير هي:

$$HE^{-1}_{Variates} = \begin{pmatrix} 0.335 & 0.000 \\ 0.000 & 0.073 \end{pmatrix}$$

من الواضح أننا نملك قيمتين فقط لتقييم الدلالة للفروق بين المجموعات. تدعى قيم العناصر القطرية للمصفوفة السابقة بالقيم الخاصة (eigenvalues) للمصفوفة HE^{-1} الأصلية. ويمكن حساب القيم الخاصة من البيانات مباشرة دون تشكيل الأشعة الخاصة. وهذه القيم تكافئ النسبة F في ANOVA، والخطوة الأخيرة إذاً هي تقييم هذه القيم مقارنة بما نتوقعه عن طريق الصدفة فقط. وهناك 4 طرق لتقييم هذه القيم.

2.4.3.14 أثر Pillai-Bartlett (V)

يُعطى أثر Pillai-Bartlett (ويدعى أحياناً أثر Pillai) بالمعادلة (6.14) حيث تمثل λ القيم الخاصة لكل من المتغيرات المميزة، و s عدد المتغيرات. وأثر Pillai هو مجموع نسب التباين المبرر في التوابع المميزة. ولذلك فهو شبيه بالنسبة SS_M/SS_T:

$$V = \sum_{i=1}^{s} \frac{\lambda_i}{1+\lambda_i} \qquad (6.14)$$

من أجل البيانات في المثال الحالي فإن قيمة V هي:

$$V = \frac{0.335}{1+0.335} + \frac{0.073}{1+0.073} = 0.319$$

ويمكن تحويلها إلى قيمة لها توزيع F تقريبي.

3.4.3.14 أثر Hotelling (T^2)

أثر Hotelling هو مجموع القيم الخاصة لكل متغير (أنظر المعادلة (7.14)). أي أنه مجموع النسب SS_M/SS_R لكلٍ من المتغيرات ولذلك يمكن مقارنته بالنسبة F في ANOVA مباشرة:

$$T = \sum_{i=1}^{s} \lambda_i = 0.335 + 0.073 = 0.408 \qquad (7.14)$$

4.4.3.14 قيمة Wilks's Lambda (Λ)

إن قيمة Wilks's Lambda هي جداء التباين غير المبرر لكل من المتغيرات، وتمثل نسبة تباين الخطأ إلى التباين الكلي (SS_R/SS_T) لكلٍ من المتغيرات:

$$\Lambda = \prod_{I=1}^{s} \frac{1}{1+\lambda_I} \qquad (8.14)$$

ومن أجل البيانات في المثال الحالي:

$$\Lambda = \left(\frac{1}{1+0.335}\right)\left(\frac{1}{1+0.073}\right) = 0.698$$

من الواضح أن القيم الخاصة الكبيرة (والتي تمثل أثراً تجريبياً كبيراً بحد ذاتها) تعطي قيمة Wilks's Lambda صغيرة، وبالتالي نحصل على دلالة إحصائية عندما تكون Wilks's Lambda صغيرة.

5.4.3.14 جذر Roy الأكبر

جذر Roy الأكبر هو القيمة الخاصة للمتغير الأول، أي أنه شبيه بأثر Hotelling ولكن من أجل المتغير الأول فقط:

$$\text{الجذر الأكبر} = \lambda_{largest} \qquad (9.14)$$

ويمثل نسبة التباين المبرر إلى التباين غير المبرر (SS_M/SS_R) من أجل التابع المميز الأول. ومن أجل البيانات في المثال الحالي فإن الجذر الأكبر هو 0.335 (القيمة الخاصة للمتغير الأول). ومن حيث المبدأ فإن هذه القيمة مماثلة للنسبة F في ANOVA وحيد المتغير. من الواضح أن جذر Roy يمثل أكبر

فرق بين المجموعات يمكن أن تعطيه البيانات المجمّعة. لذلك تكون هذه الإحصائية هي الأكثر فعالية في العديد من الحالات.

4.14 فرضيات MANOVA

يملك MANOVA فرضيات مماثلة لتلك المعتمدة مع ANOVA ولكنها موسعة لحالة عدة متغيرات:

- **الاستقلال (Independence):** يجب أن تكون المشاهدات مستقلة إحصائياً.
- **أخذ العينات عشوائياً (Random Sampling):** يجب أخذ البيانات بشكل عشوائي من المجتمع المقصود وأن يتم قياسها على مستوى المجال.
- **الطبيعية متعددة المتغيرات (Multivariate normality):** لقد افترضنا في ANOVA أن المتحول التابع موزع بشكل طبيعي ضمن كل مجموعة. وفي حال MANOVA، نفترض أن المتحولات التابعة (مجتمعة) تتمتع بالطبيعية متعددة المتغيرات ضمن المجموعات.
- **تجانس مصفوفات التباين المشترك (Homogeneity of Covariance matrices):** لقد افترضنا في ANOVA أن التباينات في كل المجموعات متساوية تقريباً (تجانس التباين). وفي MANOVA علينا أن نفترض أن ذلك صحيح لكل متحول تابع، ومن أجل الارتباط بين كل متحولين تابعين في كل المجموعات. ونتحقق من هذه الفرضية باختبار فيما إذا كانت مصفوفات التباين–التباين المشترك للمجتمع من أجل المجموعات المختلفة في التحليل هي متساوية (مصفوفة التباين–التباين المشترك هي شكل قياسي من مصفوفة SSCP).

عند خرق هذه الفرضيات فإن دقة إحصائية الاختبار متعدد المتغيرات الناتجة تكون موضع شك. ماذا نفعل عندئذ؟ لا يقدم برنامج SPSS نسخة لابارامترية من MANOVA، ولكن تم وضع بعض الأفكار اعتماداً على البيانات المرتبة (مثل الاختبارات اللابارامترية المقدمة في الفصل 13). ومع أن مناقشة هذه الأفكار تتخطى نطاق هذا الكتاب فإنه يمكننا القول أن بعض الأفكار يمكن أن تكون مفيدة عندما لا يمكن افتراض الطبيعية متعددة المتغيرات أو تجانس مصفوفات التباين المشترك.

1.4.14 التحقق من الفرضيات

يمكن التحقق من معظم الفرضيات بنفس الطريقة المتبعة من أجل الاختبارات وحيدة المتغير (أنظر الفصل 8)، أما الفرضيات الإضافية المتعلقة بالطبيعية متعددة المتغيرات وتجانس مصفوفات التباين المشترك فإنها تتطلب إجرائيات مختلفة. يمكن اختبار فرضية الطبيعية متعددة المتغيرات في برنامج SPSS ولذلك فإن الحل العملي الوحيد هو التحقق من هذه الفرضية من أجل كل متحول على حدا (أنظر الفصل 3). إن هذا الحل عملي (لأنه سهل التنفيذ) ومفيد (لأن طبيعية المتغير الوحيد هي شرط أساسي للطبيعية متعددة المتغيرات) ولكنه لا يضمن الطبيعية متعددة المتغيرات. ويمكن العودة لكتاب Stevens (1992) للتعرف على حلول بديلة.

أما فرضية تجانس مصفوفات التباين المشترك فيمكن التحقق منها بسهولة أكبر. أولاً يجب أن تتحقق الاختبارات وحيدة المتغير لتَساوي التباينات بين المجموعات. ويمكن التحقق من هذه الفرضية بسهولة وذلك باستخدام اختبار Levene (أنظر الفقرة 6.3). وكتحقق أولي يجب أن يكون اختبار Levene بدون دلالة من أجل جميع المتحولات التابعة. إن اختبار Levene لا يأخذ بعين الاعتبار التباينات المشتركة، ولذلك يجب مقارنة مصفوفات التباين-التباين المشترك بين المجموعات باستخدام اختبار Box. يجب أن يكون هذا الاختبار بدون دلالة إذا كانت المصفوفات متساوية. على كل حال، إن اختبار Box حساس جداً للانحرافات عن الطبيعية متعددة المتغيرات ولذلك يمكن أن يكون بدون دلالة ليس لأن المصفوفات متماثلة، ولكن لأن فرضية الطبيعية متعددة المتغيرات غير محققة. لذلك فمن الضروري تكوين فكرة عما إذا كانت البيانات تحقق فرضية الطبيعية متعددة المتغيرات وذلك قبل تفسير نتيجة اختبار Box.

2.4.14 اختيار إحصائية الاختبار

عندما يكون لدينا متغير قاعدي واحد فمن الضروري أن تكون إحصائيات الاختبار الأربع متماثلة. لذلك فمن المهم معرفة أفضل إحصائية اختبار من حيث القدرة والتماسك. وقد قام Olson (1974) و(1979) Stevens بدراسات موسعة حول قدرة إحصائيات الاختبار الأربع MANOVA. لاحظ Olson أن الإحصائيات الأربع تختلف قليلاً من حيث القدرة عندما تكون العينات صغيرة أو متوسطة الحجم. إذا كانت فروق المجموعات مركزة في المتغير الأول (كما هي الحال في معظم أبحاث علم الاجتماع) فإن إحصائية Roy تثبت قدرة أكبر (لأنها تأخذ بعين الاعتبار المتغير الأول فقط) يليها أثر Hotelling، ثم قيمة Wilks's Lambda وأخيراً أثر Pillai. وعندما تختلف المجموعات على أكثر من متغير واحد فإن ترتيب القدرة يصبح معكوساً (أثر Pillai يصبح الأكثر قدرة، وإحصائية Roy الأقل). المسألة الأخيرة المتعلقة بقدرة الاختبار هي حجم العينة وعدد المتحولات التابعة. وينصح Stevens باستخدام أعداد صغيرة من المتحولات التابعة (أقل من 10) ما لم يكن حجم العينة كبيراً.

ومن حيث التماسك فإن إحصائيات الاختبار الأربع متماسكة نسبياً تجاه خرق فرضية الطبيعية متعددة المتغيرات (على الرغم من أن جذر Roy يتأثر بالتوزيعات المسطّحة). إن جذر Roy ليس متماسكاً عند خرق فرضية تجانس مصفوفة التباين المشترك. وقد قادت الدراسات التي قام بها Olson & Stevens لاستنتاج أنه عندما تكون أحجام العينات متساوية فإن أثر Pillai هو الأكثر تماسكاً لخرق الفرضيات. على كل حال، عندما تكون أحجام العينات غير متساوية فإن هذه الإحصائية تتأثر بخرق تجانس مصفوفات التباين المشترك. وكقاعدة، عندما تكون أحجام العينات غير متساوية فإنه يجب التحقق من فرضية تجانس مصفوفات التباين المشترك باستخدام اختبار Box، فإذا كان هذا الاختبار بدون دلالة، وكانت فرضية الطبيعية متعددة المتغيرات محققة (مما يسمح بافتراض أن اختبار Box دقيق) فإن أثر Pillai يكون دقيقاً.

3.4.14 التحليل الملحق

ذكرنا في الفقرة 2.2.14 أن هناك جدلاً حول أفضل تحليل يتبع MANOVA الأساسي. الحل التقليدي هو تنفيذ ANOVA منفصل لكل متحول تابع عندما يكون MANOVA ذو دلالة. إذا تم تنفيذ هذا الحل فقد تتساءل لماذا ننفذ MANOVA أولاً (فقد قلنا سابقاً أن تنفيذ عدة عمليات ANOVA هو خيار سيء). والجواب هو أن ANOVA الذي يلي MANOVA ذا دلالة هو محمي بـ MANOVA الأولي. والفكرة هي أن الاختبار متعدد المتغيرات الكلي يحمي من تضخم معدلات الخطأ من النوع الأول وذلك لأنه إذا كان الاختبار الأولي بدون دلالة (أي أن فرضية العدم صحيحة) فإن أي اختبارات لاحقة تكون مهملة (لأن أي دلالة ستكون خطأً من النوع الأول وذلك لأن فرضية العدم صحيحة). على كل حال، إن مصطلح الحماية مضلل نوعاً ما لأن MANOVA ذو الدلالة يعكس فرقاً مهماً من أجل أحد (وليس جميع) المتحولات التابعة. يمكن بعد ذلك تنفيذ عدة عمليات ANOVA لاحقة من أجل جميع المتحولات التابعة، ولكن MANOVA يحمي المتحول التابع الذي تكون من أجله الفروق بين المجموعات موجودة بشكل فعلي. لذلك يمكن أن نطبق تصحيح Bonferroni على عمليات ANOVA اللاحقة.

إن حل ANOVA الذي يتبع MANOVA يفترض ضمنياً أن MANOVA ذو الدلالة لا يعود إلى المتحولات التابعة الممثلة لمجموعة من الأبعاد القاعدية التي تميز المجموعات. لذلك يوصي بعض الباحثين باستخدام تحليل المميز الذي يعثر على التركيب (أو التراكيب) الخطي للمتحولات التابعة الذي يفصل (أو يميز بين) المجموعات بشكل أفضل. وهذه الإجرائية تلائم MANOVA جداً لأنها تشمل العلاقات الموجودة بين المتحولات التابعة وهي مفيدة بالتأكيد في توضيح العلاقة بين المتحولات التابعة وعناصر المجموعات. إن الميزة الأساسية لهذا الحل مقارنة مع عدة عمليات ANOVA أنه يخفض المتحولات التابعة من حيث مجموعة الأبعاد القاعدية التي تعكس أبعاداً نظرية أو نفسية فعلية. توفر إجرائيات GLM القياسية في برنامج SPSS بشكل افتراضي عدة عمليات ANOVA وحيدة المتغير، ولكن ليس تحليل المميز. وعلى كل حال، يمكن الوصول إلى تحليل المميز عن طريق القوائم المختلفة، وسيستخدم الجزء المتبقي من هذا الفصل بيانات المثال OCD (الجدول 1.14) لتوضيح كيفية تنفيذ هذه التحاليل.

5.14 تنفيذ MANOVA في برنامج SPSS

1.5.14 التحليل الأساسي

يمكنك تحميل البيانات من الملف OCD.sav، أو إدخالها يدوياً. إذا أدخلت البيانات يدوياً فإنك بحاجة لثلاثة أعمدة، أحدهما يحوي متحول ترميز group (والذي يأخذ القيم CBT=1، BT=2، NT=3)، والعمودان الآخران لإدخال العلامات لكل من المتحولين التابعين (thoughts وactions).

بعد الانتهاء من إدخال البيانات يتم فتح مربع الحوار MANOVA الرئيسي باستخدام أمر القائمة Analyze ⇒ General Linear Model ⇒ Multivariate... (أنظر الشكل 2.14).

إن عمليات ANOVA (والمقارنات المتعددة المختلفة) المنفّذة بعد تحليل MANOVA الأساسي مشابهة لتنفيذ إجرائيات ANOVA منفصلة في برنامج SPSS لكل من المتحولات التابعة. إن مربع الحوار الرئيسي وخيارات MANOVA مشابهة جداً لإجرائية ANOVA العاملية التي رأيناها في الفصل 10. والفرق الأساسي في مربع الحوار الرئيسي هو أن الحيز Dependent Variables يتيح إدخال عدة متحولات تابعة. نختار المتحولين التابعين (actions و thoughts) من لائحة المتحولات وننقلهما إلى الحيز Dependent Variables. ثم نختار المتحول group من لائحة المتحولات وننقله إلى الحيز Fixed Factor(s). هناك أيضاً حيز لوضع المتغيرات. في هذا المثال، ليس لدينا متغيرات، وعلى كل حال يمكننا تطبيق مبادئ ANCOVA على حالة تعدد المتغيرات وتنفيذ تحليل متعدد المتغيرات للتباين المشترك (MANOVA). بعد تحديد المتحولات في التحليل، يمكننا فتح مربعات الحوار الأخرى بنقر الزر الموافق في القسم الأيمن من مربع الحوار:

الزر...Model يفتح مربع الحوار لتخصيص التحليل واختيار نوع مجاميع المربعات المستخدمة (أنظر الفقرة 2.3.10).

الزر ...Plots يفتح مربع الحوار لاختيار مخططات التفاعل. وهذا الخيار مفيد فقط عند قياس ثلاثة متحولات مستقلة على الأقل (أنظر الفقرة 3.3.10).

الزر...Save يفتح مربع الحوار لحفظ البواقي من أجل النموذج الخطي العام (GLM). وهذه الخيارات مفيدة للتحقق من أن النموذج يلائم البيانات (أنظر الفصل 5).

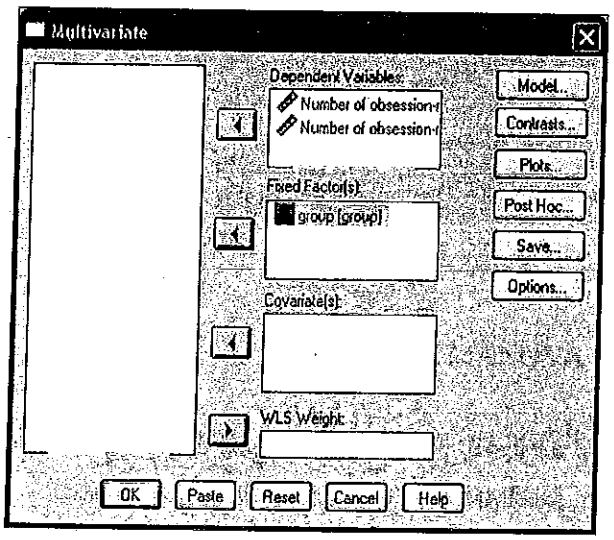

الشكل 2.14 مربع الحوار الرئيسي من أجل MANOVA

2.5.14 المقارنات المتعددة في MANOVA

الطريقة الافتراضية هي تنفيذ ANOVA وحيد المتغير منفصل لكل متحول تابع وذلك بعد تنفيذ MANOVA. ومن أجل هذه الاختبارات، يقدم برنامج SPSS نفس الخيارات كما في حالة ANOVA وحيد المتغير (أنظر الفصل 8). يفتح الزر...Contrasts مربع حوار لتحديد مقارنة واحدة من بين مجموعة المقارنات القياسية المتعددة من أجل المتحول (أو المتحولات) المستقلة في التحليل. يصف الجدول 6.8 ما تقوم به كل واحدة من تلك المقارنات، ومن أجل هذا المثال فإننا نستخدم المقارنة البسيطة Simple التي تقارن كل مجموعة من المجموعات التجريبية مع مجموعة المراقبة (بدون معالجة NT). تم ترميز المجموعة NT لتكون الفئة الأخيرة (لها الرمز الأعلى في محرر البيانات)، لذلك علينا اختيار متحول المجموعة وتغيير المقارنة إلى مقارنة بسيطة باستخدام الفئة الأخيرة كفئة مرجعية (أنظر الشكل 3.14). لمزيد من التفاصيل عن المقارنات يمكنك العودة للفقرة 10.2.8.

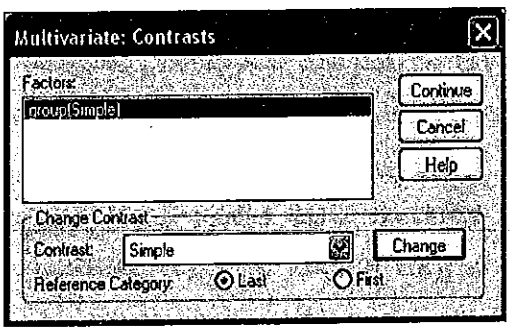

الشكل 3.14 المقارنات للمتحولات المستقلة في MANOVA

وبدلاً من تنفيذ مقارنة ما، يمكننا تنفيذ اختبارات post hoc على المتحول المستقل لمقارنة كل مجموعة مع باقي المجموعات. للوصول إلى مربع الحوار الخاص باختبارات post hoc ننقر الزر Post Hoc... إن مربع الحوار مماثل لمربع الحوار في حالة ANOVA العاملي (أنظر الشكل 5.10) ويجب أن يكون تحديد الاختبار معتمداً على نفس المعايير المبينة في الفقرة 11.2.8. ومن أجل المثال الحالي فإننا نقترح استخدام Games-Howell و REGWQ. بعد تحديد اختبارات post hoc نعود إلى مربع الحوار الرئيسي.

3.5.14 الخيارات الإضافية

انقر الزر ...Options في مربع الحوار الرئيسي لفتح مربع الحوار للخيارات Options (أنظر الشكل 4.14). إن مربع الحوار الناتج مشابه تقريباً لما نحصل عليه في ANOVA العاملي (أنظر الفقرة 6.3.10)، مع وجود بعض الخيارات الإضافية التي تستحق الإشارة إليها:

- **مصفوفات SSCP (SSCP matrices):** إذا حددت هذا الخيار فإن برنامج SPSS يعطي مصفوفة SSCP للنموذج، ومصفوفة SSCP للخطأ، ومصفوفة SSCP الكلية. ويمكن أن يكون الخيار مفيداً من أجل فهم حساب MANOVA.
- **مصفوفة SSCP للبواقي (Residual SSCP matrix):** إذا حددت هذا الخيار فإنه برنامج SPSS يعطي مصفوفة SSCP للخطأ، ومصفوفة التباين- التباين المشترك للخطأ، ومصفوفة الارتباط للخطأ. ومصفوفة التباين- التباين المشترك للخطأ هي المصفوفة التي يعتمد عليها اختبار Bartlett للكروية. يختبر اختبار Bartlett فيما إذا كانت هذه المصفوفة متناسبة مع المصفوفة المحايدة (أي أن التباينات المشتركة معدومة، والعناصر القطرية التي تمثل التباينات هي متساوية تقريباً).

أما بقية الخيارات فهي نفس الخيارات المشروحة في الفصل 10 من أجل ANOVA العاملي، لذلك ننصح بإعادة قراءة ذلك الفصل لتحديد الخيارات المفيدة.

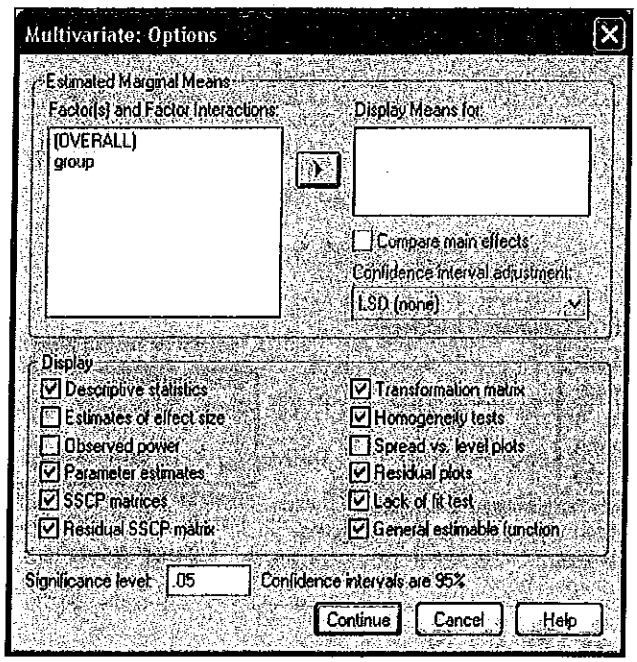

الشكل 4.14 الخيارات الإضافية في MANOVA

6.14 الخرج من MANOVA

1.6.14 التحليل التمهيدي واختبار الفرضيات

يعرض (الخرج 1.14) الجدول الأولي للإحصائيات الوصفية التي نحصل عليها بتحديد الخيار Descriptive Statistics في مربع الحوار Options (أنظر الشكل 4.14). ويحوي هذا الجدول قيم المتوسط الكلي ومتوسطات المجموعات مع الانحراف المعياري لكل متحول تابع. وتتطابق هذه القيم

مع القيم المحسوبة يدوياً في الجدول 1.14. من الواضح من خلال قيم المتوسط أن للمشتركين تفكيراً مرتبطاً بالهوس أكثر من التصرفات الهوسية.

Descriptive Statistics

	group	Mean	Std. Deviation	N
Number of obsession-related behaviours	CBT	4.90	1.197	10
	BT	3.70	1.767	10
	No Treatment Control	5.00	1.054	10
	Total	4.53	1.456	30
Number of obsession-related thoughts	CBT	13.40	1.897	10
	BT	15.20	2.098	10
	No Treatment Control	15.00	2.357	10
	Total	14.53	2.209	30

الخرج 1.14

يعرض الخرج 2.14 اختبار Box لفرضية تَساوي مصفوفات التباين المشترك (أنظر الفقرة 1.4.14). وتختبر هذه الإحصائية فرضية العدم بأن مصفوفات التباين- التباين المشترك هي نفسها في المجموعات الثلاث. لذلك إذا كانت المصفوفات متساوية (وتحققت بالتالي فرضية التجانس) فيجب أن تكون هذه الإحصائية بدون دلالة. من أجل البيانات في المثال الحالي فإن p=0.18 (وهي أكبر من 0.05) إذاً مصفوفات التباين المشترك متساوية تقريباً والفرضية محققة.

Box's Test of Equality of Covariance matrices[a]

Box's M	9.959
F	1.482
df1	6
df2	18168.923
Sig.	.180

Tests the null hypothesis that the observed covariance matrices of the dependent variables are equal across groups.

a. Design: Intercept+group

Bartlett's Test of Sphericity[a]

Likelihood Ratio	.042
Approx. Chi-Square	5.511
df	2
Sig.	.064

Tests the null hypothesis that the residual covariance matrix is proportional to an identity matrix.

a. Design: Intercept+group

الخرج 2.14

إذا كانت قيمة اختبار Box ذات دلالة (p<0.05) فإن مصفوفات التباين المشترك تكون مختلفة بشكل كبير، وتكون فرضية التجانس غير محققة. وأثر هذا الخرق للفرضية غير واضح. وقد ذكر Haskstain, Roed & Lind (1979) أن أثر Hotelling (T^2) متماسك في حالة مجموعتين عندما تكون أحجام العينات متساوية. وكقاعدة عامة، إذا كانت أحجام العينات متساوية فإننا نهمل اختبار Box لأنه غير مستقر، ونفترض أن إحصائيات Hotelling وPillai متماسكة (أنظر الفقرة 2.4.14). وإذا كانت أحجام المجموعات مختلفة فإنه لا يمكننا عندئذ افتراض التماسك (وخاصةً إذا كان اختبار Box ذا دلالة عند مستوى p<0.001). وكلما زاد عدد المتحولات التابعة المقاسة،

وكلما كانت الفروق بين أحجام العينات أكبر، أصبحت قيم الاحتمال التي يعطيها برنامج SPSS مشوهة أكثر. لذلك اقترح Tabchnick & Fidell (2001) أنه إذا أعطت العينات الكبيرة تباينات وتباينات مشتركة أكبر فإن قيم الاحتمال ستكون صارمة (ويمكن الثقة بالنتائج ذات الدلالة). على كل حال، إذا أعطت العينات الأصغر تباينات وتباينات مشتركة أكبر فإن قيم الاحتمال ستكون متسامحة أكثر ويجب التعامل عندئذ مع الفروق ذات الدلالة بحذر (بالرغم من الثقة بالآثار عديمة الدلالة). وهكذا فإننا نضطر لاعتبار اختبار Box عندما تكون أحجام العينات مختلفة، ويجب عدم الثقة به عندما لا يتم افتراض الطبيعية متعددة المتغيرات، ويجب التحقق من مصفوفات التباين-التباين المشترك للعينات لتقييم فيما إذا كانت قيم الاحتمال المطبوعة صارمة أو متسامحة.

يختبر اختبار Bartlett للكروية فيما إذا كانت فرضية الكروية محققة، وهو مفيد فقط في تصاميم القياسات المكررة وحيدة المتغير لأن MANOVA لا تحتاج هذه الفرضية.

2.6.14 إحصائيات اختبار MANOVA

يعرض الخرج 3.14 الجدول الرئيسي للنتائج. ويبين قيم إحصائيات الاختبار من أجل الاعتراض للنموذج Intercept (لأنه يمكن توصيف MANOVA كنموذج تراجع، ولكن ذلك يتخطى مجال هذا الكتاب) ومن أجل المتحول group. وما تهمنا هي آثار المتحول group لأنها تدلنا على آثار الأنواع المختلفة من العلاج على مرضى OCD. نلاحظ أن برنامج SPSS يعرض 4 إحصائيات متعددة المتغيرات، وتتطابق قيمها مع القيم المحسوبة في الفقرات 2.4.3.14 إلى 5.4.3.14. وقد تم تحويل هذه القيم إلى النسبة F في العمود الثالث. أما العمود الأهم فهو العمود الذي يحوي قيم الدلالة .Sig للنسب F. فمن أجل هذه البيانات، كانت قيم الدلالة للإحصائيات أقل من 0.05 (p=0.049 لأثر Pillai و p=0.050 لقيمة Wilks´s Lambda و p=0.020 لجذر Roy الأكبر). أما أثر Hotelling (p=0.051) فهو بدون دلالة من أجل المعيار المعتمد. وهذا السيناريو ممتع لأن إحصائية الاختبار التي سنختارها تحدد فيما إذا كنا سنقبل أو نرفض فرضية العدم التي تنص على عدم وجود فروق بين المجموعات. ومع معرفتنا بتماسك أثر Pillai عندما تكون أحجام العينات متساوية فإنه يمكننا الثقة بنتيجة إحصائية الاختبار، والتي تدل على فرق كبير. يوضح هذا المثال القدرة الإضافية المرتبطة بجذر Roy (ونلاحظ أنها أكثر دلالة من بقية الإحصائيات) وذلك عندما تكون فرضيات الاختبار محققة.

Multivariate Tests[a]

Effect		Value	F	Hypothesis df	Error df	Sig.
Intercept	Pillai's Trace	.983	745.230[a]	2.000	26.000	.000
	Wilks' Lambda	.017	745.230[a]	2.000	26.000	.000
	Hotelling's Trace	57.325	745.230[a]	2.000	26.000	.000
	Roy's Largest Root	57.325	745.230[a]	2.000	26.000	.000
group	Pillai's Trace	.318	2.557	4.000	54.000	.049
	Wilks' Lambda	.699	2.555[a]	4.000	52.000	.050
	Hotelling's Trace	.407	2.546	4.000	50.000	.051
	Roy's Largest Root	.335	4.520[b]	2.000	27.000	.020

a. Exact statistic

b. The statistic is an upper bound on F that yields a lower bound on the significance level.

c. Design: Intercept+group

الخرج 3.14

ومن هذه النتيجة يمكننا أن نستنتج أن نوع العلاج المستخدم له أثر كبير على مرضى OCD. ولكن طبيعة هذا الأثر ليست واضحة من خلال إحصائية الاختبار متعدد المتغيرات. فهي لا تدلنا عن المجموعات المختلفة، كما لاتدلنا على أثر العلاج على التفكير الهوسي أو التصرفات الهوسية أو على تركيب منهما. ولتحديد طبيعة هذا الأثر، يعطينا برنامج SPSS الاختبارات وحيدة المتغير.

3.6.14 إحصائيات الاختبار وحيدة المتغير

يعرض الخرج 4.14 جدولاً ملخصاً لاختبار Levene لتَسَاوي التباينات من أجل كل متحول من المتحولات التابعة. وهذه الاختبارات هي نفس الاختبارات التي نجدها عند تنفيذ ANOVA وحيد الاتجاه على كل متحول تابع بدوره (أنظر الفصل 8). يجب أن يكون اختبار Levene بدون دلالة من أجل جميع المتحولات التابعة وذلك إذا تحققت فرضية تجانس التباين. وتوضح نتائج هذه البيانات أن الفرضية محققة. وتعطينا هذه النتيجة الثقة بوثوقية الاختبارات وحيدة المتغير المتبعة، إضافة إلى تعزيز فرضية أن إحصائيات الاختبار متعددة المتغيرات متماسكة.

يحوي القسم التالي من الخرج جدول ANOVA الملخص من أجل المتحولات التابعة. ويهمنا الصف المسمى GROUP (لاحظ أن القيم في هذا الصف هي نفس القيم الموجودة في الصف المسمى Corrected Model، وذلك لأن النموذج الذي تتم ملاءمته للبيانات يحوي متحولاً مستقلاً وحيداً group). يحوي السطر المسمى GROUP جدول ANOVA الملخص لكل من المتحولات التابعة، والقيم معطاة من أجل مجاميع المربعات لكل من المتحولين التابعين (thoughts وactions) وهي تتطابق مع قيم SS_M المحسوبة في الفقرتين 1.3.3.14 و2.3.3.14 على الترتيب. يحوي السطر المسمى Error معلومات عن مجموع المربعات ومتوسط المربعات للبواقي من أجل المتحولين التابعين، وهذه القيم هي قيم SS_R التي تم حسابها في الفقرتين 1.3.3.14 و2.3.3.14. أما السطر المسمى

Corrected Total فيحوي قيم مجموع المربعات ومتوسط المربعات الكلي من أجل المتحولين التابعين، وهذه القيم هي قيم SS_T التي تم حسابها في الفقرتين 1.3.3.14 و2.3.3.14. إن أهم أجزاء هذا الجدول هما العمودان F و.Sig، اللذان يحويان النسب F لكل ANOVA وحيد المتغير وقيمة دلالتها. يجب أن يكون واضحاً من الخرج 4.14 ومن الحسابات المنفّذة في الفقرتين 1.3.3.14 و2.3.3.14 أن القيم المرتبطة مع عدة عمليات ANOVA وحيدة المتغير المنفّذة بعد MANOVA مماثلة لتلك التي نحصل عليها من ANOVA وحيد الاتجاه المنفّذ على كل متحول تابع. توضح هذه الحقيقة أن MANOVA يقدم حماية افتراضية من معدلات الخطأ من النوع الأول المضخمة، ولا حاجة لأي تعديل للقيم التي نحصل عليها.

Levene's Test of Equality of Error Variances[a]

	F	df1	df2	Sig.
Number of obsession-related behaviours	1.828	2	27	.180
Number of obsession-related thoughts	.076	2	27	.927

Tests the null hypothesis that the error variance of the dependent variable is equal across groups.

a. Design: Intercept+group

Tests of Between-Subjects Effects

Source	Dependent Variable	Type III Sum of Squares	df	Mean Square	F	Sig.
Corrected Model	Number of obsession-related behaviours	10.467[a]	2	5.233	2.771	.080
	Number of obsession-related thoughts	19.467[b]	2	9.733	2.154	.136
Intercept	Number of obsession-related behaviours	616.533	1	616.533	326.400	.000
	Number of obsession-related thoughts	6336.533	1	6336.533	1402.349	.000
group	Number of obsession-related behaviours	10.467	2	5.233	2.771	.080
	Number of obsession-related thoughts	19.467	2	9.733	2.154	.136
Error	Number of obsession-related behaviours	51.000	27	1.889		
	Number of obsession-related thoughts	122.000	27	4.519		
Total	Number of obsession-related behaviours	678.000	30			
	Number of obsession-related thoughts	6478.000	30			
Corrected Total	Number of obsession-related behaviours	61.467	29			
	Number of obsession-related thoughts	141.467	29			

a. R Squared = .170 (Adjusted R Squared = .109)

b. R Squared = .138 (Adjusted R Squared = .074)

الخرج 4.14

تدل قيم الدلالة في الخرج 4.14 على وجود فروق غير مهمة بين مجموعات العلاج من حيث التفكير الهوسي (p=0.136) والتصرفات الهوسية (p=0.080). ويجب أن تقودنا هاتان النتيجتان إلى الاستنتاج بأنه ليس لنوع العلاج أثر كبير على مستويات OCD التي يعاني منها المرضى. ربما لاحظتَ شيئاً غريباً في هذا المثال، لقد قادت إحصائيات الاختبار متعددة المتغيرات إلى الاستنتاج بأن لنوع العلاج أثر مهم على OCD، بينما قادت النتائج للاختبار وحيد المتغير إلى أن العلاج لم يكن ناجحاً.

إن سبب هذا الشذوذ في البيانات بسيط، فالاختبار متعدد المتغيرات يأخذ بعين الاعتبار الارتباط بين المتحولات التابعة، ومن أجل هذه البيانات فإن للاختبار متعدد المتغيرات قدرة أكبر على اكتشاف الفروق بين المجموعات. وبالاستفادة من هذه المعرفة يمكن القول أن الاختبارات وحيدة المتغير ليست مفيدة عملياً لتفسير النتائج، وذلك لأن المجموعات تختلف وفق تركيب من المتحولات التابعة. ولمعرفة كيف تتفاعل المتحولات التابعة علينا تنفيذ تحليل التابع المميز، وهذا ما سيتم وصفه في الفقرة 7.14.

4.6.14 مصفوفات SSCP

إذا حددنا الخيارين لإظهار مصفوفات SSCP (أنظر الفقرة 3.5.14) فإن برنامج SPSS سيعطي الجداول المبينة في الخرج 5.14 والخرج 6.14. يعرض الجدول الأول (الخرج 5.14) مصفوفة SSCP للنموذج (H) المسماة Hypothesis GROUP، ومصفوفة SSCP للخطأ (E) المسماة Error. وهناك أيضاً مصفوفة SSCP للاعتراض Intercept ولكنها غير مفيدة في دراستنا الحالية. من الواضح أن القيم في مصفوفتي SSCP للنموذج والخطأ مطابقة للقيم التي حسبناها في الفقرتين 6.3.3.14 و5.3.3.14 على الترتيب. وهذه المصفوفات مفيدة في التعرف على نمط البيانات، وخاصة في النظر إلى قيم الجداءات المتصالبة للدلالة على العلاقة بين المتحولات التابعة. في هذا المثال، إن مجاميع المربعات لمصفوفة SSCP للخطأ هي أكبر بكثير منها في مصفوفة SSCP للنموذج (أو Group)، بينما القيم المطلقة للجداءات المتصالبة هي متماثلة تقريباً. يشير هذا النموذج إلى أنه إذا كان MANOVA ذا دلالة فربما تكون العلاقة بين المتحولات التابعة أكثر أهمية من المتحولات التابعة المنفردة ذاتها.

Between-Subjects SSCP Matrix

			Number of obsession-related behaviours	Number of obsession-related thoughts
Hypothesis	Intercept	Number of obsession-related behaviours	616.533	1976.533
		Number of obsession-related thoughts	1976.533	6336.533
	group	Number of obsession-related behaviours	10.467	-7.533
		Number of obsession-related thoughts	-7.533	19.467
Error		Number of obsession-related behaviours	51.000	13.000
		Number of obsession-related thoughts	13.000	122.000

Based on Type III Sum of Squares

الخرج 5.14

يعرض الخرج 6.14 مصفوفة SSCP للبواقي مرة أخرى، ولكنه يضم أيضاً مصفوفة التباين- التباين المشترك ومصفوفة الارتباط. وهذه المصفوفات متعلقة ببعضها. إذا عدنا للفصل 4، فإننا نتذكر أنه يتم حساب التباين المشترك بتقسيم الجداء المتصالب على عدد المشاهدات (أي أن التباين المشترك

هو متوسط الجداء المتصالب). وبشكل مشابه فإنه يتم حساب التباين بتقسيم مجموع المربعات على عدد درجات الحرية (أي أنه يمثل متوسط مجموع المربعات). وهكذا فإن مصفوفة التباين–التباين المشترك تمثل الشكل المتوسط لمصفوفة SSCP. وأخيراً رأينا في الفصل 4 أن الارتباط هو النسخة القياسية من التباين المشترك (حيث يأخذ الانحراف المعياري بعين الاعتبار أيضاً)، ولذلك فإن مصفوفة التباين المشترك تمثل الشكل القياسي لمصفوفة التباين– التباين المشترك. وكما في حالة مصفوفة SSCP فإن هذه المصفوفات مفيدة في تقييم انتشار الخطأ في النموذج.

Residual SSCP Matrix

		Number of obsession-related behaviours	Number of obsession-related thoughts
Sum-of-Squares and Cross-Products	Number of obsession-related behaviours	51.000	13.000
	Number of obsession-related thoughts	13.000	122.000
Covariance	Number of obsession-related behaviours	1.889	.481
	Number of obsession-related thoughts	.481	4.519
Correlation	Number of obsession-related behaviours	1.000	.165
	Number of obsession-related thoughts	.165	1.000

Based on Type III Sum of Squares

الخرج 6.14

إن مصفوفة التباين– التباين المشترك مفيدة بشكل خاص، لأن اختبار Bartlett للكروية يعتمد عليها. يختبر اختبار Bartlett فيما إذا كانت هذه المصفوفة متناسبة مع مصفوفة محايدة. رأينا في الفقرة 1.3.14 أن المصفوفة المحايدة هي مصفوفة جميع العناصر القطرية فيها تساوي 1، وبقية العناصر تساوي 0. لذلك يختبر اختبار Bartlett فيما إذا كانت العناصر القطرية لمصفوفة التباين– التباين المشترك متساوية (تباينات المجموعات متساوية) والعناصر غير القطرية قريبة من الصفر (المتحولات التابعة غير مرتبطة فيما بينها). في هذا المثال، التباينات مختلفة جداً عن بعضها (1.89 و4.52) والتباينات المشتركة مختلفة عن الصفر نوعاً ما (0.48)، ولهذا فإن لاختبار Bartlett دلالة تقريباً (أنظر الخرج 2.14). وعلى الرغم من أن هذه المناقشة غير متعلقة بالاختبارات متعددة المتغيرات فإننا نأمل أنه بتوسيعها هنا ستتمكن من ربط هذه الأفكار مع مسائل الكروية التي ظهرت في الفصل 11، ومعرفة كيفية اختبار الفرضية.

5.6.14 المقارنات

اقترحنا في الفقرة 2.5.14 تنفيذ مقارنة بسيطة تتم فيها مقارنة كل من مجموعات العلاج مع مجموعة المراقبة (التي لم تتلق أي علاج). يعرض الخرج 7.14 نتائج تلك المقارنات. وقد تم تقسيم الجدول إلى قسمين يحمل أحدهما التسمية Level 1 vs. Level 3، والآخر التسمية Level 2 vs. Level 3 (حيث تدل الأرقام على الرموز للمتحول group)، وهي تمثل مقارنة CBT مع NT و مقارنة BT مع

NT على الترتيب. وقد تم تنفيذ كل مقارنة على المتحولين التابعين بشكل منفصل ولذلك فهي مماثلة للمقارنات التي نحصل عليها من ANOVA وحيد المتغير. يعطي الجدول قيم التقدير للمقارنة، والقيمة المفترضة (والتي ستكون مساوية 0 دائماً لأننا نختبر فرضية العدم التي تنص على أن الفرق بين المجموعتين يساوي 0). يتم بعد ذلك اختبار الفرق المقدر المشاهد لمعرفة فيما إذا كان مختلفاً بشكل كبير عن الصفر اعتماداً على الخطأ المعياري (ربما يكون من المهم قراءة الفصلين 1 و7 حول اختبار فرضية العدم). كما يحوي الجدول قيمة مجال الثقة 95% للفرق المقدر.

Contrast Results (K Matrix)

group Simple Contrast[a]			Dependent Variable: Number of obsession-related behaviours	Dependent Variable: Number of obsession-related thoughts
Level 1 vs. Level 3	Contrast Estimate		-.100	-1.600
	Hypothesized Value		0	0
	Difference (Estimate - Hypothesized)		-.100	-1.600
	Std. Error		.615	.951
	Sig.		.872	.104
	95% Confidence Interval for Difference	Lower Bound	-1.361	-3.551
		Upper Bound	1.161	.351
Level 2 vs. Level 3	Contrast Estimate		-1.300	.200
	Hypothesized Value		0	0
	Difference (Estimate - Hypothesized)		-1.300	.200
	Std. Error		.615	.951
	Sig.		.044	.835
	95% Confidence Interval for Difference	Lower Bound	-2.561	-1.751
		Upper Bound	-.039	2.151

a. Reference category= 3

الخرج 7.14

إن أول ما يجب ملاحظته (من خلال قيمة الدلالة Sig.) هو أنه عندما نقارن المجموعة CBT مع المجموعة NT عدم وجود فرق في التفكير (p=0.104) أو التصرفات (p=0.872) لأن كلتا القيمتين أكبر من القيمة 0.05 المعتمدة. وبمقارنة المجموعة BT مع المجموعة NT فإننا نلاحظ عدم وجود فرق في التفكير (p=0.835) ولكن هناك فرق كبير في التصرفات (p=0.044<0.05). وتؤكد مجالات الثقة هذه النتائج، فقد رأينا سابقاً أن مجال الثقة 95% هو مجال يحوي القيمة الصحيحة للفرق بين المجموعات في 95% من المرات. إذا تقاطعت حدود المجال مع الصفر (أي إذا كانت القيمة الدنيا سالبة والعليا موجبة) فمن الممكن أن تكون قيمة الفرق بين المجموعات تساوي 0 (وعندها لا يكون هناك فرق بين المجموعتين). لذلك لا يمكننا أن نثق بأن القيمة المشاهدة للفرق بين المجموعات ذات معنى لأن الفرق الحقيقي بين المجموعات في المجتمع قد يساوي الصفر. على كل حال، إذا لم يتقاطع مجال الثقة مع القيمة 0 (حدا المجال سالبان أو موجبان) فإننا نكون على ثقة بوجود فرق حقيقي

بين المجموعات. وهكذا فإن المقارنة الوحيدة ذات الدلالة هي مقارنة المجموعة BT مع المجموعة NT من أجل التصرفات الهوسية (المتحول actions). ولكن ذلك غير متوقع لأن ANOVA وحيد المتغير من أجل المتحول actions هو بلا دلالة ولذلك لا نتوقع أن يكون هناك فرق بين المجموعات.

أفكار مهمة

- يُستخدم MANOVA لاختبار الفرق بين المجموعات عبر عدة متحولات تابعة بآن واحد.
- يختبر اختبار Box فرضية تساوي مصفوفات التباين المشترك. ويمكن إهمال هذا الاختبار عندما تكون أحجام العينات متساوية، لأنه في تلك الحالة تكون بعض إحصائيات الاختبار MANOVA متماسكة تجاه خرق هذه الفرضية. أما إذا كانت أحجام العينات مختلفة فيجب النظر إلى هذا الاختبار. إذا كانت قيمة الدلالة أقل من 0.001 فإن نتائج التحليل تكون غير موثوقة (أنظر الفقرة 1.6.14).
- يعطي الجدول المسمى Multivariate Tests نتائج MANOVA. ويعرض 4 إحصائيات اختبار (أثر Pillai، قيمة Wilks's Lambda، أثر Hotelling، جذر Roy الأكبر). وننصح باستخدام أثر Pillai. إذا كانت قيمة الدلالة .Sig لهذه الإحصائية أصغر من 0.05 فإن المجموعات مختلفة بشكل كبير فيما يتعلق بالمتحولات التابعة.
- يمكن استخدام عدة عمليات ANOVA بعد MANOVA (ANOVA مختلف لكل متحول تابع). وتظهر نتائج هذه التحاليل في جدول يحمل التسمية Tests of Between-Subjects Effects. ويمكن تنفيذ مقارنات بعد هذه التحاليل (أنظر الفصول 8 إلى 12). ولكننا لا ننصح باعتماد هذا الحل ونفضل تحليل التابع المميز.

7.14 متابعة MANOVA بتحليل المميز

أشرنا سابقاً إلى أنه يمكن متابعة MANOVA ذا دلالة باستخدام ANOVA وحيد المتغير أو تحليل المميز (discriminant analysis). وفي هذا المثال، لم تكن عدة عمليات ANOVA وحيدة المتغير طريقة مفيدة لمعرفة ما تعرضه الاختبارات متعددة المتغيرات وذلك لأن العلاقة بين المتحولات التابعة لم تكن ذات أثر. على كل حال، إن هذه البيانات مصممة خصيصاً لتوضيح ضرورة التعامل مع ANOVA وحيد المتغير بحذر. وفي الحياة الحقيقية، من المحتمل أن يترافق MANOVA ذو دلالة مع ANOVA واحد ذو دلالة على الأقل. على كل حال، لا يعني هذا أن العلاقة بين المتحولات التابعة ليست هامة، ومن الضروري البحث عن طبيعة هذه العلاقة. ويعتبر تحليل المميز أفضل طريقة لإنجاز ذلك، ولذلك ننصح بمتابعة MANOVA بالاختبارات وحيدة المتغير وكذلك بتحليل المميز لفهم البيانات بشكل كامل.

إن تحليل المميز بسيط جداً في برنامج SSPS، وللوصول إلى مربع الحوار الرئيسي نستخدم أمر القائمة Analyze ⇒ Classify ⇒ Discriminant... (أنظر الشكل 5.14).

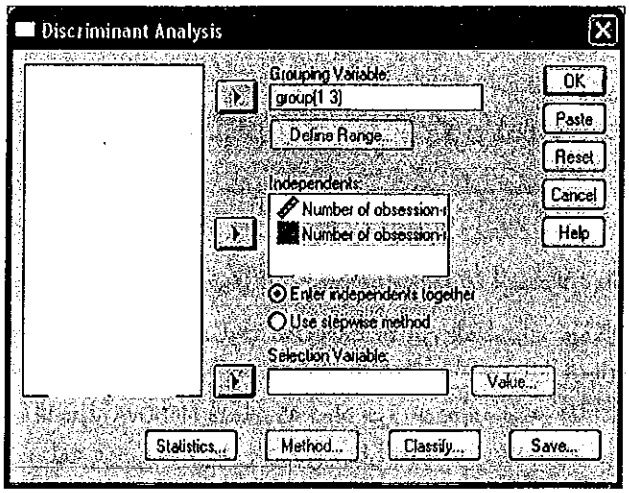

الشكل 5.14 مربع الحوار الرئيسي لتحليل المميز

يعرض القسم الأيسر من مربع الحوار الرئيسي المتحولات المستخدمة في محرر البيانات، بينما يحوي الطرف الأيمن قسمين، أحدهما لمتحول التجميع والآخر للمتحولات التنبؤية. في تحليل المميز نبحث لمعرفة الطريقة الأفضل لفصل (أو تمييز) مجموعة من المجموعات باستخدام عدة متحولات تنبؤية (لذلك فهو يشبه التراجع المنطقي نوعاً ما ولكنه يتعامل مع عدة مجموعات بدلاً من اثنتين فقط). من المربك التفكير بأن المتحولين التابعين هما متحولان مستقلان وأننا استخدمنا وصف المتحولات التنبؤية للإشارة إليهما (مع أنهما متحولان تابعان في MANOVA)، وهذا مثال آخر عن فائدة عدم الإشارة للمتحولات في تحليل الترابط كمتحولات مستقلة ومتحولات تابعة.

لتنفيذ التحليل، نختار المتحول group وننقله إلى الحيز المسمى Grouping Variable. بعد نقل المتحول يصبح الزر Define Range... نشطاً، وعلينا أن ننقر هذا الزر لفتح مربع الحوار الخاص بتحديد القيم الدنيا والعليا لمتحول الترميز (وهي 1 و3 في هذا المثال). بعد الانتهاء من تحديد مجال الترميز لمتحول التجميع، نختار المتحولين actions وthoughts وننقلهما إلى الحيز المسمى Independents. يتوفر خياران لتحديد كيفية إدخال المتحولات التنبؤية في النموذج. الخيار الافتراضي هو إدخال المتحولين معاً، وهذا الخيار هو المناسب لأنه في MANOVA يتم تحليل المتحولين التابعين بآن واحد. من الممكن إدخال المتحولات التابعة بطريقة خطوية، وإذا تم تحديد هذا الخيار (الخيار الثاني) فإن الزر Method... يصبح نشطاً، ويسمح بفتح مربع الحوار الخاص بتحديد المعايير لإدخال المتحولات التنبؤية. وبهدف متابعة MANOVA فإننا نهتم بالخيارات المتبقية فقط.

انقر الزر Statistics... لفتح مربع الحوار المبين في الشكل 6.14. والذي يسمح بطلب متوسطات المجموعات و عدة عمليات ANOVA وحيد المتغير واختبار Box لتَسَاوي مصفوفات التباين المشترك، وقد حصلنا عليها جميعاً في خرج MANOVA (لذلك لن نطلب أياً من هذه القيم). ويسمح مربع

الحوار أيضاً بطلب مصفوفات الارتباط ضمن المجموعات، ومصفوفات التباين المشترك، وهي نفس مصفوفات الارتباط للبواقي ومصفوفات التباين المشترك المبينة في الخرج 6.14. هناك أيضاً خيار لعرض مصفوفة التباين المشترك للمجموعات المنفصلة، والتي يمكن أن تكون مفيدة في التعرف على العلاقات بين المتحولات التابعة لكل مجموعة (ولا تعرض إجرائية MANOVA هذه المصفوفة لذلك ننصح بتحديد هذا الخيار لعرضها). ويمكننا أن نطلب أيضاً مصفوفة التباين المشترك الكلي، وهي تعرض التباينات المشتركة والتباينات للمتحولات التابعة بشكل إجمالي. الخيار المفيد الأخير الذي يقدمه مربع الحوار هو معاملات التابع غير القياسية. ويعطي هذا الخيار قيم b غير القياسية لكل متحول تابع (أنظر المعادلة (5.14)). وعند الانتهاء من تحديد الخيارات في مربع الحوار، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

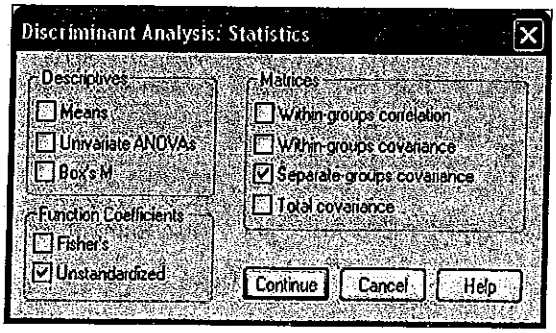

الشكل 6.14 خيارات تحديد الإحصائيات من أجل تحليل المميز

إذا نقرت الزر ...Classify فإنك تفتح مربع الحوار المبين في الشكل 7.14، الذي يوفر مجموعة من الخيارات. يمكنك أولاً تحديد كيفية حساب الاحتمالات السابقة، فإذا كانت أحجام المجموعات متساوية فيمكنك المحافظة على الخيار الافتراضي المحدد، أما إذا كان التصميم غير متوازن فمن المفضل أن يعتمد حساب الاحتمالات السابقة على أحجام المجموعات المشاهدة. إن الخيار الافتراضي لاعتماد التحليل على مصفوفة التباين المشترك ضمن المجموعات هو خيار ممتاز (لأن MANOVA تعتمد على هذه المصفوفة). يمكنك أن تحدد أيضاً مخطط المجموعات المركبة، الذي يرسم علامات المتغير لكل مشترك مجمعة وفق العلاج المعطى لذلك المشترك. يعرض مخطط المجموعات المنفصلة نفس الشيء ولكن باستخدام مخططات مختلفة لكل مجموعة من المجموعات، وعندما يكون عدد المجموعات صغيراً فمن المفضل تحديد خيار المجموعات المركبة لأن تفسيره أسهل. أما بقية الخيارات في مربع الحوار فهي قليلة الأهمية عند استخدام تحليل المميز لمتابعة MANOVA. والخيار المفيد هو الجدول الملخص الذي يعطي مؤشراً عاماً عن جودة تصنيف المتغيرات المميزة للمشتركين الحاليين. عند الانتهاء من تحديد الخيارات، انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

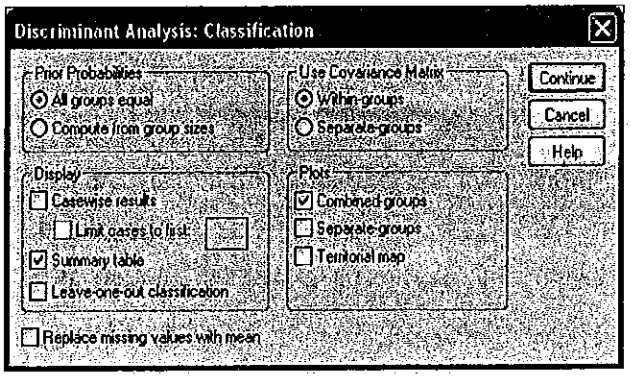

الشكل 7.14 خيارات التصنيف لتحليل المميز

الخيارات الأخيرة التي يوفرها مربع الحوار الرئيسي هي الخيارات التي يمكن الوصول إليها بنقر الزر Save... الذي يفتح مربع الحوار المبين في الشكل 8.14. تتوفر 3 خيارات، اثنان منها مرتبطان بالعناصر المتوقعة للمجموعة والاحتمالات لعناصر المجموعة من النموذج. وهذه القيم مشابهة لتلك التي حصلنا عليها في تحليل التراجع المنطقي (أنظر الفصل 6). أما الخيار الأخير فهو للحصول على العلامات المميزة (discriminant scores). وهي العلامات التي يتم الحصول عليها من المعادلة (5.14) لكل شخص من أجل كل متغير. ويمكن أن تكون هذه العلامات مفيدة لأن المتغيرات التي يحددها التحليل يمكن أن تمثل البنى النفسية أو الاجتماعية القاعدية. إذا كانت تلك البنى قابلة للتعريف فمن المفيد عندئذٍ معرفة علامات المشترك في كل بُعد من أجل التفسير.

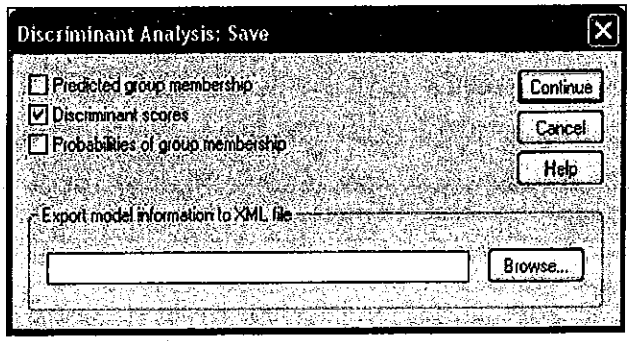

الشكل 8.14 مربع الحوار لحفظ متحولات جديدة في تحليل المميز

8.14 الخرج من تحليل المميز

يعرض الخرج 8.14 مصفوفات التباين المشترك للمجموعات المنفصلة (الخيار المحدد في الشكل 6.14). وتتكون هذه المصفوفات من التباينات المشتركة لكل متحول تابع من أجل كل مجموعة. وقد تم الحصول على التباينات المشتركة بتقسيم الجداءات المتصالبة بين المتحولات المتغيرة من أجل كل مجموعة

(من الجدول 4.14 والقيم هي 0.40 و22.6 و10-) على عدد درجات الحرية (N-1=10-1=9). والقيم في هذا الجدول مفيدة لأنها تعطينا فكرة عن كيفية تغير العلاقة بين المتحولات التابعة من مجموعة إلى مجموعة أخرى. فعلى سبيل المثال في المجموعة CBT ليست هناك علاقة بين التصرفات والتفكير لأن قيمة التباين المشترك قريبة الصفر. أما في المجموعة BT فإن التصرفات والتفكير مرتبطان طردياً، فعندما ينخفض عدد التصرفات، ينخفض عدد مرات التفكير. وفي المجموعة NT هناك علاقة عكسية، فعندما يزداد عدد مرات التفكير، ينخفض عدد التصرفات. من المهم أن نلاحظ أن هذه المصفوفات لا تدلنا على الأهمية الجوهرية للعلاقات لأنها غير قياسية (أنظر الفصل 4) ولكنها تعطينا مدلولاً أساسياً فقط.

Covariance Matrices

group		Number of obsession-related behaviours	Number of obsession-related thoughts
CBT	Number of obsession-related behaviours	1.433	4.444E-02
	Number of obsession-related thoughts	4.444E-02	3.600
BT	Number of obsession-related behaviours	3.122	2.511
	Number of obsession-related thoughts	2.511	4.400
No Treatment Control	Number of obsession-related behaviours	1.111	-1.111
	Number of obsession-related thoughts	-1.111	5.556

الخرج 8.14

يعرض الخرج 9.14 الإحصائيات الأولية من تحليل المميز. نلاحظ أولاً وجود القيم الخاصة لكل متغير وهي تتطابق مع العناصر القطرية للمصفوفة HE^{-1} (المحسوبة في الملحق A.8). وتم تحويل هذه القيم الخاصة إلى نسب مئوية من التباين، فالمتغير الأول يساهم بمقدار 82.2% من التباين مقارنة مع المتغير الثاني الذي يساهم بمقدار 17.8% فقط. يعرض القسم الثاني من الخرج قيمة Wilks's Lambda (0.699)، وعدد درجات الحرية (4)، وقيمة الدلالة (0.5) وهي نفس القيم التي أعطاها MANOVA (الخرج 3.14). إن أهم نقطة تجب ملاحظتها في هذا الجدول هي أن أحد المتغيرين فقط هو ذو دلالة (أما الأخير فهو بدون دلالة p=0.173). لذلك فإن الفروق بين المجموعات والتي يعرضها MANOVA يمكن تفسيرها بدلالة بُعد قاعدي واحد.

تعتبر الجداول المبينة في الخرج 10.14 الأكثر أهمية من ناحية التفسير. يعرض الجدول الأول معاملات التابع المميز القياسية من أجل المتغيرين. وهذه القيم هي النسخ القياسية من القيم في الأشعة الخاصة المحسوبة في الفقرة 1.4.3.14. إذا تذكرنا أنه يمكن التعبير عن المتغيرات بشكل معادلة تراجع خطي (أنظر المعادلة (4.14))، فإن معاملات التابع المميز القياسية هي المكافئات لقيم بيتا القياسية في التراجع. وهكذا تدلنا هذه القيم على المساهمة النسبية لكل متحول في المتغير. من الواضح حسب القيم لهذه البيانات أن لعدد التصرفات الهوسية المساهمة الأكبر في المتغير الأول (مقارنة بمساهمة عدد مرات التفكير)، والعكس صحيح من أجل المتغير الثاني.

Eigenvalues

Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
1	.335[a]	82.2	82.2	.501
2	.073[a]	17.8	100.0	.260

a. First 2 canonical discriminant functions were used in the analysis.

Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1 through 2	.699	9.508	4	.050
2	.932	1.856	1	.173

الخرج 9.14

نتذكر أيضاً أن قيم معاملات بيتا القياسية تتراوح في المجال 1±، ولذلك فإن مساهمة كلا المتحولين كبيرة في المتغير الأول (كلاهما هام) لأن قيم المساهمة قريبة من 1+ (للمتحول actions) و 1- (للمتحول thoughts). وبما أن المتغير الأول هو المهم فقط فيمكننا الاستنتاج بأنه من الضروري المحافظة على كلا المتحولين في مجموعة المميزات (لأن أثقالهما القياسية من نفس المرتبة تقريباً). ويدل الثقل الموجب لأحد المتحولين التابعين والثقل السالب للمتحول الآخر على أن الفروق بين المجموعات يتم تبريره بالفرق بين المتحولين التابعين.

Standardized Canonical Discriminant Function Coefficients

	Function	
	1	2
Number of obsession-related behaviours	.829	.584
Number of obsession-related thoughts	-.713	.721

Structure Matrix

	Function	
	1	2
Number of obsession-related behaviours	.711*	.703
Number of obsession-related thoughts	-.576	.817*

Pooled within-groups correlations between discriminating variables and standardized canonical discriminant functions
Variables ordered by absolute size of correlation within function.

*. Largest absolute correlation between each variable and any discriminant function

الخرج 10.14

هناك طريقة أخرى للنظر إلى العلاقة بين المتحولات التابعة والمتغيرات المميزة وهي النظر إلى مصفوفة البنية التي تعطي معاملات ارتباط المتغير القانونية (Canonical variate correlation coefficients). وقد

ناقش Bargman (1970) هذه المسألة وخلص إلى أنه عندما تكون معاملات ارتباط المتغير القانونية لبعض المتحولات التابعة مرتفعة، وللبعض الآخر منخفضة فإن المتحولات التابعة ذات القيم الأعلى تساهم بشكل أكبر في فصل المجموعات. وهكذا فهي تمثل المساهمة النسبية لكل متحول متغير في فصل المجموعات. وبما أننا نهتم بالمتغير الأول فقط (لأن الثاني عديم الدلالة) وننظر إلى مصفوفة البنية فيمكننا الاستنتاج أن عدد التصرفات أهم قليلاً في التمييز بين المجموعات الثلاث (لأن 0.711 أكبر من 0.576). على كل حال، ما يزال عدد مرات التفكير هاماً جداً لأن معامل الارتباط كبير جداً. وكما في حالة الأثقال القياسية، فإن معامل الارتباط الموجب لأحد المتحولين المتغيرين، ومعامل الارتباط السالب للمتحول الآخر، يدل على الفرق بين المتحولين التابعين يحدد الفصل بين المجموعات.

يعطي القسم التالي من الخرج (الخرج 11.14) معاملات التابع المميز القانونية، وهي النسخ غير القياسية من المعاملات القياسية المبينة سابقاً. وهكذا فإن هذه القيم هي قيم b في المعادلة (4.14) وستلاحظ أن هذه القيم تتطابق مع القيم في الأشعة الخاصة المشتقة في الفقرة 1.4.3.14 والمستخدمة في المعادلة (5.14). وهذه القيم أقل أهمية من النسخ القياسية، ولكنها توضح مصدر النسخ القياسية. يعطي الجدول الثاني قيم المركز المتوسط للمتغير في كل مجموعة. والمركز المتوسط (Centroid) هو ببساطة متوسط علامات المتغير. ومن أجل التفسير علينا أن ننظر إلى إشارة المركز المتوسط، وهكذا يبدو لنا أن المتغير الأول يميز المجموعة BT عن المجموعتين الأخريين (وخاصة عن المجموعة CBT لأن الفرق بين المركزين المتوسطين لهاتين المجموعتين هو الأكبر). أما المتغير الثاني (الذي كان بدون دلالة) فيميز المجموعة NT عن المجموعتين التجريبيتين.

Canonical Discriminant Function Cofficients

	Function	
	1	2
Number of obsession-related behaviours	.603	.425
Number of obsession-related thoughts	-.335	.339
(Constant)	2.139	-6.857

Unstandardized coefficients

Function at Group Centroids

	Function	
group	1	2
CBT	.601	-.229
BT	-.726	-.128
No Treatment Control	.125	.357

Unstandardized canonical discriminant functions evaluated at group means

الخرج 11.14

يمكن توضيح العلاقة بين المتغيرات والمجموعات بشكل أفضل باستخدام مخطط المجموعات المركبة (الذي تم اختياره باستخدام مربع الحوار المبين في الشكل 7.14). ويرسم هذا المخطط علامات المتغير لكل شخص، مجمعة وفقاً للحالة التجريبية التي ينتمي إليها الشخص. كما يعرض المراكز المتوسطة للمجموعات. ويعرض الشكل 9.14 هذا المخطط لبيانات OCD. ومن الواضح من مواقع المراكز المتوسطة أن المتغير الأول يميز المجموعة BT عن المجموعة CBT (أنظر إلى المسافة الأفقية بين هذين المركزين المتوسطين). أما المتغير الثاني فلا يميز بين المجموعات، ونعلم ذلك سابقاً لأن هذا المتغير بدون دلالة، ولكن المخطط يبين أن المسافة الشاقولية بين المراكز المتوسطة للمجموعات صغيرة جداً، وهذا يعني عدم وجود فصل بين المجموعات وفق هذا المتغير.

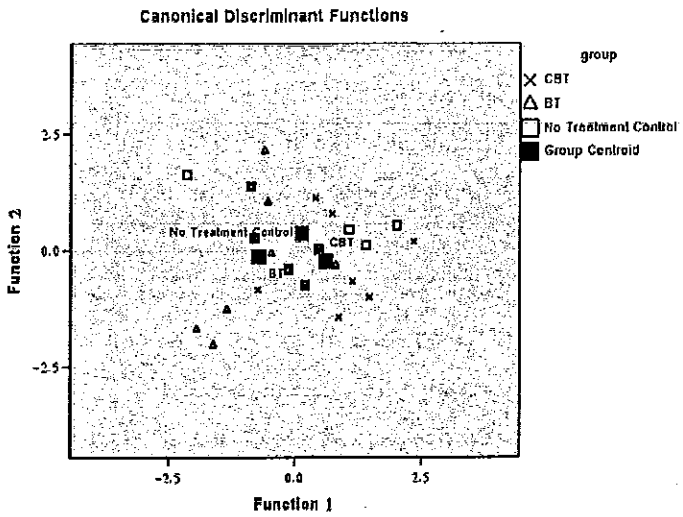

الشكل 9.14 مخطط المجموعات المركبة

أفكار مهمة

- يمكن استخدام تحليل التابع المميز (DFA) بعد MANOVA لمعرفة كيفية تمييز المتحولات التابعة للمجموعات.
- يحدد DFA المتغيرات (تراكيب من المتحولات التابعة)، ولمعرفة عدد المتغيرات ذات الدلالة أنظر إلى قيمة الدلالة .Sig في الجدول المسمى Wilks's Lambda، فإذا كانت أصغر من 0.05 فإن المتغير يميز بين المجموعات بشكل كبير.
- بعد معرفة المتغيرات ذات الدلالة، استخدم الجدول المسمى Standardized Canonical Discriminant Function Coefficients لمعرفة مدى مساهمة المتحولات التابعة في كل متغير. تدل العلامات المرتفعة على أن المتحول التابع هام بالنسبة للمتغير، وتساهم المتحولات ذات المعاملات الموجبة والسالبة في المتغير بطرق متعاكسة.

- أخيراً، لإيجاد المجموعات المميزة من قبل أحد المتغيرات، أنظر في الجدول المسمى Function at Group Centroids من أجل متغير محدد، فالمجموعات ذات القيم متعاكسة الإشارة هي المميزة بذلك المتغير.

9.14 بعض الملاحظات النهائية

1.9.14 التفسير النهائي

لقد جمعنا مقداراً هائلاً من المعلومات حول البيانات، ولكن كيف يمكننا تجميعها معاً للإجابة على السؤال الأساسي للبحث: هل يمكن للعلاج أن يحسّن حالة مرضى OCD؟ وإذا كان الجواب نعم، فما هو العلاج الأفضل؟ يدلنا MANOVA على أنه يمكن أن يكون للعلاج أثر فعّال على أعراض OCD، ولكن عمليات ANOVA وحيدة المتغير بدون دلالة، وتشير إلى أن التحسن ليس من ناحية التفكير أو السلوك. أما تحليل المميز فيشير إلى أن فصل المجموعات يمكن تفسيره بدلالة بُعد قاعدي واحد. وضمن هذا الإطار فمن المرجح أن يكون هذا البعد هو OCD ذاته (والذي يمكننا أنً نفترضه مكوناً من التفكير والتصرفات معاً). لذلك فالعلاج لا يغير التفكير أو التصرفات بشكل منفصل، ولكنه يؤثر على البعد القاعدي لـــ OCD. وبالتالي فإن الإجابة على السؤال الأول تبدو: نعم، يمكن أن يؤثر العلاج على OCD ولكن طبيعة هذا التأثير غير واضحة.

السؤال الثاني أكثر تعقيداً: ما هو العلاج الأفضل؟ يعرض الشكل 10.14 مخططات العلاقات بين المتحولات التابعة ومتوسطات المجموعات للبيانات الأصلية. يبين مخطط المتوسطات أنه من أجل المتحول actions، فإن المجموعة BT تخفض عدد التصرفات الهوسية، بينما لا تفعل ذلك مجموعتا CBT وNT. أما من أجل المتحول thoughts، فإن المجموعة CBT تخفض عدد مرات التفكير الهوسي، بينما لا تفعل ذلك مجموعتا BT وNT (تحقق من نمط الأعمدة). ننظر الآن إلى العلاقات بين المتحولين actions و thoughts ، ففي المجموعة BT هناك علاقة طردية شبه خطية بين التصرفات والتفكير، فكلما زاد عدد مرات التفكير الهوسي عند شخص ما، ازدادت التصرفات الهوسية. في المجموعة CBT ليست هناك علاقة على الإطلاق فالمتحولان يتغيران بشكل مستقل عن بعضهما البعض. وفي المجموعة التي لم تتلق أي علاج (NT) هناك علاقة عكسية (ولكن بدون دلالة) بين التفكير والتصرفات. وما اكتشفناه من تحليل المميز هو أن التصرفات أكثر أهمية من التفكير فيما يتعلق بـــ OCD (كبنية) وذلك بفضل معاملات ارتباط المتغير القانونية. لذلك يبدو علاج السلوك (BT) هو الأفضل لأنه يتوجه لمعالجة التصرفات بدلاً من التفكير (وخاصة بالمقارنة مع CBT، حسب المسافة الأفقية بين المراكز المتوسطة للمجموعات في الشكل 9.14). وعلى كل حال، فإن دلالة التابع المميز لا تخبرنا بالضرورة أن المجموعة BT كانت أدنى من المجموعة NT (أي أن العلاج ليس بالضرورة أفضل من عدم المعالجة). ولذلك فإن للمجموعة BT أكبر تأثير على OCD كبنية، بسبب الأهمية النسبية للتصرفات في تلك البنية مقارنة مع الإدراك.

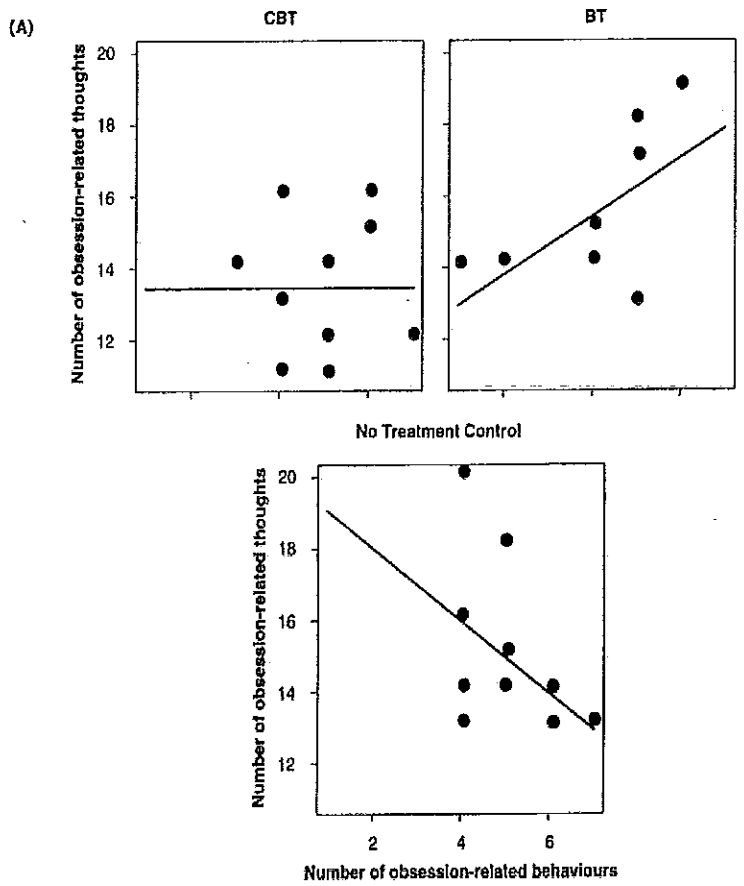

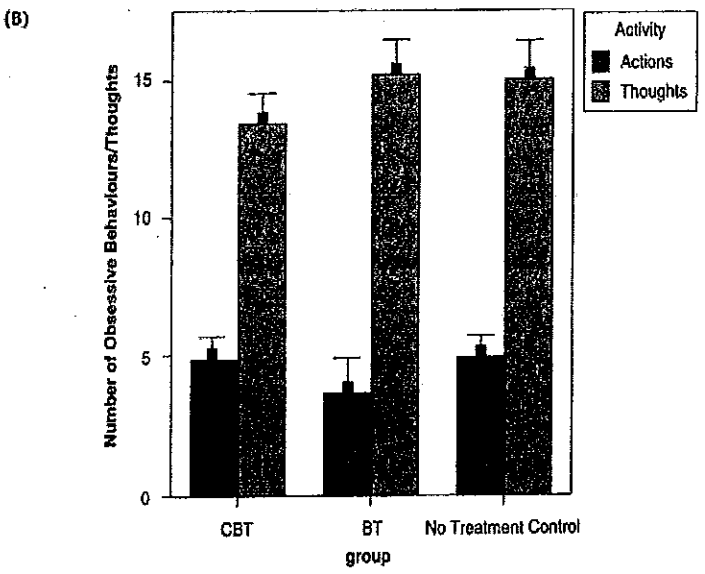

الشكل 10.14 توضح المخططات (A) العلاقات و(B) المتوسطات بين المتحولات التابعة في كل مجموعة علاج

2.9.14 ANOVA وحيد المتغير أم تحليل المميز؟

يوضح هذا المثال أن ANOVA وحيد المتغير وتحليل المميز هما طريقتان للإجابة على الأسئلة المختلفة التي تظهر من MANOVA ذي دلالة. إذا اخترنا ANOVA وحيد المتغير فيجب تطبيق تصحيحات Bonferroni على المستوى الذي يتم عنده قبول الدلالة. والحقيقة أنه يجب تنفيذ كلا التحليلين للحصول على صورة كاملة لما يحدث في البيانات. إن فائدة تحليل المميز أنه يدلنا على الأبعاد القاعدية ضمن البيانات (وهذا مفيد بشكل خاص عند استخدام عدة متحولات تابعة لالتقاط البنية النفسية أو الاجتماعية). وحتى إذا كان ANOVA وحيد المتغير ذا دلالة فإن تحليل المميز يوفر معرفة عميقة مفيدة بالبيانات ويجب استخدامها.

10.14 ما الذي اكتشفناه عن الإحصاء؟

تعرفنا في هذا الفصل على MANOVA وتحليل التابع المميز. في بعض الأحيان يتم قياس عدة متحولات للنتيجة في مجموعة مختلفة واكتشفنا أنه في هذه الحالات يمكننا توسيع تقنية ANOVA إلى التحليل متعدد المتغيرات للتباين MANOVA (Multivariate Analysis of Variance). والسبب في استخدام هذه التقنية بدلاً من تنفيذ مجموعة عمليات ANOVA هو أننا نتحكم بمعدل الخطأ من النوع الأول، وأنه يمكننا إدخال العلاقات بين متحولات النتيجة ضمن التحليل. بعد ذلك اكتشف بعضكم أن MANOVA يعمل بطرق مماثلة لعمل ANOVA ولكن باستخدام المصفوفات بدلاً من القيم المنفردة. فيما اكتشف البعض الآخر أنه من المفضل إهمال الفقرات النظرية في الكتاب. تعرفنا بعد ذلك على طريقة تنفيذ مثال MANOVA باستخدام برنامج SPSS واكتشفنا أنه لجعل الوضع مشوشاً ومربكاً قدر الإمكان فإننا حصلنا على 4 إحصائيات اختبار متعلقة بنفس الأثر. وقد حاولنا إقناعك أن أثر Pillai هو الخيار الآمن. وأخيراً تعرفنا على طريقتين لمتابعة MANOVA: تنفيذ مجموعة من عمليات ANOVA أو تحليل التابع المميز. وأكّدنا على أن تحليل التابع المميز يعطينا معلومات أكثر، ولكن تفسيرها هو كابوس فعلي.

11.14 المصطلحات الأساسية التي اكتشفناها

اختبار Bartlett للكروية	(Bartlett's test of sphericity)
اختبار Box	(Box's test)
تحليل المميز	(Discriminant analysis)
متغيرات التابع المميز	(Discriminant function variates)
العلامات المميزة	(Discriminant scores)
المصفوفة E	(Error SSCP)

تجانس مصفوفات التباين المشترك	(Homogeneity of covariance matrices)
أثر Hotelling-Lawley	(Hotelling-Lawley trace)
المصفوفة H	(Hypothesis SSCP)
المصفوفة المحايدة	(Identity matrix)
المصفوفة	(Matrix)
متعدد المتغيرات	(Multivariate)
التحليل متعدد المتغيرات للتباين	(Multivariate analysis of variance) (MANOVA)
الطبيعية متعددة المتغيرات	(Multivariate normality)
أثر Pillai-Bartlett	(Pillai-Bartlett trace)
جذر Roy الأكبر	(Roy's largest root)
المصفوفة المربعة	(Square matrix)
مصفوفة مجموع المربعات والجداء المتصالب	(Sum of squares and cross-product matrix) (SSCP)
المصفوفة T	(Total SSCP)
وحيد المتغير	(Univariate)
مصفوفة التباين–التباين المشترك	(Variance-covariance matrix)
إحصائية Wilks's lambda	(Wilks's lambda (Λ))

12.14 مهمات يجب تنفيذها

يحوي الملف Answers(Chapter14).pdf الإجابات على هذه المهمات.

- **المهمة الأولى:** لاحظ أحد أطباء النفس أن عدداً من مرضاه manic psychotic ينتحلون شخصية الدجاج أمام الجمهور. وتساءل عن إمكانية استخدام هذا السلوك لتشخيص هذا الاضطراب وقرر مقارنة المرضى مع عينة طبيعية. فراقب 10 مرضى خلال يوم عادي، و 10 أشخاص طبيعيين. وقام بقياس متحولين تابعين، الأول هو عدد مرات انتحال شخصية الدجاج التي يقومون بها عند سيرهم في شارع معين خلال يوم كامل، والثاني جودة انتحالهم للشخصية (كعلامة من 10 يقدرها خبير بضجيج المزارع). يحوي الملف Chicken.sav تلك البيانات. استخدم MANOVA وDFA لمعرفة فيما إذا كان ممكناً استخدام هذه المتحولات لتمييز مرضى manic psychotic عن الأشخاص الذين لا يعانون من هذا المرض.

- **المهمة الثانية:** اهتم أحد الباحثين بمعرفة فيما إذا كانت معارف الطلاب في المجالات المختلفة لعلم النفس تتحسن خلال تدرجهم في سنوات الدراسة. لقد أخذ عينات من السنة الأولى والسنة الثانية والسنة الثالثة وأجرى لهم 5 اختبارات (العلامة من 15) تمثل المجالات المختلفة لعلم النفس: Exper (علم النفس التجريبي)، Stats (الإحصاء)، Social (علم النفس الاجتماعي)، Develop (علم النفس التطوري)، Person (الشخصية). يحوي الملف Psychology.sav هذه البيانات. وتتكون المهمة من:

* تنفيذ تحليل عام مناسب لتحديد فيما إذا كان هناك فروق إجمالية بين المجموعات على هذه المتحولات.
* النظر إلى التحليل حسب المقياس للفروق بين المجموعات الناتجة في الخرج وتفسير النتائج وفقاً لذلك.
* اختيار المقارنات التي تختبر فرضية أن علامات طلاب السنة الثانية والسنة الثالثة هي أعلى من علامات طلاب السنة الأولى على جميع المقاييس.
* اختيار الاختبارات لمقارنة كل المجموعات مع بعضها البعض، وقارن هذه النتائج مع المقارنات.
* تنفيذ تحليل منفصل يتم فيه اختبار فيما إذا كان تركيبٌ من تلك القياسات يستطيع تمييز المجموعات بنجاح (اكتب تعليقاً مختصراً عن هذا التحليل). استخدم المقاييس التي تكشف الفروق بين المجموعات فقط في المقارنات. كيف يمكن للنتائج مساعدتك في تفسير نتائج التحليل الأولي؟

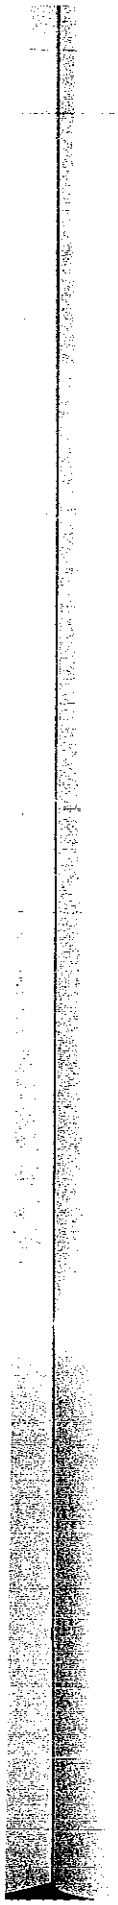

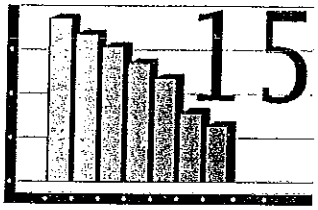

التحليل العاملي الاستكشافي

1.15 بماذا يخبرنا هذا الفصل؟

يتركز الاهتمام في العلوم الاجتماعية غالباً على محاولة قياس الأشياء التي لا يمكن قياسها بشكل مباشر والتي تدعى المتحولات المستترة (Latent variables). فعلى سبيل المثال يهتم طلاب الإدارة (وحتى علماء النفس) بقياس ما يسمى الإنهاك (Burnout) وهي الحالة التي يعمل فيها شخص ما في مشروع معين بجد لفترة طويلة من الزمن ثم يجد نفسه فجأة مجرداً من الاندفاع والإلهام. لا يمكن قياس هذه الحالة مباشرة، لأن لها عدة أوجه. ولكن يمكن قياس معالمها المختلفة، حيث يمكن تكوين فكرة عن الاندفاع ومستويات الإجهاد، وفيما إذا كانت لدى الشخص أفكار جديدة وغير ذلك. بعد إنجاز ذلك، يكون من المفيد معرفة فيما إذا كانت هذه القياسات تعكس فعلياً متحولاً وحيداً. أو بطريقة أخرى، هل تم اشتقاق هذه المتحولات المختلفة من نفس المتحول القاعدي؟ يتعامل هذا الفصل مع التحليل العاملي (Factor analysis) (وتحليل المكونات الأساسية) وهو تقنية للتعرف على مجموعات المتحولات. ولهذه التقنية ثلاثة استخدامات أساسية: (1) فهم البنية لمجموعة من المتحولات (فعلى سبيل المثال، استخدم روّاد الذكاء مثل Spearman و Thurston التحليل العاملي لمحاولة فهم بنية المتحول المستتر "الذكاء"). (2) بناء استبيان لقياس متحول قاعدي (فعلى سبيل المثال، يمكنك بناء استبيان لقياس الإنهاك). (3) تخفيض مجموعة البيانات إلى حجم قابل للإدارة مع المحافظة قدر الإمكان على المعلومات الأصلية (رأينا في الفصل 5 أن الارتباط الخطي المتعدد يمكن أن يعتبر مشكلة في التراجع المتعدد، ولذلك يمكن استخدام التحليل العاملي لحل هذه المشكلة بتركيب المتحولات المرتبطة خطياً فيما بينها). وسنكتشف في هذا الفصل: ما هي العوامل، وكيف نجدها، وعلام تدلنا بما يخص العلاقة بين المتحولات التي قمنا بقياسها.

2.15 العوامل

إذا قمنا بقياس عدة متحولات، أو طرحنا عدة أسئلة على شخص ما، فإنه يمكن ترتيب الارتباط بين كل زوج من المتحولات (أو الأسئلة) في مصفوفة تدعى المصفوفة R (R-matrix). والمصفوفة R هي مصفوفة ارتباط تحوي معاملات الارتباط بين المتحولات (وقد رأينا نسخاً صغيرة من هذه

المصفوفة في الفصل 4). وجميع العناصر القطرية في المصفوفة R تساوي 1 لأن كل متحول يرتبط بنفسه بشكل كامل. أما العناصر غير القطرية فهي معاملات الارتباط بين أزواج المتحولات أو الأسئلة. إن وجود تجمعات لعوامل الارتباط الكبيرة بين مجموعات جزئية من المتحولات يشير إلى أن هذه المتحولات يمكن أن تقيس بعض معالم البعد القاعدي ذاته. تدعى هذه الأبعاد القاعدية بالعوامل (Factors) أو المتحولات المستترة (Latent Variables). وبتخفيض مجموعة البيانات من مجموعة من المتحولات المرتبطة داخلياً فيما بينها إلى مجموعة أصغر من العوامل، فإن التحليل العاملي يقوم بتفسير المقدار الأعظمي من التباينات التشاركية في مصفوفة ارتباط وذلك باستخدام العدد الأدنى من المفاهيم الاستكشافية.

هناك أمثلة عديدة عن استخدام التحليل العاملي في العلوم الاجتماعية. فقد استخدم علماء النفس التحليل العاملي دون كلل لقياس سمات الشخصية. وتعتمد معظم استبيانات الشخصية على التحليل العاملي بهدف توظيف الأشخاص في القطاعات الصناعية أو حتى من قبل المجموعات الدينية. وعلى الرغم من شهرة التحليل العاملي كأداة مستخدمة من قبل علماء النفس، فإن استخدامه غير محدود بقياس أبعاد الشخصية. فعلى سبيل المثال يستخدم الاقتصاديون التحليل العاملي لمعرفة فيما إذا كان ممكناً تخفيض الإنتاجية والأرباح والقوة العاملة إلى بعد قاعدي لنمو الشركة، كما تم استخدامه من قبل أخصائي في الكيمياء الحيوية لتحليل عينات من البول!

لنضع بعض هذه الأفكار قيد التطبيق ونتخيل أننا نريد قياس المعالم المختلفة لما يمكن أن يجعل الشخص محبوباً. يمكننا أن ندير مجموعة من القياسات التي نعتقد أنها تلمس المعالم المختلفة للشعبية. لذلك يمكن أن نقيس المهارات الاجتماعية للشخص (Social Skills)، الأنانية (Selfish)، مدى الطرافة التي يجدها الآخرون في هذا الشخص (Interest)، نسبة الوقت الذي يقضيه في الحديث عن الأشخاص الآخرين خلال محادثة ما (Talk1)، نسبة الوقت الذي يقضيه في الحديث عن نفسه (Talk2)، نزعته وميله للكذب على الآخرين (Liar). يمكننا بعد ذلك قياس معامل الارتباط لكل زوج من المتحولات وإنشاء المصفوفة R. يعرض الجدول 1.15 هذه المصفوفة. وقد تم إظهار معاملات الارتباط المهمة بالخط الغامق. من الواضح وجود تجمّعين من المتحولات المترابطة فيما بينها. لذلك ربما تقيس هذه المتحولات بعداً قاعدياً مشتركاً. يبدو أن الوقت الذي يقضيه شخص ما في الحديث عن الآخرين خلال محادثة ما، يرتبط بشكل وثيق مع كل مستوى من المهارات الاجتماعية، ومدى الطرافة التي يجدها الآخرون في هذا الشخص. وكذلك فإن المهارات الاجتماعية ترتبط مع مدى الطرافة التي يجدها الآخرون في شخص ما. تدل هذه العلاقات على أنه كلما كانت مهاراتك الاجتماعية أفضل، كان من المرجح أن تكون طريفاً وثرثاراً. وهناك تجمع آخر للمتحولات. إن الوقت الذي يقضيه شخص ما في الحديث عن نفسه أثناء محادثة ما يرتبط بمدى أنانيته وكذبه على الآخرين. كما أن أنانية الشخص ترتبط بمدى كذبه على الآخرين. وباختصار فإن الأشخاص الأنانيين يميلون للكذب والحديث عن أنفسهم.

	Talk1	Social Skills	Interest	Talk2	Selfish	Liar
Talk1	1.000	العامل 1				
Social Skills	**0.772**	**1.000**				
Interest	**0.646**	**0.879**	1.000			
Talk2	0.074	-1.200	0.054	1.000	العامل 2	
Selfish	-0.131	0.031	-0.101	**0.441**	**1.000**	
Liar	0.068	0.012	0.110	**0.361**	**0.277**	1.000

الجدول 1.15 المصفوفة R

ونسعى في التحليل العاملي لتخفيض المصفوفة R إلى أبعادها القاعدية بالنظر إلى المتحولات التي تبدو مجمعة معاً بطريقة مفيدة. ويتم تخفيض البيانات بالبحث عن المتحولات التي ترتبط بشكل وثيق مع مجموعة من المتحولات الأخرى، ولكنها لا ترتبط مع المتحولات خارج تلك المجموعة. في هذا المثال، هناك مجموعتان تحققان المطلوب. لذلك يبدو أن العامل الأول متعلق بالاجتماعية العامة (General Sociability)، بينما يبدو العامل الثاني متعلقاً بكيفية تعامل الشخص اجتماعياً مع مراعاة الآخرين (Consideration). ولهذا يمكن أن نفترض أن الشعبية (حب الناس) لا تعتمد فقط على قدرة الشخص على أن يكون اجتماعياً، بل تعتمد أيضاً على صدقه تجاه الآخرين.

1.2.15 التمثيل البياني للعوامل

العوامل (ويجب تمييزها عن المتحولات المستقلة في ANOVA العاملي) هي كيانات إحصائية يمكن رؤيتها كمحاور تصنيف يتم عليها رسم متحولات القياس. ويعني ذلك أنه إذا تخيلنا العوامل كمحاور في مخطط بياني فإنه يمكننا رسم المتحولات على هذه المحاور. وتمثل إحداثيات المتحولات على كل محور قوة العلاقة بين ذلك المتحول وكل عامل من العوامل. يبين الشكل 1.15 هذا المخطط لبيانات الشعبية (لدينا عاملان فقط). إن أول ما يجب ملاحظته من أجل كلا العاملين أن قيم المحور تتراوح بين 1- و 1+ وهي حدود معامل الارتباط. لذلك فإن موقع متحول معين يعتمد على ارتباطه بالعاملين. تمثل الدوائر المتحولات الثلاثة التي ترتبط بشكل وثيق مع العامل الأول (المحور الأفقي: الاجتماعية) وبشكل خفيف مع العامل الثاني (المحور الشاقولي: مراعاة الآخرين). أما المثلثات فتمثل المتحولات التي ترتبط بشكل وثيق مع العامل الثاني (مراعاة الآخرين) وبشكل خفيف مع العامل الأول (الاجتماعية). ومن هذا المخطط يمكننا القول أن الأنانية ومقدار حديث الشخص عن نفسه وميله للكذب على الآخرين، تساهم جميعاً في العامل الذي يمكن تسميته مراعاة الآخرين. أما حديث الشخص عن الآخرين، وطرافة الشخص ومستوى مهاراته الاجتماعية فتساهم في العامل الذي يمكن تسميته الاجتماعية. لذلك فإن هذا المخطط يدعم البنية التي كانت ظاهرة في المصفوفة R. إذا وُجد عامل ثالث ضمن هذه البيانات فيمكن تمثيله على محور ثالث (إنشاء مخطط ثلاثي الأبعاد). أما إذا كان عدد العوامل أكثر من ثلاثة فلا يمكن تمثيلها على مخطط.

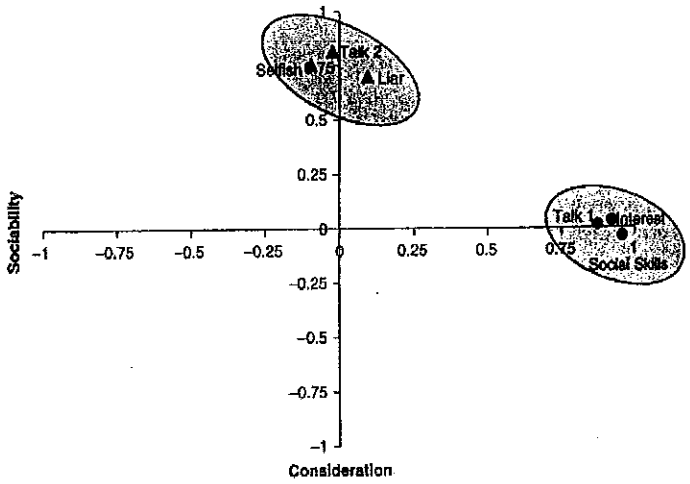

الشكل 1.15 مثال عن مخطط العوامل

إذا كان كل محور في المخطط يمثل عاملاً، فإنه يمكن رسم المتحولات التي تشكل عاملاً ما وفق مدى علاقتها مع عامل معطى. ولذلك تمثل إحداثيات المتحول علاقته مع العوامل. في عالم مثالي، يكون لمتحول ما إحداثيات كبيرة على أحد المحاور، وإحداثيات صغيرة من أجل بقية العوامل. ويدل هذا السيناريو على أن هذا المتحول يتعلق بعامل واحد فقط. وعندما تملك عدة متحولات إحداثيات كبيرة على نفس المحور فإننا نفترض أنها تقيس المعالم المختلفة لبعد قاعدي مشترك معين. تدعى إحداثيات المتحول على محور التصنيف بتحميل العامل (Factor loading). ويمكن النظر إلى تحميل العامل على أنه معامل Pearson للارتباط بين عامل ما ومتحول ما (انظر المربع 1.15). ومما تعلمناه عن تفسير معاملات الارتباط (انظر الفقرة 3.5.4) يمكننا أن نقول أنه إذا قمنا بتربيع تحميل العامل فإننا نحصل على قياس للأهمية الجوهرية لمتحول معين بالنسبة لعامل ما.

2.2.15 التمثيل الرياضي للعوامل

إن المحاور المرسومة في الشكل 1.15 هي خطوط مستقيمة، ولذلك يمكن توصيفها رياضياً بمعادلة خط مستقيم. ويمكن أيضاً توصيف العوامل بهذه المعادلة. تُذكّرنا المعادلة (1.15) بالمعادلة التي تصف نموذجاً خطياً وهي تنطبق على هذه الحالة لتوصيف عامل ما. ستلاحظ عدم وجود اعتراض في هذه المعادلة وذلك لأن الخطوط تتقاطع عند الصفر (لذلك فإن الاعتراض =0). تمثل القيم b في هذه المعادلة قيم تحميل العامل:

$$Y_i = b_1X_1+b_2X_2+ \ldots+b_nX_n+\varepsilon_i$$

$$Factor_i = b_1Variable_1+b_2Variable_2+ \ldots+ b_nVariable_n+\varepsilon_i \qquad (1.15)$$

ونبقى مع مثال الشعبية حيث وجدنا أن هناك عاملين لهذه البنية وهما الاجتماعية ومراعاة الآخرين. لذلك يمكننا إنشاء معادلة لوصف كل من العاملين بدلالة المتحولات التي تم قياسها. وهاتان المعادلتان هما:

$$\begin{aligned}\text{Sociabilit } y_i &= b_1.\text{Talk1}_i + b_2.\text{Social Skills}_i + b_3.\text{Interest}_i \\ &\quad + b_4.\text{Talk2}_i + b_5.\text{Selfish}_i + b_5.\text{Liar}_i + \varepsilon_i \\ \text{Considerat ion}_i &= b_1.\text{Talk1}_i + b_2.\text{Social Skills}_i + b_3.\text{Interest}_i \\ &\quad + b_4.\text{Talk2}_i + b_5.\text{Selfish}_i + b_5.\text{Liar}_i + \varepsilon_i\end{aligned} \qquad (2.15)$$

نلاحظ أولاً أن المعادلتين متماثلتين من ناحية الشكل، فكلاهما تتضمنان جميع المتحولات المقاسة. أما قيم b في المعادلتين فستكون مختلفة (اعتماداً على الأهمية النسبية لكل متحول في العامل المقصود). وفي الحقيقة، يمكننا تبديل كل قيمة b بإحداثيات المتحول على المخطط المبين في الشكل 1.15 (أي استبدال قيمة b بتحميل العامل)، فتكون المعادلتان بالشكل التالي:

$$\begin{aligned}\text{Sociabilit } y_i &= 0.87 \times \text{Talk1}_i + 0.96 \times \text{Social Skills}_i + 0.92 \times \text{Interest}_i \\ &\quad + 0.00 \times \text{Talk2}_i - 0.10 \times \text{Selfish}_i + 0.09 \times \text{Liar}_i + \varepsilon_i \\ \text{Considerat ion}_i &= 0.01 \times \text{Talk1}_i - 0.03 \times \text{Social Skills}_i + 0.04 \times \text{Interest}_i \\ &\quad + 0.82 \times \text{Talk2}_i + 0.75 \times \text{Selfish}_i + 0.70 \times \text{Liar}_i + \varepsilon_i\end{aligned} \qquad (3.15)$$

لاحظ أنه من أجل عامل الاجتماعية فإن قيم b مرتفعة من أجل المتحولات Talk1 وSocial Skills وInterest. أما من أجل المتحولات Talk2 وSelfish وLiar فإن قيم b منخفضة جداً (قريبة من الصفر). ويدلنا ذلك على أن ثلاثة متحولات هي هامة جداً لهذا العامل (ذات قيم b المرتفعة) وأن ثلاثة متحولات هي غير هامة (ذات قيم b المنخفضة). وقد رأينا أن هذه النقطة صحيحة لأن هذه المتحولات الهامة مجمعة على مخطط العوامل. ويجب أن تتذكر أن مخطط العوامل وهذه المعادلات تمثلان نفس الشيء، فتحميل العوامل على المخطط هي ببساطة قيم b في هذه المعادلات (ولكن انظر المربع 1.15). ومن أجل العامل الثاني (اعتبار الآخرين) فإننا نجد النمط المعاكس حيث تملك المتحولات Talk2 وSelfish وLiar قيم b مرتفعة، بينما تملك المتحولات الباقية Talk1 وocial Skills وInterest قيم b قريبة من الصفر.

يمكن وضع تحميل العوامل في مصفوفة، حيث تمثل الأعمدة العوامل، وتمثل الصفوف قيم التحميل لكل متحول من أجل كل عامل، ومن أجل المثال الحالي يكون عدد أعمدة هذه المصفوفة 2 (عمود لكل عامل) وعدد أسطرها 6 (سطر لكل متحول). تدعى هذه المصفوفة عادة مصفوفة العوامل (Factor matrix) أو مصفوفة المكونات (Component matrix) (إذا قمنا بتحليل المكونات الأساسية– انظر المربع 1.15 لمعرفة الأشكال المختلفة لهذه المصفوفة)، ويرمز لها بالحرف A:

$$A = \begin{pmatrix} 0.87 & 0.01 \\ 0.96 & -0.03 \\ 0.92 & 0.04 \\ 0.00 & 0.82 \\ -0.10 & 0.75 \\ 0.09 & 0.70 \end{pmatrix}$$

الفرضية الأساسية في التحليل العاملي هي أن العوامل الجبرية تمثل أبعاد العالم الحقيقي، ويجب تخمين طبيعتها بفحص المتحولات التي لها تحميل مرتفع على نفس العامل. لذلك يعتقد علماء النفس أن العوامل تمثل أبعاد النفس، ويعتقد الباحثون في مجال التعليم أنها تمثل القدرات، بينما يعتقد علماء الاجتماع أنها تمثل الأعراق أو الطبقات الاجتماعية. على كل حال، تشكل هذه الفرضية نقطة جدل كبيرة، ويعتقد البعض أن الأبعاد المشتقة من التحليل العاملي هي حقيقة بالمعنى الإحصائي فقط، ولكنها محض خيال في العالم الحقيقي.

المربع 1.15 ما الفرق بين مصفوفة النمط ومصفوفة البنية؟

كانت مناقشتنا لتحميل العوامل مبهمة نوعاً ما. فقد قلنا أنه يمكن النظر إليها كمعاملات ارتباط بين متحول ما وعامل ما، ثم وضعناها في مكان آخر بدلالة معاملات التراجع (b). ومن خلال ما اكتشفناه في الفصلين 4 و 5 فيجب أن يكون بديهياً أن معاملات التراجع ومعاملات الارتباط هي معاملات مختلفة تماماً عن بعضها، فما الذي نقوله إذاً؟ وما هي قيم تحميل العوامل بالضبط؟

يمكننا القول أن معاملات الارتباط ومعاملات التراجع تمثل العلاقة بين متحول ما ونموذج خطي بالمعنى الواسع! لذلك يكون المغزى الرئيسي الذي ينبغي عليك فهمه هو أن تحميل العامل يدلنا على المساهمة النسبية لمتحول ما في عامل معين.

وفي تحليل معين، يمكن أن تكون قيم تحميل العامل هي معاملات الارتباط ومعاملات التراجع بآن واحد. وبعد عدة فقرات سنكتشف أن تفسير التحليل العاملي يتم بمساعدة كبيرة من تقنية تدعى الدوران (Rotation). وبدون أن ندخل في التفاصيل يمكننا أن نقول أن هناك نوعان: الدوران المتعامد والدوران المائل (انظر الفقرة 6.3.15). عند استخدام الدوران المتعامد فإن العوامل القاعدية تعتبر مستقلة، ويصبح تحميل العامل هو معامل الارتباط بين العامل والمتحول، وبنفس الوقت معامل التراجع. أي أن قيم معاملات الارتباط هي نفس قيم معاملات التراجع. في بعض الحالات، يُفترض أن العوامل القاعدية متعلقة أو مرتبطة ببعضها البعض. وفي هذه الحالات يُستخدم الدوران المائل وتكون معاملات الارتباط الناتجة بين المتحولات والعوامل مختلفة عن معاملات التراجع. وفي هذه الحالة هناك مجموعتان مختلفتان من قيم تحميل العامل: معاملات الارتباط بين كل متحول وكل عامل ويتم وضعها في مصفوفة البنية للعامل (Factor structure matrix)، ومعاملات التراجع من أجل كل متحول لكل عامل ويتم وضعها في مصفوفة النمط للعامل (Factor pattern matrix). ويمكن أن يكون لهذه المعاملات تفسير مختلف تماماً.

3.2.15 علامات العامل

يمكن توصيف عامل ما بدلالة المتحولات المقاسة والأهمية النسبية لهذه المتحولات (ممثلة بالقيم b). لذلك وبعد أن اكتشفنا العوامل الموجودة، وكتبنا المعادلات التي تصفها، يصبح من الممكن تقدير علامة شخص ما في عامل ما، اعتماداً على علاماته في المتحولات المكونة لهذا العامل. وهكذا، إذا أردنا اشتقاق علامة الاجتماعية لشخص معين فإنه يمكننا وضع علاماته للقياسات المختلفة في المعادلة (3.15). تدعى هذه الطريقة بالمعدَّل المثقَّل (Weighted average). وفي الواقع، فإن هذه الطريقة نادرة الاستخدام، ولكنها أبسط طريقة لشرح المبدأ. فعلى سبيل المثال، تخيل أن قيم المقاييس الستة لمثال الشعبية تتراوح بين 0 و10، وان علامات شخص ما هي: 4 (Talk1) و9 (Social Skills) و8 (Interest) و6 (Talk 2) و8 (Selfish) و6 (Liar). يمكننا تبديل هذه العلامات في المعادلة (3.15) للحصول على علامة هذا الشخص في العامل Sociability والعامل Consideration:

$$\begin{aligned} \text{Sociability} &= 0.87\times 4 + 0.96\times 9 + 0.92\times 8 + 0.00\times 6 - 0.10\times 8 + 0.09\times 6 = 19.22 \\ \text{Consideration} &= 0.01\times 4 - 0.03\times 9 + 0.04\times 8 + 0.82\times 6 + 0.75\times 8 + 0.70\times 6 = 15.21 \end{aligned} \quad (4.15)$$

تعكس العلامات الناتجة (19.22 و15.21) درجة الاجتماعية لهذا الشخص وعدم اعتباره لمشاعر الآخرين. وتؤثر سلالم القياس المستخدمة على العلامات الناتجة، وإذا استخدمتْ المتحولات المختلفة سلالم قياس مختلفة فإنه لا يمكن مقارنة علامات العامل من أجل العوامل المختلفة. ولذلك فإن هذه الطريقة لحساب علامات العامل ضعيفة، وعادة يتم استخدام طرق متقدمة لتنفيذ هذه الحسابات.

1.3.2.15 طريقة التراجع

هناك عدة تقنيات متقدمة لحساب علامات العامل والتي تستخدم معاملات علامة العامل كأثقال في المعادلة (1.15) بدلاً من قيم تحميل العامل. ويبقى شكل المعادلة دون تغيير، ولكن يتم استبدال قيم b في المعادلة بمعاملات علامة العامل. ويمكن حساب معاملات علامة العامل بطرق عديدة، وتعتبر طريقة التراجع من أسهل تلك الطرق. في هذه الطريقة يتم ضبط قيم تحميل العامل لتأخذ معاملات الارتباط الأولية بين المتحولات بعين الاعتبار، وبذلك تتم موازنة الفروق في وحدات القياس وتباينات المتحولات.

للحصولّ على مصفوفة معاملات علامة العامل (B) نضرب مصفوفة تحميل العامل (A) بمقلوب مصفوفة الارتباط الأصلية (R^{-1}). وتمثل المصفوفة الناتجة العلاقة بين كل متحول وكل عامل مع أخذ العلاقات الأصلية بين كل زوج من المتحولات بعين الاعتبار. وبذلك تكون مقياساً أنقى للعلاقة الوحيدة بين المتحولات والعوامل.

ومن أجل بيانات المثال الحالي، فإن برنامج SPSS يعطي المصفوفة B، ويمكنك التحقق من ذلك يدوياً بتنفيذ عملية ضرب المصفوفات (انظر الملحق A.9):

$$B = R^{-1} \cdot A$$

$$B = \begin{pmatrix} 4.76 & -7.46 & 3.91 & -2.35 & 2.42 & -0.49 \\ -7.46 & 18.49 & -12.42 & 5.45 & -5.54 & 1.22 \\ 3.91 & -12.42 & 10.07 & -3.65 & 3.79 & -0.96 \\ -2.35 & 5.45 & -3.65 & 2.97 & -2.16 & 0.02 \\ 2.42 & -5.54 & 3.79 & -2.16 & 2.98 & -0.56 \\ -0.49 & 1.22 & -0.96 & 0.02 & -0.56 & 1.27 \end{pmatrix} \begin{pmatrix} 0.87 & 0.01 \\ 0.96 & -0.03 \\ 0.92 & 0.04 \\ 0.00 & 0.82 \\ -0.10 & 0.75 \\ 0.09 & 0.70 \end{pmatrix}$$

$$= \begin{pmatrix} 0.343 & 0.006 \\ 0.376 & -0.020 \\ 0.362 & 0.020 \\ 0.000 & 0.473 \\ -0.037 & 0.437 \\ 0.039 & 0.405 \end{pmatrix}$$

إن نمط قيم التحميل مماثل لنمط معاملات علامة العامل، فالمتحولات الثلاثة الأولى تملك تحميلاً كبيراً للعامل الأول وتحميلاً خفيفاً للعامل الثاني، بينما المتحولات الثلاثة الأخيرة تملك تحميلاً خفيفاً للعامل الأول و تحميلاً كبيراً للعامل الثاني. والفرق الوحيد هو القيم الفعلية للتثقيل التي أصبحت أصغر وذلك بسبب أخذ الارتباط بين المتحولات بعين الاعتبار. يمكن استخدام معاملات علامة العامل بدلاً من القيم b في المعادلة (4.15):

$$\begin{aligned} \text{Sociability} &= 0.343 \times \text{Talk1} + 0.376 \times \text{Social Skills} + 0.362 \times \text{Interest} \\ &\quad + 0.000 \times \text{Talk2} \quad 0.037 \times \text{Selfish} + 0.039 \times \text{Liar} \\ \text{Sociability} &= 0.343 \times 4 + 0.376 \times 9 + 0.362 \times 8 \\ &\quad + 0.000 \times 6 - 0.037 \times 8 + 0.039 \times 6 \\ &= 7.59 \\ \text{Considerat ion} &= 0.006 \times \text{Talk1} \quad 0.020 \times \text{Social Skills} + 0.020 \times \text{Interest} \\ &\quad + 0.473 \times \text{Talk2} + 0.473 \times \text{Selfish} + 0.405 \times \text{Liar} \\ \text{Considerat ion} &= 0.006 \times 4 - 0.020 \times 9 + 0.020 \times 8 \\ &\quad + 0.473 \times 6 + 0.473 \times 8 + 0.405 \times 6 \\ &= 8.768 \end{aligned} \qquad (5.15)$$

تبين المعادلة (5.15) كيفية استخدام هذه المعاملات لحساب علامات العاملَين لكل شخص. وفي هذه الحالة، للمشترك نفس العلامات من أجل كل متحول كما في المعادلة (4.15). والعلامات الناتجة متشابهة أكثر مما كانت عليه عند استخدام قيم تحميل العامل كأثقال وذلك لأنه تم التحكم بالتباينات المختلفة بين المتحولات الستة. وتعكس هذه القيم المرتفعة والمتشابهة جداً لعلامات العاملَين أن هذا الشخص يحقق علامات مرتفعة للمتحولات المتعلقة بالاجتماعية، وكذلك علامات مرتفعة للمتحولات المتعلقة بعدم مراعاة الآخرين. تضمن هذه التقنية لحساب علامات العامل أن للعلامات الناتجة متوسطاً يساوي 0 وتبايناً يساوي مربع قيمة الارتباط المتعدد بين علامات العامل المقدرة وقيم العامل الحقيقية. على كل حال، يتمثل الجانب السلبي لطريقة التراجع بأن العلامات يمكن أن ترتبط ليس فقط بالعوامل الأخرى غير المستندة إليها، ولكن أيضاً بعلامات العامل الآخر الناتجة عن عامل متعامد مختلف.

2.3.2.15 الطرق الأخرى

للتغلب على المشاكل المرتبطة بطريقة التراجع، تم اقتراح تعديلين: طريقة Bartlett وطريقة Anderson-Rubin. ويمكن لبرنامج SPSS أن يعطي علامات العامل اعتماداً على أي من هاتين الطريقتين. تعطي طريقة Bartlett علامات غير منحازة وترتبط فقط بالعامل الخاص بها. وتكون قيم المتوسط والانحراف المعياري للعلامات مطابقة للقيم التي تعطيها طريقة التراجع. وعلى كل حال، يمكن أن تبقى علامات العامل مرتبطة ببعضها. الطريقة الأخيرة هي طريقة Anderson-Rubin، وهي تعديل لطريقة Bartlett وتعطي علامات العامل غير المرتبطة والمعيارية (المتوسط=0، الانحراف المعياري=1). وقد استنتج Tabachnick & Fidell (2001) أن طريقة Anderson-Rubin هي المثلى عندما يكون المطلوب هو علامات غير مرتبطة، ولكن طريقة التراجع هي المفضلة في الحالات الأخرى لأنها الأبسط ويمكن فهمها بسهولة. ومع أنه من غير المهم معرفة الخلفية الرياضية لكل طريقة، فمن المهم معرفة أن علامات العامل تمثل علامة مركبة لكل مشترك على عامل محدد.

3.3.2.15 استخدامات علامات العامل

هناك عدة استخدامات لعلامات العامل. إذا كان الهدف من التحليل العاملي تخفيض مجموعة البيانات إلى مجموعة جزئية أصغر من متحولات القياس فإن علامات العامل تدلنا على علامة مشترك ما وفق هذه المجموعة الجزئية من القياسات. ولذلك فإنه يمكن تنفيذ عمليات التحليل اللاحقة على علامات العامل بدلاً من البيانات الأصلية. فعلى سبيل المثال، يمكننا تنفيذ اختبار t لمعرفة فيما إذا كانت الإناث أكثر اجتماعية من الذكور باستخدام علامات العامل Sociability. الاستخدام الثاني لعلامات العامل هو للتغلب على مشاكل الارتباط الخطي في التراجع. فإذا حددنا مصادر الارتباط المتعدد بعد عملية تحليل تراجع متعدد فإن تفسير التحليل يكون موضع تساؤل (انظر الفقرة 3.2.6.5). في هذه الحالة، يمكننا تنفيذ تحليل عاملي على المتحولات التنبؤية لتخفيضها إلى مجموعة من العوامل غير المرتبطة. سيتم تركيب المتحولات التي تسبب الارتباط الخطي المتعدد لتشكل عاملاً واحداً. فإذا أعدنا تنفيذ تحليل التراجع بعد ذلك ولكن باستخدام علامات العامل كمتحولات تنبؤية فإن مشكلة الارتباط الخطي المتعدد ستختفي (لأن المتحولات أصبحت مركبة في عامل وحيد). هناك طرق يمكن من خلالها التأكد بأن العوامل غير مرتبطة (وإحدى الطرق هي استخدام طريقة Anderson-Rubin). وباستخدام علامات العامل غير المرتبطة كمتحولات تنبؤية في التراجع يمكن أن نكون على ثقة بعدم وجود ارتباط بين المتحولات التنبؤية وبالتالي عدم وجود ارتباط خطي متعدد.

3.15 اكتشاف العوامل

تبحث هذه الفقرة في كيفية إيجاد العوامل. وسنختبر الطرق المختلفة، ونتعرف على الخلفية الرياضية لإحدى الطرق (طريقة المكونات الأساسية)، ونتحرى المعايير لتحديد أهمية العامل، ونكتشف كيفية تحسين التفسير لحل معطى.

1.3.15 اختيار طريقة

إن أول شيء تجب معرفته هو وجود عدة طرق لاكتشاف العوامل المخفية في البيانات. ويعتمد اختيار الطريقة على الهدف الذي تنشده من تنفيذ التحليل. وهناك شيئان يجب أخذهما بعين الاعتبار: هل سيتم تعميم النتائج من العينة على المجتمع، وهل يتم استكشاف البيانات أم اختبار فرضية محددة. يصف هذا الفصل تقنيات استكشاف البيانات باستخدام التحليل العاملي. أما اختبار الفرضيات حول بنى المتحولات المستترة وعلاقاتها مع بعضها البعض فهو معقد جداً ويمكن تنفيذه باستخدام برنامج خاصة مثل AMOS، وتدعى تقنياته بالتحليل العاملي التأكيدي (Confirmatory actor Analysis). بفرض أننا نريد استكشاف البيانات، علينا أن نحدد فيما إذا كنا نريد تطبيق النتائج على العينة المعتبرة (الطرق الوصفية Descriptive methods) أو تعميم النتائج على مجتمع ما (الطرق الاستدلالية Inferential methods). عندما تم وضع التحليل العاملي كان المفترض أن يتم استخدامه لاستكشاف البيانات بهدف تعميم الفرضيات المستقبلية. وهكذا تم افتراض أن تطبيق هذه التقنية سيتم على المجتمع المقصود بكامله. ولذلك تفترض بعض التقنيات أن العينة المستخدمة هي المجتمع، ولذلك لا يمكن استيفاء النتائج خارج العينة المعتبرة. ومن هذه التقنيات تحليل المكونات الأساسية وتحليل العوامل الأساسية وتحليل التباين المشترك للصورة. ويعتبر تحليل المكونات الأساسية وتحليل العوامل الأساسية من الطرق المفضلة ويعطيان نتائج متماثلة (انظر الفقرة 3.3.15). وعند استخدام هذه الطرق فإن الاستنتاجات تكون مقتصرة على العينة المعتبرة، ولا يمكن تعميم النتائج إلا عندما يعطي التحليل باستخدام عينات مختلفة نفس بنية العامل.

هناك مقاربة أخرى تفترض أنه تم اختيار المشتركين بشكل عشوائي وأن المتحولات المقاسة تشكل مجتمع المتحولات الذي يهمنا. بافتراض ذلك، يمكننا أن نطور تقنيات تسمح بتعميم النتائج من عينة المشتركين إلى مجتمع أكبر. على كل حال، هناك قيد وهو أن النتائج تبقى صحيحة من أجل مجموعة المتحولات المقاسة (لأننا افترضنا أن هذه المجموعة تشكل المجتمع الكامل للمتحولات). ومن التقنيات في هذه الفئة طريقة الاحتمالية العظمى (Maximum-liklihood method)، وطريقة تحليل Kaiser's alpha إلى عوامل. ويعتمد اختيار الطريقة بشكل كبير على نوع التعميم الذي ترغب بتطبيقه.

2.3.15 التشاركية

قبل المتابعة، من المهم توضيح بعض الأشياء الأساسية حول التباين ضمن المصفوفة R. ومن الممكن حساب التغايرية في العلامات (التباين) لأي قياس معطى (أو متحول). وقد تعرفنا على التباين وطريقة حسابه في الفصل 1. ويتكون التباين الكلي لمتحول معطى من مكونين: جزء مشترك مع بقية المتحولات أو القياسات ويدعى التباين التشاركي (Common variance)، وجزء خاص بذلك المتحول ويدعى التباين الوحيد (Unique variance). ونميل لاستخدام مصطلح "التباين الوحيد" للإشارة إلى التباين الذي يمكن نسبه بصورة موثوقة إلى قياس واحد فقط. على كل حال، هناك أيضاً تباين خاص بأحد القياسات ولكن ليس بشكل موثوق، ويدعى بالتباين العشوائي (Random variance). وتدعى نسبة التباين التشاركي الموجود في متحول ما بالتشاركية (Communality). وهكذا إذا لم يكن للمتحول تباين خاص (أو تباين عشوائي) فإن تشاركيته تساوي 1، أما المتحول الذي لا يشارك أي جزء من تباينه مع أي متحول آخر فتكون تشاركيته مساوية للصفر.

ونهتم في التحليل العاملي بإيجاد الأبعاد القاعدية المشتركة ضمن البيانات ولذلك نهتم بشكل رئيسي بالتباين التشاركي. لذلك عندما نقوم بتنفيذ تحليل عاملي فمن الضروري معرفة مقدار التباين التشاركي الموجود ضمن البيانات. ويضعنا ذلك في مأزق منطقي: لتنفيذ التحليل العاملي علينا معرفة نسبة التباين التشاركي الموجود ضمن البيانات، مع أن الطريقة الوحيدة لإيجاد مقدار التباين التشاركي هي تنفيذ تحليلٍ عاملي! هناك طريقتان لمقاربة هذه المشكلة: الطريقة الأولى هي افتراض أن كل التباين هو تباين تشاركي، وهكذا تكون التشاركية لكل متحول هي 1. وبهذه الفرضية فإننا ننقل البيانات الأصلية إلى مكونات خطية (لذلك تعرف بتحليل المكونات الأساسية). أما في الطريقة الثانية فيتم تقدير مقدار التباين التشاركي بتقدير قيم التشاركية لكل متحول. وهناك طرق مختلفة لتقدير التشاركية ولكن أكثرها استخداماً هي استخدام مربع الارتباط المتعدد SMC (Squared Multiple Correlation) لكل متحول مع بقية المتحولات. ومن أجل المثال الحالي، تخيل أننا نفّذنا التراجع المتعدد باستخدام قياس واحد (Selfish) كمتحول نتيجة، والمتحولات الخمسة الباقية كمتحولات تنبؤية. نستخدم قيمة R^2 الناتجة (انظر الفقرة 2.5.5) كتقدير للتشاركية من أجل المتحول Selfish. والطريقة الثانية هي التي يتم تنفيذها في التحليل العاملي. تسمح هذه التقديرات بتنفيذ التحليل العاملي. بعد الحصول على العوامل القاعدية، يمكن حساب قيم التشاركية التي تمثل الارتباط المتعدد بين كل متحول والعوامل التي تم الحصول عليها. وهكذا فالتشاركية هي مقياس لنسبة التباين التي تبررها العوامل التي تم الحصول عليها.

3.3.15 التحليل العاملي مقابل تحليل المكونات الأساسية

لقد أوضحنا وجود طريقتين لتحديد الأبعاد القاعدية لمجموعة بيانات معينة: التحليل العاملي وتحليل المكونات الأساسية. وتختلف هاتان التقنيتان في تقديرات التشاركية المستخدمة. ويشتق التحليل العاملي نموذجاً رياضياً يتم من خلاله تقدير العوامل، بينما يقوم تحليل المكونات الأساسية بتفكيك

البيانات الأصلية إلى مجموعة من المتغيرات الخطية. وهكذا فإن التحليل العاملي هو الوحيد الذي يمكنه تقدير العوامل القاعدية ويعتمد على فرضيات مختلفة لتكون هذه التقديرات دقيقة. ويهتم تحليل المكونات الأساسية بإيجاد المكونات الخطية الموجودة ضمن البيانات، وكيفية مساهمة متحول معين في تلك المكونات. على كل حال، علينا أن نراعي فيما إذا كانت التقنيات توفر حلولاً مختلفة لنفس المسألة. وبناءً على مراجعة موسعة للأدبيات في هذا الموضوع، فقد استنتج Guadagnoli & Velicer (1998) أن الحلول الناتجة عن تحليل المكونات الأساسية تختلف قليلاً عن تلك الناتجة عن تقنيات التحليل العاملي. وفي الواقع، هناك بعض الحالات التي يكون ذلك غير صحيح. وقد لخص Stevens (1992) واستنتج أنه بوجود 30 متحولاً على الأقل وقيم تشاركية أكبر من 0.7 لجميع المتحولات، فإن الحلول المختلفة غير محتملة، ولكن مع 20 متحول وقيم دنيا للتشاركية (0.4>) فإن الفروق قد تحدث.

وقد وصف Cliff (1987) الجانب الآخر لهذه الحجة ببلاغة حين قال "إن تحليل المكونات هو في أحسن حالاته تحليل عاملي مع بعض الأخطاء المضافة، وفي أسوأ الحالات مجموعة من الأشياء غير المعروفة التي لا يمكن تحديد أي شيء عن طريقها". وعند استخدام تحليل المكونات الأساسية، يجب عدم وصفه كتحليل عاملي، وعدم نسب المعنى الجوهري إلى المكونات الناتجة. وبالنسبة لغير الإحصائيين فلا يمكن تحديد الفرق بين مكون أساسي وعامل من حيث المبدأ (فكلاهما نموذج خطي)، وتنتج الفروق عن الحسابات.

4.3.15 نظرية تحليل المكونات الأساسية

يعمل تحليل المكونات الأساسية بطريقة مشابهة لطريقة عمل MANOVA وتحليل تابع المميز (انظر الفصل السابق). ففي MANOVA يتم حساب عدة مصفوفات SSCP وهي تحوي معلومات عن العلاقات بين المتحولات التابعة. وقد ذكرنا سابقاً أنه يمكن تحويل مصفوفات SSCP إلى مصفوفات تباين-تباين مشترك بسهولة، وهي تمثل نفس المعلومات ولكن بشكل متوسط (فهي تأخذ عدد المشاهدات بعين الاعتبار). وقلنا أيضاً أنه بتقسيم كل عنصر على الانحراف المعياري المرتبط به تصبح مصفوفات التباين-التباين المشترك معيارية. والنتيجة هي مصفوفة ارتباط.

وفي التحليل العاملي نتعامل عادة مع مصفوفات الارتباط (ومن الممكن أيضاً تحليل مصفوفة تباين-تباين مشترك) وهي تمثل نفس المعلومات كما في مصفوفة SSCP في MANOVA. والفرق هو أن مصفوفة الارتباط هي نسخة متوسطة من مصفوفة SSCP التي تم جعلها قياسية.

في MANOVA، استخدمنا عدة مصفوفات SSCP والتي مثلت المكونات المختلفة للتغاير التجريبي (تغاير النموذج وتغاير الباقي). وفي تحليل المكونات الأساسية لا يمكن تقسيم مصفوفة التباين المشترك (أو الارتباط) بهذه الطريقة. لأن جميع البيانات تأتي من نفس مجموعة المشتركين). وفي MANOVA، نجد أنفسنا ننظر إلى المتغيرات أو مكونات المصفوفة SSCP التي تمثل نسبة تباين النموذج

إلى تباين الخطأ. وهذه المتغيرات هي الأبعاد الخطية التي تفصل المجموعات المختبرة، وقد رأينا أنه يمكن تحويل المتحولات التابعة إلى المكونات القاعدية. وباختصار فإننا نحاول معرفة فيما إذا كان ممكناً الفصل بين المجموعات بتركيب خطي من المتحولات التابعة. وتم إيجاد هذه المتغيرات بحساب الأشعة الخاصة لمصفوفة SSCP. إن عدد المتغيرات التي تم الحصول عليها هو القيمة الأصغر بين P (عدد المتحولات التابعة) و k-1 (حيث k عدد المجموعات). وفي تحليل المكونات قمنا بشيء مماثل، فقد أخذنا مصفوفة ارتباط وحسبنا المتغيرات. ليست هناك مجموعات من المشاهدات، ولذلك فإن عدد المتغيرات المحسوبة سيكون دائماً مساوياً لعدد المتحولات المقاسة (P). ويتم وصف المتغيرات، كما في MANOVA، بالأشعة الخاصة المتعلقة بمصفوفة الارتباط. وعناصر الأشعة الخاصة هي الأثقال لكل متحول في المتغير (انظر المعادلة (5.14)). وهذه القيم هي قيم تحميل العامل الموصوفة سابقاً. وتوفر القيمة الخاصة الكبرى المتعلقة بكل شعاع خاص مؤشراً على الأهمية الجوهرية لكل متغير (أو مكون). والفكرة الأساسية هي أننا نحتفظ بالعوامل ذات القيم الخاصة الكبيرة نسبياً ونهمل العوامل ذات القيم الخاصة الصغيرة نسبياً.

والخلاصة هي أن تحليل المكونات يعمل بطريقة مماثلة لطريقة عمل MANOVA. حيث نبدأ بمصفوفة تمثل العلاقات بين المتحولات. يتم بعد ذلك حساب المكونات الخطية (تدعى أيضاً المتغيرات أو العوامل) لتلك المصفوفة بحساب القيم الخاصة للمصفوفة. ثم نستخدم القيم الخاصة لحساب الأشعة الخاصة، وهي العناصر التي تعطي تحميل متحول معين لعامل محدد (إنها قيم b في المعادلة (1.15)). والقيم الخاصة هي مقياس أيضاً للأهمية الجوهرية للشعاع الخاص المرتبط به.

5.3.15 استخراج العوامل: القيم الخاصة ومخطط المنحدر

لا يتم الاحتفاظ بجميع العوامل الناتجة عن التحليل، وهناك جدل حول المعيار المستخدم لتحديد العامل المهم إحصائياً. ذكرنا سابقاً أن القيم الخاصة المرتبطة مع متغير تدل على الأهمية الجوهرية لذلك العامل. ولهذا يبدو من المنطقي أن نحتفظ بالعوامل ذات القيم الخاصة الكبيرة فقط. ولكن كيف نقرر فيما إذا كانت القيمة الخاصة كبيرة لحد يجعلها ممثلة لعامل مهم؟ هناك تقنية اقترحها Cattell وهي رسم مخطط لكل قيمة خاصة (على المحور Y) مع العامل المرتبطة بها (على المحور X). يدعى هذا المخطط بمخطط الانحدار (Scree plot). وقد ذكرنا سابقاً أنه من الممكن الحصول على عدد من العوامل يساوي عدد المتحولات، وأن كل عامل مرتبط بقيمة خاصة. برسم القيم الخاصة تصبح الأهمية النسبية لكل عامل واضحة. وعادةً يكون هناك عدد قليل من العوامل ذات القيم الخاصة المرتفعة، والعديد من العوامل ذات القيم الخاصة المتدنية، ولذلك فإن لهذا المخطط شكل مميز جداً، إذ يحوي المنحني انحداراً حاداً يليه تلاشي وتضاؤل (انظر الشكل 2.15). ويوحي Cattell بأن نقطة القطع لاختيار العوامل يجب أن تكون عند نقطة الانعطاف لهذا المنحني. فمن أجل عينة تحوي أكثر من 200 مشترك، يوفر هذا المخطط معياراً موثوقاً لاختيار العامل.

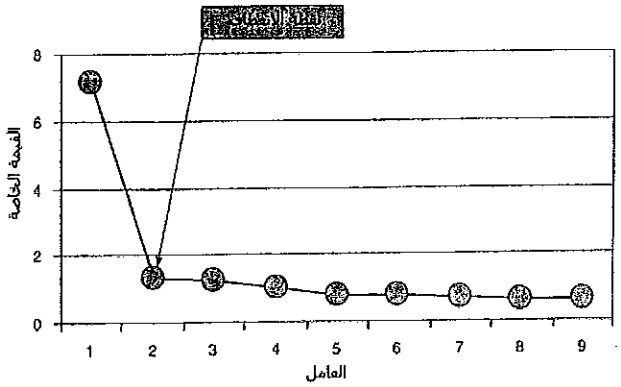

الشكل 2.15 مثال عن مخطط المنحدر (Scree plot) لبيانات ذات عامل قاعدي واحد

ومع أن مخطط المنحدر مفيد جداً، فإن اختيار العامل يجب ألا يكون معتمداً على هذا المعيار فقط. وقد نصح Kaiser (1960) بالاحتفاظ بجميع العوامل التي تكون قيمتها الخاصة أكبر من 1. ويعتمد هذا المعيار على فكرة أن القيم الخاصة تمثل مقدار التغاير الذي يبرره العامل، وأن القيمة 1 للقيمة الخاصة تمثل مقداراً هاماً من التغاير. وذكر Jolliffe (1972, 1986) أن معيار Kaiser صارم جداً واقترح المعيار الثالث الذي ينص على الاحتفاظ بجميع العوامل التي تكون قيمتها الخاصة أكبر من 0.7. والفرق بين عدد العوامل التي يتم الاحتفاظ بها وفق طريقة Kaiser وطريقة Jolliffe يمكن أن يكون هائلاً.

وقد دلت الدراسات على أن معيار Kaiser يكون دقيقاً عندما يكون عدد المتحولات أقل من 30 وجميع قيم التشاركية الناتجة (بعد استخراج العوامل) هي أكبر من 0.7. ويكون دقيقاً أيضاً عندما يزيد حجم العينة عن 250 وتكون التشاركية الوسطية أكبر من أو تساوي 0.6. وفي الحالات الأخرى، يفضل استخدام مخطط المنحدر بشرط أن يزيد حجم العينة عن 200. وبشكل افتراضي، يستخدم برنامج SPSS معيار Kaiser لاستخراج العوامل. ولذلك إذا استخدمت مخطط المنحدر لتحديد عدد العوامل التي تريد الاحتفاظ بها، فربما عليك إعادة تنفيذ التحليل بعد تحديد عدد العوامل التي يجب على برنامج SPSS استخراجها.

وكما هي الحال في الإحصاء، فغالباً ما تعطي المعايير الثلاثة حلولاً مختلفة! وفي هذه الحالة يجب أن تؤخذ التشاركية للعوامل بعين الاعتبار. في تحليل العوامل الأساسية نبدأ بقيمة 1 للتشاركية مع الاحتفاظ بجميع العوامل (لأننا نفترض أن كل التباين هو تباين تشاركي). وحتى هذه المرحلة فإن كل ما فعلناه هو إيجاد المتغيرات الخطية الموجودة في البيانات، أي أننا نقلنا البيانات دون إهمال أي معلومة. ولاكتشاف التباين التشاركي الموجود فعلياً بين المتحولات علينا أن نقرر ما هي العوامل الهامة ونهمل العوامل الأخرى. لذلك فإننا نأخذ بعض المعلومات بعين الاعتبار. لن تبرر العوامل التي نحتفظ بها جميع التباين في البيانات (لأننا أهملنا بعض المعلومات) ولذلك فإن قيم التشاركية بعد

استخراج العوامل ستكون أصغر من 1 دائماً. ولا تنقل العوامل المستبقاة المتحولات الأصلية بشكل مثالي، فهي تعكس فقط التباين الموجود في البيانات. فإذا مثلت قيم التشاركية فقدان المعلومات فإنها تعتبر إحصائيات هامة. وكلما كانت قيمة التشاركية أقرب إلى القيمة 1 كانت العوامل أفضل في تفسير البيانات الأصلية. ومن المنطقي أنه كلما زاد عدد العوامل المستبقاة، كانت قيم التشاركية أكبر (لأنه تم إهمال معلومات أقل)، ولذلك فإن قيم التشاركية هي مؤشرات هامة على عدد العوامل التي تم الاحتفاظ بها. وباستخدام التحليل العاملي بالمربعات الصغرى المعمم والتحليل العاملي بالاحتمالية العظمى يمكنك الحصول على مقياس إحصائي لجودة التوافق لحل العوامل (انظر الفصل التالي لمزيد من التفاصيل عن اختبارات جودة التوافق). ويقيس ذلك بشكل أساسي نسبة التباين التي يفسرها حل العوامل (لذلك يمكن اعتباره مقارنة لقيم التشاركية قبل استخراج العوامل وبعده).

والنصيحة الأخيرة هي أن قرارك بتحديد عدد العوامل التي تريد استخراجها يعتمد أيضاً على الهدف الأساسي لعملية التحليل (فإذا كنت تحاول التغلب على مشاكل الارتباط الخطي المتعدد في التراجع، فمن الأفضل استخراج أكبر عدد ممكن من العوامل).

6.3.15 تحسين التفسير: دوران العوامل

بعد استخراج العوامل يصبح من الممكن حساب درجة تحميل المتحولات على هذه العوامل (أي حساب تحميل المتحول على كل عامل). وبشكل عام نجد أن لمعظم المتحولات تحميلاً مرتفعاً على أهم عامل، وتحميلاً أخف على بقية العوامل. وتجعل هذه السمة التفسير صعباً، ولذلك يتم استخدام تقنية تدعى دوران العوامل (Factor rotation) للتمييز بين العوامل. إذا كان العامل هو محور تصنيف يمكن رسم المتحولات عليه فإن دوران العوامل هي عملية يتم فيها تدوير هذه المحاور بحيث يصبح تحميل المتحولات أعظمياً على عامل واحد فقط. يوضح الشكل 3.15 آلية عمل هذه العملية باستخدام مثال يحوي عاملين فقط. في البداية، يمثل الخطان المستمران (المحور الأفقي والمحور الشاقولي) هذين العاملين، وعند النظر إلى الإحداثيات نجد أن للنقاط الفاتحة تحميلاً مرتفعاً على العامل 2 وتحميلاً متوسطاً على العامل 1. أما النقاط الغامقة فتملك تحميلاً مرتفعاً على العامل 1 وتحميلاً متوسطاً على العامل 2. وبتدوير المحاور (الحصول على الخطين المنقطين) فإننا نضمن أن كلا التجمعين من المتحولات سيتقاطع مع العامل المتعلق به بشكل أكبر. ولذلك فإنه بعد الدوران يصبح تحميل المتحولات أعظمياً على عامل واحد (العامل الذي يتقاطع مع تجمع هذه المتحولات) وأصغرياً على العامل (أو العوامل) الآخر. إذا مر محور عبر تجمع للمتحولات، فإن تحميل هذه المتحولات على المحور الآخر سيكون معدوماً تقريباً. إذا كانت هذه الفكرة مشوشة قليلاً فانظر إلى الشكل 3.15 وقارن بين قيم الإحداثيات قبل تدوير المحاور وبعدها.

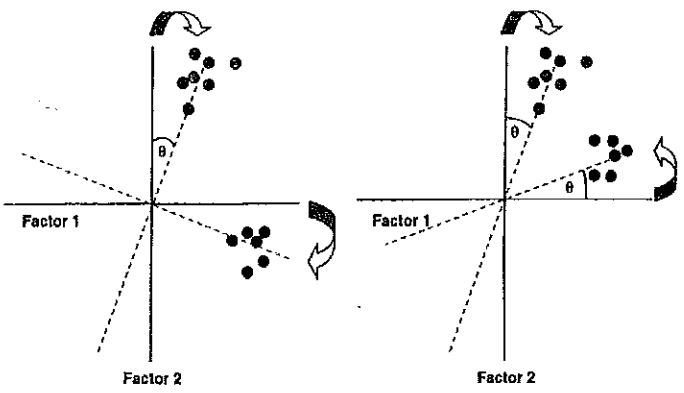

الشكل 3.15 تمثيل تخطيطي لعملية دوران المحاور. يظهر المخطط الأيسر الدوران المتعامد بينما يظهر المخطط الأيمن الدوران المائل. وتمثل θ زاوية الدوران

هناك نوعان من الدوران. النوع الأول هو الدوران المتعامد (Orthogonal rotation) ونراه في المخطط الأيسر من الشكل 3.15. وقد رأينا في الفصل 8 أن المصطلح "متعامد" يعني "غير مرتبط"، وفي هذا الإطار فإنه يعني أننا نقوم بتدوير العوامل مع المحافظة عليها مستقلة. فقبل التدوير كانت جميع العوامل مستقلة (غير مرتبطة نهائياً)، ويضمن الدوران المتعامد بقاء جميع العوامل غير مرتبطة. ولذلك بقيت الزاوية قائمة بين المحاور بعد تدويرها. أما النوع الثاني فهو الدوران المائل (Oblique rotation). وفي هذه الحالة يسمح بالارتباط بين العوامل (ولذلك فإن الزاوية بين المحورين لم تعد قائمة بعد التدوير كما في المخطط الأيمن في الشكل 3.15).

ويعتمد اختيار الدوران على وجود سبب نظري جيد لافتراض ضرورة أن تكون العوامل مرتبطة أو مستقلة، وعلى كيفية تجمع المتحولات على العوامل قبل الدوران. بالنسبة للنقطة الأولى، إذا توقعنا على أسس نظرية طبعاً أن لا يكون أحد العاملين مستقلاً عن الآخر فيمكننا اختيار المائل. أما بالنسبة للنقطة الثانية، فيوضح الشكل 3.15 مدى أهمية توضع التجمعات في تحديد نجاح عملية الدوران (لاحظ موقع النقاط الغامقة). إذا تم تنفيذ الدوران المتعامد في المخطط الأيمن من الشكل 3.15 فإنه سيكون أقل نجاحاً من الدوران المائل في جعل قيم التحميل أعظمية. لذلك من المفضل تنفيذ التحليل باستخدام نوعي الدوران. وقد أشار Pedhazur & Schmelkin (1991) إلى أنه إذا أظهر الدوران المائل ارتباطاً مهملاً بين العوامل المستخرجة فمن المعقول عندئذ استخدام الدوران المتعامد. وإذا كشف الدوران المائل عن بنية عوامل مرتبطة فيجب إهمال الدوران المتعامد عندئذ. وعند وجود أسباب معقولة لافتراض أن العوامل القاعدية قد تكون مرتبطة بالمعنى النظري فإنه يجب استخدام الدوران المائل.

إن الخلفية الرياضية لتدوير العوامل معقدة جداً (وخاصة الدوران المائل). ففي حالة الدوران المائل يمكن تدوير كل عامل بمقدار مختلف عن البقية ولذلك نحتاج لمصفوفة تحويل العوامل Λ (Factor transformation matrix)، وهي مصفوفة مربعة تعتمد أبعادها على عدد العوامل

المستخرجة من البيانات. فإذا كان عدد العوامل 2 فإن أبعاد المصفوفة هي 2×2، وإذا كان عدد العوامل 4 فإن أبعاد المصفوفة هي 4×4. يتم ضرب هذه المصفوفة بمصفوفة قيم تحميل العامل A للحصول على مصفوفة قيم تحميل العوامل المدوّرة. من أجل عاملين فقط فإن مصفوفة تحويل العوامل تأخذ الشكل التالي:

$$\Lambda = \begin{pmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{pmatrix}$$

لذلك يجب النظر إلى هذه المصفوفة كممثل للزاوية التي يتم تدوير المحاور أو العوامل بها. وللحصول على حل أمثلي للعوامل فإنه يتم الحصول على زاوية الدوران بطريقة تكرارية، ويمكن استخدام طرق مختلفة لتحقيق ذلك.

1.6.3.15 اختيار طريقة تدوير العوامل

يوفر برنامج SPSS ثلاث طرق للدوران المتعامد (Varimax وQuartimax وEquamax) وطريقتان للدوران المائل (Direct oblimin وPromax). وتختلف هذه الطرق عن بعضها في كيفية تدويرها للعوامل، ولذلك فإن الخرج الناتج يعتمد على الطريقة المعتمدة. تحاول طريقة دوران Quartimax تكبير انتشار تحميل العوامل من أجل متحول ما عبر جميع العوامل، ولذلك يصبح تفسير المتحولات أكثر سهولة. وغالباً ما ينتج عن ذلك متحولات كثيرة ذات تحميل مرتفع على عامل واحد. أما طريقة Varimax فهي معاكسة تماماً لأنها تحاول تكبير التحميل ضمن العوامل، لذلك فهي تحاول تحميل عدد أصغر من المتحولات بشكل كبير على كل عامل مما يعطي تجمعات للعوامل أسهل تفسيراً. وطريقة Equamax هي طريقة هجينة من الطريقتين السابقتين وتوصف بأنها ذات سلوك متقلب غير منتظم. فمن أجل تحليل أولي عليك اختيار Varimax لأنها طريقة عامة جيدة تبسط تفسير العوامل.

في حالة الدوران المائل تصبح الأمور أكثر صعوبة بسبب السماح بوجود الارتباط بين العوامل. ففي حالة Direct oblimin تتحدد درجة الارتباط المسموح به بقيمة ثابت يدعى دلتا delta. القيمة الافتراضية لهذا الثابت هي 0 في برنامج SPSS وهذا يضمن عدم السماح بحدوث ارتباط كبير بين العوامل (ويدعى ذلك دوران Direct quartimin). إذا اخترت قيمة دلتا بحيث تكون أكبر من 0 (حتى 0.8) فيمكنك أن تتوقع عوامل مرتبطة بشكل كبير، وإذا اخترت قيمة أصغر من 0 (حتى 0.8-) فيمكنك أن تتوقع عوامل أقل ارتباطاً. والقيمة الافتراضية (0) حساسة لمعظم عمليات التحليل ولا ننصح بتغييرها ما لم تكن على معرفة بما تفعله. أما طريقة Promax فهي إجرائية أسرع مصممة لمجموعات البيانات الكبيرة جداً.

ونظرياً، يعتمد الاختيار الدقيق للدوران على اعتقادك بضرورة ارتباط العوامل القاعدية. فإذا كنت تتوقع أن تكون العوامل مستقلة فعليك اختيار إحدى طرق الدوران المتعامد (وننصح باستخدام

Varimax). وإذا كانت هناك أرضية نظرية لافتراض أن العوامل قد تكون مرتبطة فيمكنك اختيار طريقة Direct oblimin. وعملياً، هناك دوافع قوية للاعتقاد بأن عمليات الدوران المتعامد هي هراء بالنسبة للبيانات الطبيعية، وخصوصاً من أجل البيانات التي تتعلق بالبشر (هل تعتقد مثلاً أن أي بنية نفسية هي غير مرتبطة بأي بنية نفسية أخرى؟). ولذلك يقترح البعض عدم استخدام الدوران المتعامد أبداً.

2.6.3.15 الأهمية الجوهرية لقيم تحميل العامل

بعد إيجاد بنية العامل، من المهم تحديد المتحولات المكوّنة لكل عامل. وقد قلنا سابقاً أن قيم تحميل العامل هي مؤشر على الأهمية الجوهرية لمتحول ما من أجل عامل ما. لذلك يمكننا استخدام هذه القيم لوضع المتحولات مع العوامل. من الممكن تقييم الدلالة الإحصائية لتحميل عامل ما (لأنه معامل ارتباط أو معامل تراجع)، وهناك عدة أسباب لعدم سهولة هذا الخيار. وعادةً يعتبر الباحثون القيمة المطلقة للتحميل التي تتجاوز 0.3 كمعيار للأهمية. وعلى كل حال تعتمد دلالة العامل على حجم العينة. وقد أعطى Stevens (1992) جدولاً للقيم الحرجة التي يمكن مقارنة قيم التحميل معها. ونصح بأنه من أجل عينة ذات 50 عنصر يمكن اعتبار قيمة التحميل 0.722 ذات دلالة، ومن أجل عينة ذات 100 عنصر يجب أن تكون قيمة التحميل أكبر من 0.512، ومن أجل 200 عنصر يجب أن يكون التحميل أكبر من 0.364، ومن أجل 300 عنصر يجب أن يكون التحميل أكبر من 0.298، ومن أجل 600 عنصر يجب أن يكون التحميل أكبر من 0.21، ومن أجل 1000 عنصر يجب أن يكون التحميل أكبر من 0.162. وتعتمد هذه القيم على مستوى ألفا 0.01 (ثنائي الطرف) مما يقتضي اختبار عدة قيم للتحميل. لذلك، وفي العينات الكبيرة جداً يمكن اعتبار قيم التحميل الصغيرة مهمة إحصائياً. ولا يقدم برنامج SPSS أي اختبارات للدلالة من أجل قيم تحميل العامل، ولكن تطبيق توجيهات Stevens يوفر رؤية واضحة لبنية المتحولات والعوامل.

وتعطي الدلالة لقيمة تحميل ما مؤشراً صغيراً على الأهمية الجوهرية لمتحول ما من أجل عامل ما. ويمكن إيجاد هذه القيمة بتربيع تحميل العامل للحصول على تقدير لمقدار التباين في عامل ما والذي يساهم به متحول ما (مثل R^2). ولذلك ينصح Stevens بتفسير قيم تحميل العامل ذات القيمة المطلقة التي تتجاوز 0.4 (وهذا يفسر حوالي 16% من التباين في المتحول).

4.15 مثال بحثي

يعتبر تطوير الاستبيانات أحد استخدامات التحليل العاملي (ويحوي الملحق A.11 بعض النصائح حول عملية تطوير الاستبيانات)، فإذا أردنا قياس القابلية أو السمة، فعلينا أن نضمن أن الأسئلة المطروحة تتعلق بالبنية التي نريد قياسها. لاحظ أحد الباحثين أن عدداً كبيراً من الطلاب يصابون بالقلق من برنامج SPSS. لذلك أراد تصميم استبيان لقياس سمة دعاها "قلق SPSS". وقرر وضع

استبيان لقياس السمات المختلفة لقلق الطلاب تجاه تعلم البرنامج SPSS، فوضع أسئلة اعتمدت على مقابلاته مع الطلاب القلقين وغير القلقين، ووصل عدد هذه الأسئلة إلى 23 سؤالاً. وكان كل سؤال متبوعاً بمقياس ذي 5 نقاط يتراوح بين "غير موافق أبداً" إلى "موافق تماماً". ويحوي الشكل 4.15 نسخة من هذا الاستبيان.

SD= غير موافق أبداً، D= غير موافق، N= لا أعرف، A= موافق، SA= موافق تماماً

		SD	D	N	A	SA
1	علم الإحصاء يبكيني	O	O	O	O	O
2	سيعتقد أصدقائي أنني غبي لعدم قدرتي على النجاح في التعامل مع SPSS	O	O	O	O	O
3	الانحرافات المعيارية تثيرني	O	O	O	O	O
4	أحلم بأن Pearson يهاجمني بمعاملات الارتباط	O	O	O	O	O
5	أنا لا أفهم الإحصاء	O	O	O	O	O
6	خبرتي قليلة في التعامل مع جهاز الحاسب	O	O	O	O	O
7	جميع الحواسب تكرهني	O	O	O	O	O
8	لم أكن جيداً أبداً في الرياضيات	O	O	O	O	O
9	أصدقائي أفضل مني في الإحصاء	O	O	O	O	O
10	الحواسب مفيدة من أجل الألعاب فقط	O	O	O	O	O
11	دراستي للرياضيات في المدرسة سيئة جداً	O	O	O	O	O
12	يحاول الناس إقناعي أن SPSS يجعل الإحصاء أسهل فهماً، لكنه ليس كذلك	O	O	O	O	O
13	أخاف أن أسبب أضراراً للحواسب غير قابلة للإصلاح بسبب عدم كفاءتي	O	O	O	O	O
14	للحواسب أدمغتها الخاصة وتنفذ عمليات خاطئة بشكل مقصود عندما أستخدمها	O	O	O	O	O
15	تحاول الحواسب جاهدة النيل مني	O	O	O	O	O
16	أبكي أمام الملأ عند ذكر النزعة المركزية	O	O	O	O	O
17	أصاب بغيبوبة عند رؤية معادلة ما	O	O	O	O	O
18	ينهار برنامج SPSS عندما أحاول استخدامه	O	O	O	O	O
19	ينظر إلي الجميع عندما أستخدم SPSS	O	O	O	O	O
20	لا أستطيع النوم عند التفكير بالأشعة الخاصة	O	O	O	O	O
21	أستيقظ تحت اللحاف وأعتقد أنني محبوس تحت توزيع طبيعي	O	O	O	O	O
22	أصدقائي أفضل مني في استخدام SPSS	O	O	O	O	O
23	إذا كنت جيداً في الإحصاء فإن الناس سيعتقدون أنني عبقري	O	O	O	O	O

الشكل 4.15 استبيان القلق من برنامج SPSS (SAQ)

تم تصميم الاستبيان للتنبؤ بمدى القلق عند شخص معين حول تعلمه كيفية استخدام برنامج SPSS. وأراد الباحث معرفة فيما إذا كان ممكناً تقسيم القلق من SPSS إلى أشكال محددة من القلق. بمعنى آخر، ما هي المتحولات المستترة التي تساهم في القلق من SPSS؟ وبمساعدة من زملائه، جمع الباحث 2571 استبياناً كاملاً. تم تخزين البيانات في الملف SAQ.sav. لنفتح هذا الملف في برنامج

SPSS وننظر إلى المتحولات وخصائصها. وأول ما يجب ملاحظته هو أن كل سؤال (متحول) قد تم تمثيله في عمود مختلف. ونعلم أنه يتم تخزين البيانات لكل شخص في سطر مستقل بينما يتم تخزين المتحولات في أعمدة مستقلة. والشيء الآخر الذي تجب ملاحظته هو وجود 23 متحولاً (أسماؤها Q1 حتى Q23) ولكل متحول تسمية تدل على السؤال.

1.4.15 الاعتبارات الأولية

1.1.4.15 حجم العينة

تتقلب معاملات الارتباط من عينة إلى أخرى، وبشكلٍ أكبر في العينات الصغيرة. لذلك فإن وثوقية التحليل العاملي تعتمد أيضاً على حجم العينة. وقد كُتبت العديد عن المقالات حول حجم العينة الضروري من أجل التحليل العاملي. وأصبحت هناك قواعد أساسية، منها أن يتراوح عدد المشتركين لكل متحول بين 10 و15 مشتركاً على الأقل، مع أن الأسس التجريبية لهذه القاعدة غير واضحة. وقد نصح Kass & Tinsley (1979) بوجود 5 إلى 10 مشتركين لكل متحول بحيث لا يتجاوز العدد الكلي 300 (عند تجاوز هذا الحد تميل بارامترات الاختبار للاستقرار بغض النظر عن نسبة المشتركين إلى المتحولات). وبالفعل يوافق Tabachnick & Fidell (2001) على أن وجود 300 حالة على الأقل هو مريح من أجل التحليل العاملي، بينما يصنف Comrey & Lee (1992) العدد 300 كحجم عينة جيد، و 100 كحجم قليل و 1000 كحجم ممتاز.

لحسن الحظ، فقد رأينا في السنوات الأخيرة أبحاثاً مبينة على التجارب التي تستخدم البيانات المقلدة (وتدعى دراسات مونت كارلو). استخدم Arrindell & van der Ende(1985) بيانات من الحياة الحقيقية لبحث أثر نسب المشتركين المختلفة إلى المتحولات. وقد استنتجنا أن التغير في هذه النسب يؤثر بشكل طفيف على استقرار حلول العوامل. وفي عام 1988 وجد Guadagnoli & Velicer أن أهم العوامل المؤثرة في حساب حل موثوق للعوامل هي حجم العينة المطلق والقيمة المطلقة لمطال تحميل العامل. وباختصار فقد قدما البراهين على أنه إذا كان لعامل ما 4 قيم تحميل على الأقل تزيد عن 0.6 فإن العامل موثوق بغض النظر عن حجم العينة، والعوامل التي فيها 10 قيم تحميل على الأقل تزيد عن 0.4 تكون موثوقة إذا كان حجم العينة يزيد على 150. أما العوامل التي فيها عدد قليل من قيم التحميل المنخفضة فلا يجب تفسيرها ما لم يزيد حجم العينة على 300. وقد أظهر MacCallum, Widaman, Zhang & Hong (1999) أن حجم العينة الأصغري أو نسبة العينة إلى المتحولات الأصغرية تعتمد على مظاهر أخرى للتصميم المدروس. وأشارت دراستهم إلى أنه إذا انخفضت قيم التشاركية فإن أهمية حجم العينة تزداد. فإذا كانت جميع قيم التشاركية أكبر من 0.6 فإن العينات الصغيرة نسبياً (أقل من 100) ربما تكون مناسبة تماماً. وإذا كانت قيم التشاركية في المجال 0.5 فإن العينات ذات الحجم 100 إلى 200 يمكن أن تكون كافية بشرط وجود عدد قليل نسبياً من العوامل التي تحوي عدداً صغيراً من المتحولات ذات الدلالة. وفي أسوأ الحالات لقيم

التشاركية المنخفضة (أدنى من 0.5) ووجود عدد أكبر من العوامل القاعدية فإن هؤلاء الباحثين ينصحون بأن يكون حجم العينة أكبر من 500.

من الواضح من هذه الدراسة أن عينة ذات 300 عنصر على الأقل ربما توفر حلاً مستقراً للعوامل، ولكن الباحث الذكي سيقوم بقياس عدد كافٍ من المتحولات لقياس جميع العوامل التي يتوقع إيجادها نظرياً.

هناك مقاربة أخرى وهي استخدام معيار Kaiser-Meyer-Olkin (KMO) لكفاية أخذ العينات. يمكن حساب KMO للمتحولات المنفردة والمتعددة ويمثل نسبة مربع الارتباط بين المتحولات إلى مربع الارتباط الجزئي بين المتحولات. وتتراوح قيمة KMO بين 0 و1. تدل القيمة 0 على أن مجموع الارتباطات الجزئية كبير جداً مقارنة بمجموع الارتباطات، مما يدل على انتشار نمط الارتباطات (من المحتمل أن يكون التحليل العاملي غير مناسب). أما القيم القريبة من 1 فتدل على أن نمط الارتباطات مضغوط نسبياً ولذلك يجب أن يعطي التحليل العاملي عوامل منفصلة وموثوقة. وقد وصف Kaiser (1974) بأن قبول القيم التي تزيد على 0.5 على أنها بالكاد مقبولة (أما القيم الأصغر فيجب أن تدفع باتجاه جمع بيانات أكثر أو إعادة التفكير بالمتحولات الواجب تضمينها في التحليل). أما القيم بين 0.5 و0.7 فهي متواضعة، والقيم بين 0.7 و0.8 هي جيدة، والقيم بين 0.8 و0.9 هي ممتازة، والقيم الأكبر من 0.9 هي رائعة.

2.1.4.15 تصفية البيانات

إذا وضعنا مجموعة من المتحولات فإن برنامج SPSS سيجد دائماً حلاً للعوامل. ولكن من المرجح ألا يكون لهذا الحل أي معنى إذا لم تكن المتحولات التي تم تحليلها حساسة. إن أول ما يجب فعله عند تنفيذ التحليل العاملي هو النظر إلى الارتباط المتبادل بين المتحولات. إذا كانت أسئلة المثال البحثي (الاستبيان) تقيس نفس البعد القاعدي (أو الأبعاد القاعدية) فعلينا أن نتوقع أن تكون مرتبطة مع بعضها البعض (لأنها تقيس نفس الشيء). وحتى إذا كانت الأسئلة تقيس المظاهر المختلفة لنفس الأشياء (يمكننا قياس القلق الكلي بدلالة المكونات الجزئية مثل الانزعاج، التفكير المتطفل، الإثارة النفسية) فما يزال هناك ارتباط متبادل مرتفع بين المتحولات المتعلقة بهذه السمات. إذا وجدنا أي متحولات لا ترتبط مع المتحولات الأخرى فعلينا استثناء هذه المتحولات قبل تنفيذ التحليل العاملي. هناك حالة قصوى لهذه المسألة وهي عندما تشبه مصفوفة الارتباط المصفوفة المحايدة (انظر الفقرة 2.3.14). في هذه الحالة، ترتبط المتحولات مع ذاتها فقط وتكون جميع معاملات الارتباط الأخرى قريبة من الصفر. يختبر برنامج SPSS ذلك باستخدام اختبار Bartlett للكروية (انظر الفقرة التالية). يمكن التحقق من الارتباط بين المتحولات باستخدام الإجرائية Correlate (انظر الفصل 4) لإنشاء مصفوفة الارتباط لجميع المتحولات. يمكن أيضاً إنشاء هذه المصفوفة كجزء من التحليل العاملي الأساسي.

المسألة المعاكسة هي عندما تكون المتحولات مترابطة بشدة. مع أن الارتباط الخطي المتعدد المعتدل لا يعتبر مشكلة في التحليل العاملي فمن المهم تجنب الارتباط الخطي المتعدد الأقصى (المتحولات مترابطة بشكل مرتفع جداً) والشذوذ (المتحولات مترابطة بشكل تام). وكما في حالة التراجع، يسبب الشذوذ المشاكل في التحليل العاملي لأنه يصبح من المستحيل تحديد المساهمة الوحيدة للمتحولات المترابطة بشدة في عامل ما. لذلك سنقوم في هذه المرحلة المبكرة بحذف المتحولات التي لا ترتبط مع المتحولات الأخرى أو التي ترتبط بشدة مع المتحولات الأخرى (R>0.9). يمكن اكتشاف الارتباط الخطي المتعدد بالنظر إلى قيمة المحدد للمصفوفة R (انظر الفقرة التالية).

كذلك ينبغي التأكد من أن للبيانات توزيعاً طبيعياً تقريباً وأنها مقاسة على مستوى المجال (Interval Level). إن فرضية الطبيعية هي الأهم إذا أردنا تعميم النتائج خارج إطار العينة.

5.15 تنفيذ التحليل

نفتح مربع الحوار الرئيسي (المبين في الشكل 5.15) باستخدام أمر القائمة Analyze ⇒ Data Reduction ⇒ Factor... نختار المتحولات التي نريد تضمينها في التحليل (تذكر استثناء المتحولات التي تم التعرف عليها كإشكالية خلال تصفية البيانات) وننقلها إلى الحيز المسمى Variables.

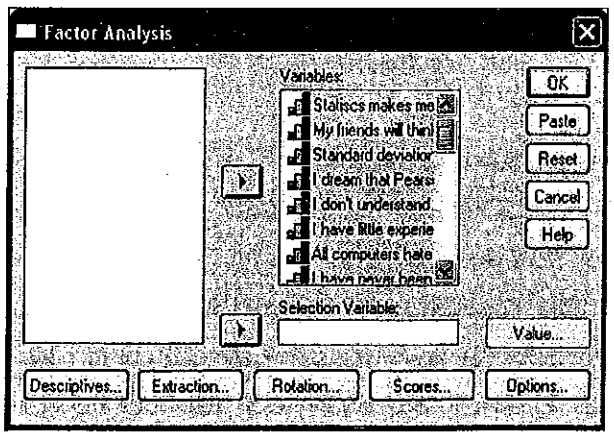

الشكل 5.15 مربع الحوار الرئيسي للتحليل العاملي

تتوفر عدة خيارات، يمكن الوصول إلى أولها بنقر الزر Descriptives... حيث يتم فتح مربع الحوار المبين في الشكل 6.15.

يسمح الخيار Univariate descriptives بالحصول على قيم المتوسط والانحراف المعياري لكل متحول. أما بقية الخيارات فيتعلق معظمها بمصفوفة الارتباط للمتحولات (المصفوفة R). يعطي الخيار Coefficients المصفوفة R، بينما يعطي الخيار Significance Levels مصفوفة تحوي قيم الدلالة لكل معامل ارتباط في المصفوفة R. يمكننا أن نطلب حساب المحدد لهذه المصفوفة باستخدام

الخيار Determinant. وهذا الخيار حيوي من أجل اختبار الارتباط الخطي المتعدد أو الشذوذ. يجب أن تكون قيمة المحدد للمصفوفة R أكبر من 0.00001، وإذا كانت القيمة أصغر من ذلك فيجب البحث في مصفوفة الارتباط عن المتحولات التي ترتبط بشدة مع متحولات أخرى (R>0.8) وحذف أحد المتحولات (أو عدة متحولات حسب مدى المشكلة) قبل المتابعة. وكما أشرنا في الفقرة 8.6، فإن اختيار أحد المتحولين ليتم حذفه سيتم بشكل اعتباطي، وإيجاد الارتباط الخطي المتعدد في البيانات سيطرح أسئلة حول اختيار العناصر ضمن الاستبيان.

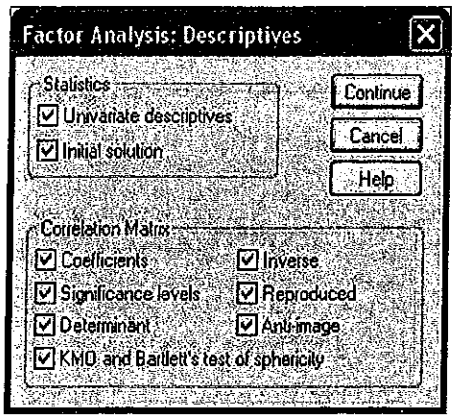

الشكل 6.15 الاحصائيات الوصفية في التحليل العاملي

يعطي الخيار KMO and Bartlett's test of Sphericity معيار KMO واختبار Bartlett. وفي عينة يبلغ حجمها 2571 لن تظهر أي مشكلة متعلقة بحجم العينة (انظر الفقرة 1.1.4.15). لقد تعرفنا على معيار KMO (في الفقرة 1.1.4.15) ورأينا المعايير المختلفة للكفاية. كما تعرفنا على اختبار Bartlett في الفصل 14، وهو يختبر فيما إذا كانت مصفوفة الارتباط للمجتمع تشبه المصفوفة الحيادية (أي أنه يختبر فيما إذا كانت العناصر غير القطرية قريبة من الصفر). إذا كانت مصفوفة الارتباط للمجتمع شبيهة بالمصفوفة الحيادية فهذا يعني أن كل متحول يرتبط بجميع المتحولات الأخرى بشكل ضعيف جداً (جميع معاملات الارتباط قريبة من الصفر). وإذا كانت المصفوفة حيادية تماماً فهذا يعني أن جميع المتحولات مستقلة بشكل كامل عن بعضها البعض (جميع معاملات الارتباط تساوي الصفر). وبما أننا نبحث عن تجمعات من المتحولات التي تقيس أشياء متماثلة فمن البديهي أن هذا الوضع إشكالي، فإذا لم تكن المتحولات مترابطة فلن تكون هناك تجمعات يمكن العثور عليها.

يعطي الخيار Reproduced مصفوفة ارتباط بناءً على النموذج (بدلاً من البيانات الفعلية). وتشير الفروق بين هذه المصفوفة ومصفوفة الارتباط المبنية على البيانات الفعلية إلى البواقي للنموذج. يعطي برنامج SPSS هذه البواقي في الجدول السفلي للمصفوفة المعاد إنتاجها، ونرغب أن يكون

هناك عدد صغير نسبياً من القيم التي تزيد على 0.05. ويعطي برنامج SPSS ملخصاً لعدد البواقي التي تزيد على 0.05، ولذلك يجب تحديد الخيار Reproduced للحصول على هذا الملخص. يعطي الخيار Anti-Image مصفوفة الصورة المعاكسة للتباينات المشتركة والارتباطات. تحوي هذه المصفوفات قياسات كفاية أخذ العينات لكل متحول على قطرها الرئيسي، والقيم المعاكسة (السلبية) للارتباط الجزئي/ التباينات المشتركة في العناصر غير القطرية. يجب أن تكون قيم جميع العناصر القطرية أكبر من 0.5 كحد أدنى وذلك إذا كانت العينة مناسبة من أجل زوج معين من المتحولات. وإذا كانت القيمة لأي زوج من المتحولات أدنى من هذه القيمة فيجب إهمال أحد المتحولين من عملية التحليل. أما العناصر غير القطرية فيجب أن تكون صغيرة جداً (قريبة من الصفر) في نموذج جيد. عند الانتهاء من تحديد الخيارات انقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

1.5.15 استخراج العوامل في برنامج SPSS

لفتح مربع الحوار الخاص باستخراج العوامل (الشكل 7.15) ننقر الزر ...Extraction في مربع الحوار الرئيسي. هناك عدة طرق لتنفيذ التحليل العاملي (انظر الفقرة 1.3.15)، ويعتمد مكان استخدام كل طريقة على عدة أشياء. وفي مثالنا الحالي سنستخدم تحليل المكونات الأساسية وهو ليس تحليلاً عاملياً بالمعنى الحرفي، ولكن الإجرائيتان تعطيان غالباً نتائج متماثلة (انظر الفقرة 3.3.15).

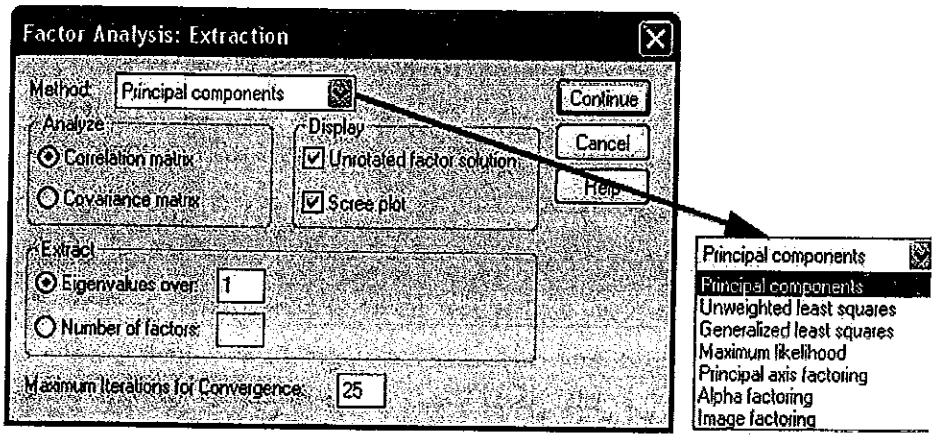

الشكل 7.15 مربع الحوار لاستخراج العوامل

يحوي القسم Analyze خيارين، أحدهما لتحليل مصفوفة الارتباط (Correlation matrix) والآخر لتحليل مصفوفة التباين المشترك (Covariance matrix). وهاتان المصفوفتان هما عملياً نسختان مختلفتان لشيء واحد، فمصفوفة الارتباط هي النسخة القياسية من مصفوفة التباين المشترك. والخيار الافتراضي لتحليل مصفوفة التباين المشترك هو خيار مفيد لأنه يأخذ الشكل القياسي للمصفوفة،

لذلك إذا تم قياس المتحولات باستخدام سلالم مختلفة فإن هذا لن يؤثر على التحليل. في هذا المثال، تم قياس جميع المتحولات باستخدام نفس السلم (مقياس مكون من 5 نقاط) ولكن غالباً ما نريد تحليل المتحولات التي تستخدم سلالم مختلفة. ويضمن تحليل مصفوفة الارتباط أن يتم أخذ الفروق بين سلالم القياس بعين الاعتبار. إضافة لذلك فقد تملك المتحولات المقاسة باستخدام نفس السلم تباينات مختلفة جداً وهذا يسبب مشاكل أيضاً في تحليل المكونات الأساسية. واستخدام مصفوفة الارتباط يلغي هذه المشاكل أيضاً. وهناك أسباب إحصائية لتفضيل تحليل مصفوفة التباين المشترك، وعادةً تختلف النتائج عن تلك التي نحصل عليها من تحليل مصفوفة الارتباط. على كل حال، يجب تحليل مصفوفة التباين المشترك في حالة واحدة وهي عندما تكون المتحولات متكافئة (قابلة للقياس بالوحدات نفسها).

ويحوي القسم Display خيارين أيضاً، أحدهما إظهار حل العوامل غير المدوّر Unrotated factor solution والآخر لإظهار مخطط المنحدر Scree plot. لقد تم وصف مخطط المنحدر سابقاً، وهو طريقة مفيدة لتحديد عدد العوامل التي يجب الاحتفاظ بها في التحليل. أما حل العوامل غير المدوّر فهو مفيد في تقييم تحسّن التفسير الناتج عن الدوران. إذا كان الحل المدوّر أفضل بقليل من الحل غير المدوّر فمن الممكن أننا استخدمنا طريقة تدوير غير مناسبة.

يحوي القسم Extract الخيارات المتعلقة باستخدام العوامل. ولدينا الخيار لاختيار العوامل التي تكون قيمها الخاصة أكبر من قيمة يحددها المستخدم، أو لتحديد عدد العوامل كرقم معين. والخيار الافتراضي هو اختيار العوامل التي تكون قيمها الخاصة أكبر من Eigenvalues over 1، وهذه القيمة هي التي يوصي بها Kaiser، ولكن يمكننا تغييرها إلى القيمة 0.7 التي يوصي بها Jolliffe أو إلى أي قيمة نريدها. ربما يكون من الأفضل تنفيذ تحليل أولي مع تحديد الخيار Eigenvalues over 1 واختيار مخطط المنحدر ومقارنة النتائج. إذا كان النظر إلى مخطط المنحدر والعوامل ذات القيم الخاصة أكبر من 1 يقودان إلى الاحتفاظ بنفس العدد من العوامل فإنه يمكننا الاستمرار بالتحليل. أما إذا أعطى المعياران نتائج مختلفة فعلينا التحقق من قيم التشاركية واعتماد المعيار الذي نراه مناسباً. إذا قررنا استخدام مخطط المنحدر فربما يتوجب علينا إعادة تنفيذ التحليل وتحديد عدد العوامل الواجب استخراجها. يمكن تحديد عدد العوامل الواجب استخراجها بتحديد الخيار Number of factors وكتابة العدد المطلوب في الحيز الخاص بذلك.

2.5.15 الدوران

رأينا سابقاً أنه يمكن تحسين تفسير العوامل باستخدام الدوران. يزيد الدوران قيمة التحميل لحدها الأعظمي لكل متحول على أحد الغوامل المستخرجة ويقلل التحميل على بقية العوامل إلى حده الأدنى. توضح هذه العملية ارتباط المتحولات بالعوامل. ويعمل الدوران من خلال تغيير القيم المطلقة للمتحولات مع الاحتفاظ بقيمها التفاضلية ثابتة. ننقر الزر ...Rotation لفتح مربع الحوار

المبين في الشكل 8.15. لقد ناقشنا الخيارات المختلفة للدوران في الفقرة 1.6.3.15، ولكننا نلخص ذلك بأن الاختيار الدقيق للدوران سيعتمد على اعتقاد بأن العوامل القاعدية ستكون مرتبطة أم لا. إذا كانت هناك أرضية نظرية للاعتقاد بأن العوامل مستقلة (غير مرتبطة) فعلينا اختيار أحد أنواع الدوران المتعامد (وننصح باستخدام Varimax). على كل حال، إذا كانت الأرضية النظرية تشير إلى أن العوامل قد تكون مترابطة فيجب عندئذ اختيار أحد أنواع الدوران المائل (Direct oblimin أوPromax). وفي هذا المثال اخترنا Varimax.

يحوي مربع الحوار خيارات لإظهار الحل المدوّر Rotated Solution ومخطط التحميل Loading plot. يتم إظهار الحل المدوّر بشكل افتراضي، وهو أساسي من أجل تفسير التحليل المدوّر النهائي. أما مخطط التحميل فيوفر إظهار بيانياً لكل متحول مع العوامل المستخرجة (الحد الأعظمي 3 عوامل، لأن برنامج SPSS غير قادر على إظهار مخططات رباعية أو خماسية الأبعاد). وهذا المخطط مشابه للمخطط المبين في الشكل 1.15، ويستخدم تحميل العامل لكل متحول من أجل كل عامل. بوجود عاملين يمكن تفسير هذه المخططات إلى حد ما، حيث نأمل بوجود مجموعة من المتحولات متجمعة قريباً من المحور الأفقي، ومجموعة مختلفة من المتحولات متجمعة قريباً من المحور الشاقولي. إذا كانت جميع المتحولات متجمعة بين المحورين، فإن الدوران كان غير ناجح تماماً في زيادة التحميل لمتحول ما على عامل وحيد إلى حده الأعظمي. وعند وجود ثلاثة عوامل تصبح هذه المخططات معقدة ومجهدة للنظر. ولكنها تبقى طريقة مفيدة لتحديد البنى القاعدية ضمن البيانات.

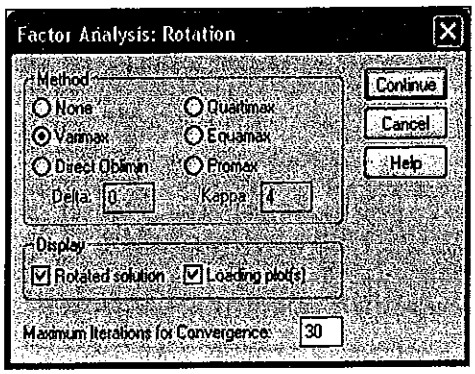

الشكل 8.15 مربع الحوار الخاص بدوران العوامل

الخيار الأخير هو تحديد العدد الأعظمي لمرات التكرار من أجل التقارب Maximum Iterations for Convergence. والقيمة الافتراضية في معظم الحالات هي 25 وتناسب برنامج SPSS لإيجاد حل لمجموعة بيانات معينة. على كل حال، إذا كانت لدينا مجموعة كبيرة من البيانات (كما هي الحال في هذا المثال) فإن البرنامج SPSS سيجد صعوبة في العثور على حل (وخاصة في حالة الدوران المائل)، ولذلك نغير القيمة إلى 30.

3.5.15 العلامات

نفتح مربع الحوار علامات العامل المبين في الشكل 9.15 وذلك بنقر الزر ...Scores في مربع الحوار الرئيسي. ويسمح هذا الخيار بحفظ علامات العامل (انظر الفقرة 3.2.15) لكل شخص في محرر البيانات. وينشئ برنامج SPSS عموداً جديداً لكل عامل مستخرج ويضع علامة العامل لكل شخص ضمن ذلك العمود. يمكن استخدام هذه العلامات من أجل عمليات التحليل اللاحقة، أو لتحديد مجموعات المشتركين الذين تكون علاماتهم مرتفعة على عامل معين. وهناك ثلاث طرق للحصول على هذه العلامات، وقد تم وضعها بالتفصيل في الفقرات 4.2.15 و1.4.2.15. إذا أردنا التأكد من أن علامات العامل غير مترابطة فعلينا اختيار طريقة Anderson-Rubin، وإذا كانت قيم الارتباط بين علامات العامل مقبولة فعلينا اختيار طريقة التراجع Regression.

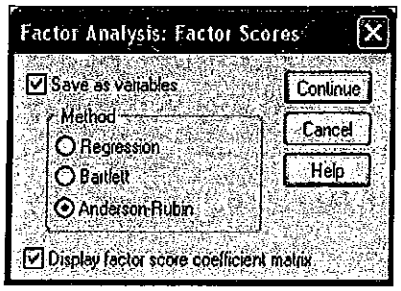

الشكل 9.15 مربع الحوار علامات العامل

وكخيار أخير يمكننا أن نطلب من برنامج SPSS أن يعطي مصفوفة معاملات علامات العامل. وهذه المصفوفة هي المصفوفة B التي تم شرحها في الفقرة 4.2.5. ويمكن أن تكون هذه المصفوفة مفيدة إذا أردنا إنشاء معادلات العامل مثل المعادلة (5.15)، لأنها تعطي قيم b لكل متحول.

4.5.15 الخيارات

يمكن الوصول إلى مجموعة الخيارات (الشكل 10.15) بنقر الزر ...Options في مربع الحوار الرئيسي. تعتبر البيانات المفقودة مشكلة في التحليل العاملي كما في بقية الإجرائيات، ويوفر برنامج SPSS خياراً لاستثناء الحالات أو تقدير قيمة لحالة ما. وبناءً على نصيحة Tabachnick & Fidell (2001) حول تصفية البيانات، علينا أن نأخذ بعين الاعتبار التوزيع للبيانات المفقودة. إذا كانت البيانات المفقودة موزعة بشكل غير طبيعي، أو كان حجم العينة بعد استثناء البيانات المفقودة صغيراً جداً فإن التقدير يصبح ضرورياً. يستخدم برنامج SPSS المتوسط كتقدير (Replace with mean). تخفّض هذه الإجرائيات الانحراف المعياري للمتحولات ويمكن أن تقود إلى نتائج مهمة مع العلم أنها يمكن أن تكون غير مهمة لو لم يتم ذلك. لهذا إذا كانت البيانات عشوائية علينا استثناؤها. يسمح برنامج SPSS باستثناء الحالات حسب القائمة (Exclude cases listwise) حيث يتم استثناء

المشترك الذي يحوي بيانات مفقودة، أو استثناء الحالات حسب الأزواج (Exclude cases pairwise) حيث يتم استثناء بيانات المشترك من الحسابات لأي بيانات مفقودة فقط. إذا استثنينا الحالات بشكل أزواج فإن التقديرات قد تكون مرتفعة، لذلك فمن الأفضل استثناء الحالات حسب القائمة ما لم يؤدي ذلك إلى فقد كبير للبيانات.

يتعلق الخياران الأخيران بكيفية إظهار المعاملات. يقوم برنامج SPSS بشكل افتراضي بعرض المتحولات حسب ترتيب إدخالها في محرر البيانات. وهذا الخيار هو الأنسب عادة. وعند تفسير العوامل فقد يكون من المفيد أحياناً عرض المتحولات حسب حجمها. بتحديد الخيار Sorted by size يقوم برنامج SPSS بترتيب المتحولات حسب قيم تحميل العامل. وينفذ ذلك عادةً بطريقة ذكية بحيث يتم عرض جميع المتحولات ذات التحميل المرتفع على نفس العامل سوية. الخيار الثاني هو إخفاء القيم المطلقة الأصغر من قيمة معينة (وعادة 0.1) Suppress absolute values less than. يضمن هذا الخيار عدم عرض قيم تحميل العامل الواقعة ضمن المجال ±0.1 في الخرج. ومرة أخرى، يفيد هذا الخيار في عملية التفسير. ربما تكون القيمة الافتراضية حساسة، لذلك ننصح أن تستخدم في التحليل الأولي القيمة 0.4 (بهدف التفسير) أو أي قيمة تعكس القيمة المتوقعة لتحميل عامل مهم حسب حجم العينة (انظر الفقرة 2.6.3.15). وهذا يجعل عملية التفسير أبسط. يمكننا إعادة تنفيذ التحليل ووضع قيمة أدنى قليلاً للتحقق من عدم نسيان أي شيء (مثل 0.39). ومن أجل هذا المثال فقد اخترنا القيمة 0.4.

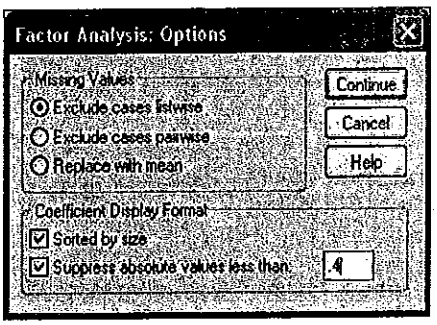

الشكل 10.15 مربع الحوار خيارات

6.15 تفسير الخرج من برنامج SPSS

بعد تحديد نفس الخيارات المبينة في الأشكال السابقة نقوم بتنفيذ التحليل العاملي مع الدوران المتعامد. وبعد الانتهاء، نحدد الخيار Direct oblimin (الشكل 8.15) ونكرر التحليل. يجب أن نحصل على خرجين متماثلين في السمات باستثناء أن أحدهما يستخدم دوراناً متعامداً والآخر دوراناً مائلاً.

وبهدف توفير المساحة في هذه الفقرة فقد استخدمنا خيارات برنامج SPSS الافتراضية بحيث تتم الإشارة لكل متحول باسمه المذكور في محرر البيانات (مثل Q12). يمكنك الحصول على الخرج

بحيث يستخدم برنامج SPSS تسمية المتحول (السؤال ذاته) بدلاً من اسمه. عند النظر إلى الخرج تذكر أن Q1 يمثل السؤال الأول، وQ17 يمثل السؤال السابع عشر. يمكنك العودة إلى الشكل 4.15 للمطابقة بين رقم السؤال واسم المتحول وتسميته.

1.6.15 التحليل التمهيدي

يتعلق الجزء الأول من الخرج بتصفية البيانات واختبار الفرضيات وكفاية أخذ العينات. وسنجد عدة جداول كبيرة (أو مصفوفات) تدلنا على أشياء ممتعة عن البيانات. إذا اخترنا الخيار Univariate descriptives في الشكل 6.15 فإن الجدول الأول من الخرج سيحوي الإحصائيات الوصفية لكل متحول (المتوسط، الانحراف المعياري، عدد الحالات). ولم يتم وضع هذا الجدول هنا، ولكن تفسيره لن يكون صعباً. يحوي الجدول أيضاً عدد الحالات المفقودة، ويفيد هذا الملخص في تحديد امتداد البيانات المفقودة.

يعرض (الخرج 1.15) المصفوفة R (مصفوفة الارتباط، وقد قمنا بحذف بعض الأعمدة توفيراً للمساحة وقمنا بإظهار الأعمدة الخمسة الأولى والأعمدة الخمسة الأخيرة فقط) التي نتجت عن استخدام الخيارين Coefficients و Significance levels في الشكل 6.15. يحوي النصف العلوي من الجدول معاملات Pearson للارتباط بين جميع أزواج الأسئلة في الاستبيان بينما يحوي النصف السفلي قيم الدلالة وحيدة الطرف لهذه المعاملات. ونحتاج في التحليل العاملي لأن تكون المتحولات مترابطة بشكل جيد ولكن ليس بشكل تام. كما يجب أن نحذف المتحولات التي لا ترتبط بمتحولات أخرى. لذلك يمكننا استخدام مصفوفة الارتباط للتحقق من نمط العلاقات. وأسهل طريقة لتنفيذ ذلك هي البحث بين قيم الدلالة عن المتحولات التي تكون معظم قيم الدلالة لها أكبر من 0.05. ثم البحث بين معاملات الارتباط عن القيم التي تكون أكبر من 0.9. إذا وجدنا مثل تلك القيم فيجب أن نكون حذرين من ظهور مشكلة بسبب الشذوذ في البيانات، ولذلك نتحقق من قيمة المحدد لمصفوفة الارتباط ونحذف أحد المتحولين أو كلا المتحولين اللذين يسببان المشكلة إذا كان ذلك ضرورياً. يتم عرض قيمة المحدد تحت الجدول مباشرة، ومن أجل المثال الحالي فإن قيمة المحدد هي 5.271E-04 (أي 0.0005271) وهي أكبر من القيمة الضرورية 0.00001 (انظر الفقرة 5.15). لذلك نكون على ثقة بأن الارتباط الخطي المتعدد غير موجود في هذه البيانات. والخلاصة هي أن جميع الأسئلة في الاستبيان ترتبط بشكل جيد مع بعضها البعض (ويعود بعض الفضل في ذلك إلى حجم العينة الكبير جداً) وليست هناك قيم كبيرة لمعاملات الارتباط، ولذلك لا داعي لحذف أي سؤال في هذه المرحلة.

Correlation Matrix[a]

		Q01	Q02	Q03	Q04	Q05	Q19	Q20	Q21	Q22	Q23
Correlation	Q01	1.000	-.099	-.337	.436	.402	-.189	.214	.329	-.104	-.004
	Q02	-.099	1.000	.318	-.112	-.119	.203	-.202	-.205	.231	.100
	Q03	-.337	.318	1.000	-.380	-.310	.342	-.325	-.417	.204	.150
	Q04	.436	-.112	-.380	1.000	.401	-.186	.243	.410	-.098	-.034
	Q05	.402	-.119	-.310	.401	1.000	-.165	.200	.335	-.133	-.042
	Q06	.217	-.074	-.227	.278	.257	-.167	.101	.272	-.165	-.069
	Q07	.305	-.159	-.382	.409	.339	-.269	.221	.483	-.168	-.070
	Q08	.331	-.050	-.259	.349	.269	-.159	.175	.296	-.079	-.050
	Q09	-.092	.315	.300	-.125	-.096	.249	-.159	-.136	.257	.171
	Q10	.214	-.084	-.193	.216	.258	-.127	.084	.193	-.131	-.062
	Q11	.357	-.144	-.351	.369	.298	-.200	.255	.346	-.162	-.086
	Q12	.345	-.195	-.410	.442	.347	-.267	.298	.441	-.167	-.046
	Q13	.355	-.143	-.318	.344	.302	-.227	.204	.374	-.195	-.053
	Q14	.338	-.165	-.371	.351	.315	-.254	.226	.399	-.170	-.048
	Q15	.246	-.165	-.312	.334	.261	-.210	.206	.300	-.168	-.062
	Q16	.499	-.168	-.419	.416	.395	-.267	.265	.421	-.156	-.082
	Q17	.371	-.087	-.327	.383	.310	-.163	.205	.363	-.126	-.092
	Q18	.347	-.164	-.375	.382	.322	-.257	.235	.430	-.160	-.080
	Q19	-.189	.203	.342	-.186	-.165	1.000	-.249	-.275	.234	.122
	Q20	.214	-.202	-.325	.243	.200	-.249	1.000	.468	-.100	-.035
	Q21	.329	-.205	-.417	.410	.335	-.275	.468	1.000	-.129	-.068
	Q22	-.104	.231	.204	-.098	-.133	.234	-.100	-.129	1.000	.230
	Q23	-.004	.100	.150	-.034	-.042	.122	-.035	-.068	.230	1.000
Sig. (1-tailed)	Q01		.000	.000	.000	.000	.000	.000	.000	.000	.410
	Q02	.000		.000	.000	.000	.000	.000	.000	.000	.000
	Q03	.000	.000		.000	.000	.000	.000	.000	.000	.000
	Q04	.000	.000	.000		.000	.000	.000	.000	.000	.043
	Q05	.000	.000	.000	.000		.000	.000	.000	.000	.017
	Q06	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q07	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q08	.000	.006	.000	.000	.000	.000	.000	.000	.000	.005
	Q09	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q10	.000	.000	.000	.000	.000	.000	.000	.000	.000	.001
	Q11	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q12	.000	.000	.000	.000	.000	.000	.000	.000	.000	.009
	Q13	.000	.000	.000	.000	.000	.000	.000	.000	.000	.004
	Q14	.000	.000	.000	.000	.000	.000	.000	.000	.000	.007
	Q15	.000	.000	.000	.000	.000	.000	.000	.000	.000	.001
	Q16	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q17	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q18	.000	.000	.000	.000	.000	.000	.000	.000	.000	.000
	Q19	.000	.000	.000	.000	.000		.000	.000	.000	.000
	Q20	.000	.000	.000	.000	.000	.000		.000	.000	.039
	Q21	.000	.000	.000	.000	.000	.000	.000		.000	.000
	Q22	.000	.000	.000	.000	.000	.000	.000	.000		.000
	Q23	.410	.000	.000	.043	.017	.000	.039	.000	.000	

a. Determinant = 5.271E-04

الخرج 1.15

يعرض (الخرج 2.15) مقلوب مصفوفة الارتباط (R^{-1}) الذي يستخدم في الحسابات المختلفة (بما فيها علامات العامل، انظر الفقرة 4.2.15). ونحصل على هذه المصفوفة بفضل الخيار Inverse في الشكل 6.15، وهي مفيدة فقط في التعرف بشكل أفضل على الحسابات في التحليل العاملي.

Inverse of Correlation Matrix

	Q01	Q02	Q03	Q04	Q05	Q19	Q20	Q21	Q22	Q23
Q01	1.595	-.028	.087	-.268	-.233	.017	-.024	.011	.002	-.078
Q02	-.028	1.232	-.224	-.057	.013	-.037	.076	.062	-.148	-.003
Q03	.087	-.224	1.661	.138	.057	-.175	.118	.122	-.009	-.103
Q04	-.268	-.057	.138	1.626	-.203	-.049	-.006	-.149	-.045	-.023
Q05	-.233	.013	.057	-.203	1.410	-.024	-.016	-.074	.045	-.006
Q06	.034	-.078	-.072	-.011	-.055	-.023	.080	.069	.058	.025
Q07	.039	.025	.127	-.152	-.072	.105	.077	-.386	.019	-.012
Q08	-.087	-.051	-.013	-.134	-.045	.074	.034	-.039	-.035	.003
Q09	-.023	-.242	-.208	.043	-.027	-.141	.050	-.047	-.158	-.110
Q10	-.017	-.015	-.023	.009	-.124	-.012	.056	.026	.023	.017
Q11	-.075	.061	.121	-.041	.000	-.010	-.140	-.009	.055	.015
Q12	-.011	.046	.147	-.259	-.091	.060	-.100	-.141	.028	-.038
Q13	-.145	-.011	-.055	.040	.007	.014	.028	-.061	.077	-.042
Q14	-.084	.033	.115	-.007	-.040	.063	.002	-.110	.041	-.034
Q15	.136	.050	.013	-.098	.021	.013	-.054	.058	.034	-.030
Q16	-.454	-.017	.142	-.063	-.155	.071	-.008	-.158	-.005	.033
Q17	-.084	-.045	.063	-.064	-.030	-.074	.025	-.077	.015	.080
Q18	-.041	.028	.070	-.044	.004	.047	-.004	-.136	-.037	.033
Q19	.017	-.037	-.175	-.049	-.024	1.264	.120	.048	-.141	-.045
Q20	-.024	.076	.118	-.006	-.016	.120	1.370	-.511	-.014	-.034
Q21	.011	.062	.122	-.149	-.074	.048	-.511	1.830	-.036	.018
Q22	.002	-.148	-.009	-.045	.045	-.141	-.014	-.036	1.200	-.202
Q23	-.078	-.003	-.103	-.023	-.006	-.045	-.034	.018	-.202	1.094

الخرج 2.15

يعرض (الخرج 3.15) بعض الأجزاء الهامة جداً من الخرج: معيار KMO، اختبار Bartlett للكروية ومصفوفات الارتباط والتباين المشترك للصورة المعاكسة. وتقدم هذه المصفوفات معلومات متماثلة (تذكّر العلاقة بين مصفوفات الارتباط والتباين المشترك) لذلك سنكتفي بدراسة مصفوفة الارتباط للصورة المعاكسة بالتفصيل لأنها أغنى بالمعلومات. ونحصل على هذه الجداول بفضل الخيارات KMO and Bartlett test of Sphericity وAnti-image المحددة في الشكل 6.15.

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy		.930
Bartlett's Test of Sphericity	Approx. Chi-Square	19334.492
	df	253
	Sig.	.000

Anti-image Matrices

		Q01	Q02	Q03	Q04	Q05	Q19	Q20	Q21	Q22	Q23
Anti-Image Correlation	Q01	.930[a]	-2.00E-02	5.320E-02	-.167	-.156	1.231E-02	-1.81E-02	6.436E-03	1.450E-03	-5.92E-02
	Q02	-2.00E-02	.875[a]	-.157	-4.05E-02	1.018E-02	-2.93E-02	5.877E-02	4.139E-02	-.121	-2.39E-03
	Q03	5.320E-02	-.157	.951[a]	8.381E-02	3.725E-02	-.121	7.790E-02	6.983E-02	-6.57E-03	-7.63E-02
	Q04	-.167	-4.05E-02	8.381E-02	.955[a]	-.134	-3.47E-02	-4.07E-03	-8.64E-02	-3.25E-02	-1.71E-02
	Q05	-.156	1.018E-02	3.725E-02	-.134	.960[a]	-1.77E-02	-1.14E-02	-4.59E-02	3.455E-02	-4.75E-03
	Q06	2.016E-02	-5.33E-02	-4.23E-02	-8.77E-03	-3.52E-02	-1.63E-02	5.144E-02	3.887E-02	3.994E-02	1.848E-02
	Q07	2.264E-02	1.846E-02	7.159E-02	-8.86E-02	-4.43E-02	8.802E-02	4.798E-02	-.208	1.278E-02	-8.07E-03
	Q08	-4.91E-02	-3.26E-02	-7.21E-03	-7.49E-02	-2.72E-02	4.696E-02	2.094E-02	-2.05E-02	-2.28E-02	2.202E-03
	Q09	-1.84E-02	-.193	-.142	2.966E-02	-1.98E-02	-.111	3.803E-02	-3.06E-02	-.128	-9.29E-02
	Q10	-1.22E-02	-1.21E-02	-1.62E-02	8.031E-03	-9.32E-02	-9.16E-03	4.272E-02	1.899E-02	1.887E-02	1.482E-02
	Q11	-4.07E-02	3.757E-02	8.429E-02	-2.22E-02	-3.27E-05	-5.81E-03	-8.18E-02	-4.58E-03	3.429E-02	9.600E-03
	Q12	-8.63E-03	3.129E-02	8.667E-02	-.154	-5.83E-02	4.030E-02	-8.47E-02	-7.93E-02	1.803E-02	-2.79E-02
	Q13	-8.51E-02	-7.86E-03	-3.16E-02	2.303E-02	4.238E-03	8.994E-03	1.768E-02	-3.33E-02	5.233E-02	-2.99E-02
	Q14	-3.98E-02	2.313E-02	8.946E-02	-4.26E-03	-2.63E-02	4.398E-02	1.124E-03	-6.37E-02	2.896E-02	-2.56E-02
	Q15	8.860E-02	3.660E-02	8.159E-03	-6.21E-02	1.413E-02	9.384E-03	-3.74E-02	3.483E-02	2.488E-02	-2.36E-02
	Q16	-.264	-1.14E-02	8.067E-02	-3.62E-02	-9.57E-02	4.865E-02	-5.30E-03	-8.54E-02	-3.26E-03	2.298E-02
	Q17	-4.74E-02	-2.87E-02	3.487E-02	-3.55E-02	-1.80E-02	-4.88E-02	1.547E-02	-4.06E-02	1.004E-02	5.457E-02
	Q18	-2.31E-02	1.825E-02	3.880E-02	-2.45E-02	2.488E-03	2.990E-02	-2.54E-03	-7.17E-02	-2.40E-02	2.257E-02
	Q19	1.231E-02	-2.93E-02	-.121	-3.47E-02	-1.77E-02	.941[a]	9.081E-02	3.145E-02	-.115	-3.84E-02
	Q20	-1.81E-02	5.877E-02	7.790E-02	-4.07E-03	-1.14E-02	9.081E-02	.889[a]	-.323	-1.12E-02	-2.81E-02
	Q21	6.436E-03	4.139E-02	6.983E-02	-8.64E-02	-4.59E-02	3.145E-02	-.323	.929[a]	-2.41E-02	1.275E-02
	Q22	1.450E-03	-.121	-6.57E-03	-3.25E-02	3.455E-02	-.115	-1.12E-02	-2.41E-02	.879[a]	-.176
	Q23	-5.92E-02	-2.39E-03	-7.63E-02	-1.71E-02	-4.75E-03	-3.84E-02	-2.81E-02	1.275E-02	-.176	.786[a]

a. Measures of Sampling Adequacy(MSA)

الخرج 3.15

وقد تعرفنا في الفقرة 1.1.4.15 على إحصائية KMO وتوصيات Kaiser التي تقول بأن القيم التي تكون أعلى من 0.9 هي رائعة. ومن أجل هذه البيانات فإن القيمة تبلغ 0.93، ولذلك نكون على ثقة بأن التحليل العاملي مناسب لهذه البيانات.

لقد أشرنا سابقاً إلى أنه يمكن حساب KMO لمتحولات منفصلة أو متعددة. تمثل العناصر القطرية لمصفوفة الارتباط للصورة المعاكسة قيم KMO للمتحولات المنفصلة (وقد تم إظهارها بخط غامق). وتجعل هذه القيم مصفوفة الارتباط للصورة المعاكسة من أهم الأجزاء في الخرج. ويتمتع فحص العناصر القطرية لمصفوفة الارتباط للصورة المعاكسة بنفس أهمية الإحصائية KMO الإجمالية، ويجب أن تكون القيم لجميع المتحولات أعلى من الحد الأدنى البالغ 0.5. ومن أجل المثال الحالي فإن جميع القيم أعلى من 0.5 وهذا رائع. لو وجدنا أن القيم لبعض المتحولات هي أدنى من 0.5 لكان علينا استثناء هذه المتحولات من التحليل (أو تنفيذ التحليل مع أو بدون المتحولات وتدوين الفرق). يؤثر حذف متحول ما على الإحصائية KMO، لذلك إذا حذفنا متحولاً ما ينبغي علينا إعادة فحص مصفوفة الارتباط للصورة المعاكسة. تمثل العناصر غير القطرية في مصفوفة الارتباط للصورة المعاكسة قيم الارتباط الجزئي بين المتحولات. ولكي يكون التحليل العاملي جيداً نريد أن تكون هذه القيم صغيرة جداً (وكلما كانت أصغر كان ذلك أفضل). لذلك نتحقق كخطوة أخيرة من أن

قيم العناصر غير القطرية هي صغيرة. تختبر إحصائية Bartlett فرضية العدم التي تنص على أن مصفوفة الارتباط الأصلية هي مصفوفة محايدة. ولكي يعمل التحليل العاملي يجب أن تكون هناك بعض العلاقات بين المتحولات، وإذا كانت المصفوفة R محايدة فإن جميع معاملات الارتباط هي معدومة. لذلك نريد أن يكون هذا الاختبار ذا دلالة (قيمة الدلالة أصغر من 0.05). يدلنا الاختبار ذو الدلالة على أن المصفوفة R ليست محايدة، وهناك بالتالي بعض العلاقات بين المتحولات التي نأمل تضمينها في التحليل. من أجل المثال الحالي، كان اختبار Bartlett عالي الدلالة (P<0.001)، ولذلك فإن التحليل العاملي مناسب لهذه البيانات.

أفكار مهمة التحليل التمهيدي

- ابحث في مصفوفة الارتباط عن المتحولات التي لا ترتبط بأي متحولات أخرى، أو التي ترتبط بشكل قوي جداً (r=0.9) مع متحولات أخرى. في التحليل العاملي، تحقق من أن قيمة المحدد لهذه المصفوفة أكبر من 0.00001 ، فإذا كان ذلك محققاً فإن الارتباط الخطي المتعدد لا يعتبر مشكلة في التحليل العاملي.
- ابحث في الجدول المسمى KMO and Bartlett Test عن قيمة الإحصائية KMO التي يجب أن تكون أكبر من القيمة 0.5 كحد أدنى، إذا لم تكن كذلك فعليك جمع المزيد من البيانات. يجب أن يكون اختبار Bartlett للكروية ذا دلالة (يجب أن تكون قيمة الدلالة .Sig أصغر من 0.05). يمكنك التحقق من قيمة الإحصائية KMO للمتحولات المنفصلة بالنظر إلى العناصر القطرية لمصفوفات الصورة المعاكسة. ومرة أخرى، يجب أن تكون هذه القيم أكبر من 0.5 (وهذا مفيد في التعرف على المتحولات الإشكالية إذا كانت قيمة KMO الإجمالية غير مرضية).

2.6.15 استخراج العوامل

يهدف الجزء الأول من عملية استخراج العوامل لتحديد المكونات الخطية ضمن مجموعة البيانات (الأشعة الخاصة) وذلك بحساب القيم الخاصة للمصفوفة R (انظر الفقرة 4.3.15). نعلم أن عدد الأشعة الخاصة للمصفوفة R يساوي عدد المتحولات، ولكن معظمها لن يكون مهماً. لتحديد أهمية شعاع معين ننظر إلى مطال القيمة الخاصة المرتبطة به، ثم نطبق المعايير لتحديد العوامل التي سنحتفظ بها أو إهمالها. يستخدم برنامج SPSS معيار Kaiser بشكل افتراضي للاحتفاظ بالعوامل التي تكون قيمها الخاصة أكبر من 1 (انظر الشكل 7.15).

يعرض الخرج 4.15 القيم الخاصة المرتبطة مع كل مكون خطي (عامل) قبل الاستخراج، وبعد الاستخراج، وبعد الدوران. لقد حدد برنامج SPSS 23 مكوناً خطياً ضمن مجموعة البيانات قبل الاستخراج (وهذا يساوي عدد المتحولات). تمثل القيم الخاصة المرتبطة بكل عامل التباين الذي يبرره ذلك المكون الخطي، كما يعرض برنامج SPSS القيمة الخاصة بشكل نسبة مئوية من التباين المبرر (وهكذا يفسر العامل الأول 31.696% من التباين الكلي). من الواضح أن العوامل الأولى تفسر مقداراً كبيراً من التباين الكلي (وخاصة العامل الأول) بينما تفسر بقية العوامل مقداراً صغيراً فقط.

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	7.290	31.696	31.696	7.290	31.696	31.696	3.730	16.219	16.219
2	1.739	7.560	39.256	1.739	7.560	39.256	3.340	14.523	30.742
3	1.317	5.725	44.981	1.317	5.725	44.981	2.653	11.099	41.841
4	1.227	5.336	50.317	1.227	5.336	50.317	1.950	8.476	50.317
5	.988	4.295	54.612						
6	.895	3.893	58.504						
7	.806	3.502	62.007						
8	.783	3.404	65.410						
9	.751	3.265	68.676						
10	.717	3.117	71.793						
11	.684	2.972	74.765						
12	.670	2.911	77.676						
13	.612	2.661	80.337						
14	.578	2.512	82.849						
15	.549	2.388	85.236						
16	.523	2.275	87.511						
17	.508	2.210	89.721						
18	.456	1.982	91.704						
19	.424	1.843	93.546						
20	.408	1.773	95.319						
21	.379	1.650	96.969						
22	.364	1.583	98.552						
23	.333	1.448	100.000						

Extraction Method: Principal Component Analysis.

الخرج 4.15

يستخرج برنامج SPSS بعد ذلك جميع العوامل التي تزيد قيمها الخاصة على 1، وعددها 4 فقط. ويعيد إظهار القيم الخاصة لهذه العوامل والنسب المئوية للتباين الذي تفسره. ويعرض هذه النتائج في العمود المسمى Extraction Sums of Squared Loadings، وهي نسخة عن النتائج الموجودة قبل الاستخراج. أما العمود الأخير من هذا الجدول والمسمى Rotation Sums of Squared Loadings فيعرض القيم الخاصة للعوامل بعد الدوران. قام الدوران بتحسين بنية العوامل نحو الأمثل، فتمت المساواة بين أهمية العوامل المستخرجة. قبل الدوران، كان العامل الأول يساهم بجزء كبير من التباين مقارنة بالعوامل الثلاثة الأخرى (31.696% مقارنة مع 7.560% و5.725% و5.336%)، وبعد الدوران أصبحت مساهمته 16.219% مقارنة مع 14.523% و11.099% و8.475%.

يعرض الخرج 5.15 جدول قيم التشاركية قبل الاستخراج وبعده. تذكر أن التشاركية هي نسبة التباين التشاركي ضمن متحول ما (انظر الفقرة 1.3.15). ويعمل تحليل المكونات الأساسية على الفرضية الأولية بأن كل التباين هو تباين تشاركي، ولذلك فإن قيم التشاركية قبل استخراج العوامل هي 1 (انظر العمود المسمى Initial). وفي الواقع، فقد تم افتراض أن كل التباين المرتبط بمتحول ما هو تباين تشاركي. بعد استخراج العوامل: تتكون لدينا فكرة أفضل عن مقدار التباين التشاركي الموجود فعلياً. فعلى سبيل المثال يمكننا القول أن 43.5% من التباين المرتبط بالسؤال

الأول (Q01) هو تباين تشاركي. هناك طريقة أخرى للنظر إلى قيم التشاركية وهي بدلالة نسبة التباين التي تفسرها العوامل القاعدية. قبل الاستخراج، كان عدد العوامل مساوياً لعدد المتحولات، لذلك يتم تفسير كل التباين بالعوامل وتكون جميع قيم التشاركية هي 1. وبعد الاستخراج، تم إهمال عدد من العوامل ولذلك ضاعت بعض المعلومات. ولا تستطيع العوامل المستبقاة تفسير كل التباين الموجود في البيانات ولكنها تستطيع تفسير جزء منه فقط. وهكذا فإن قيم التشاركية تمثل مقدار التباين في كل متحول والذي تستطيع العوامل المستبقاة تفسيره.

كما يعرض الخرج 5.15 مصفوفة المكونات قبل الدوران. تحوي هذه المصفوفة قيم التحميل على كل عامل. وبشكل افتراضي يعرض برنامج SPSS جميع قيم التحميل، ولكننا طلبنا عدم عرض القيم التي تكون أقل من 0.4 (انظر الشكل 10.15) ولذلك نرى فراغات في الجدول. وهذه المصفوفة ليست مهمة في التفسير، ولكن من المفيد ملاحظة أن قيم التحميل قبل الدوران لمعظم المتحولات هي كبيرة على العامل الأول (ولذلك يساهم العامل الأول بقسم كبير من التباين، انظر الخرج 4.15).

Communalities

	Initial	Extraction
Q01	1.000	.435
Q02	1.000	.414
Q03	1.000	.530
Q04	1.000	.469
Q05	1.000	.343
Q06	1.000	.654
Q07	1.000	.545
Q08	1.000	.739
Q09	1.000	.484
Q10	1.000	.335
Q11	1.000	.690
Q12	1.000	.513
Q13	1.000	.536
Q14	1.000	.488
Q15	1.000	.378
Q16	1.000	.487
Q17	1.000	.683
Q18	1.000	.597
Q19	1.000	.343
Q20	1.000	.484
Q21	1.000	.550
Q22	1.000	.464
Q23	1.000	.412

Extraction Method: Principal Component Analysis.

Component Matrix[a]

	Component			
	1	2	3	4
Q18	.701			
Q07	.685			
Q16	.679			
Q13	.673			
Q12	.669			
Q21	.658			
Q14	.656			
Q11	.652			-.400
Q17	.643			
Q04	.634			
Q03	-.629			
Q15	.593			
Q01	.586			
Q05	.556			
Q08	.549	.401		-.417
Q10	.437			
Q20	.436		-.404	
Q19	-.427			
Q09		.627		
Q02		.548		
Q22		.465		
Q06	.562		.571	
Q23				.507

Extraction Method: Principal Component Analysis.
a. 4 components extracted.

الخرج 5.15

عند هذه المرحلة، استخرج برنامج SPSS أربعة عوامل. وبما أن التحليل العاملي هو أداة استكشاف فيجب استخدامه لإرشاد الباحث في اتخاذ القرارات المختلفة، ويجب أن لا نترك للبرنامج اتخاذ القرارات. من القرارات الهامة تحديد عدد العوامل التي يجب استخراجها. وقد رأينا في الفقرة 5.3.15 مختلف المعايير لتقييم أهمية العوامل. باستخدام معيار Kaiser يتوجب علينا استخراج 4 عوامل وهذا ما قام به SPSS. ويكون هذا المعيار دقيقاً عندما يكون عدد المتحولات أقل من 30، وقيم التشاركية بعد استخراج العوامل أكبر من 0.7، أو عندما يزيد حجم العينة على 250 وتكون التشاركية الوسطى أكبر من 0.6. يعرض الخرج 5.15 قيم التشاركية، ونلاحظ أنها لا تتجاوز 0.7. يمكن إيجاد التشاركية الوسطى بجمع قيم التشاركية معاً وتقسيم الناتج على عددها (11.573/23=0.503). لذلك فإن معيار Kaiser غير دقيق. على كل حال، يجب أن نأخذ حجم العينة الهائل بعين الاعتبار، لأن الأبحاث في معيار Kaiser تعطي التوصيات من أجل عينات أصغر بكثير. وحسب معيار Jolliffe علينا الاحتفاظ بالعوامل التي تكون قيمها الخاصة أكبر من 0.7، وهذا يرفع عدد العوامل المستبقاة إلى 10 (انظر الخرج 4.15)، ولكن هناك عدد قليل من الباحثين ممن ينصحون بتفضيل هذا المعيار على معيار Kaiser. يمكننا أيضاً استخدام مخطط المنحدر الذي طلبنا من برنامج SPSS إظهاره باستخدام الخيار في الشكل 7.15. يعرض الخرج 6.15 مخطط المنحدر مع وجود سهم يدل على نقطة الانعطاف للمخطط. من الصعب تفسير هذا المخطط لأن المنحني يبدأ بالتلاشي بعد 3 عوامل فقط، ولكن هناك انحداراً آخر بعد 4 عوامل قبل الوصول إلى منطقة مستقرة. لذلك يمكننا تبرير الاحتفاظ بعاملين أو أربعة عوامل. ونظراً لكبر حجم العينة فربما يكون من الأفضل اعتماد معيار Kaiser، ولكن يمكنك إعادة تنفيذ التحليل وتحديد عدد العوامل باثنين فقط (انظر الشكل 7.15) ومقارنة النتائج.

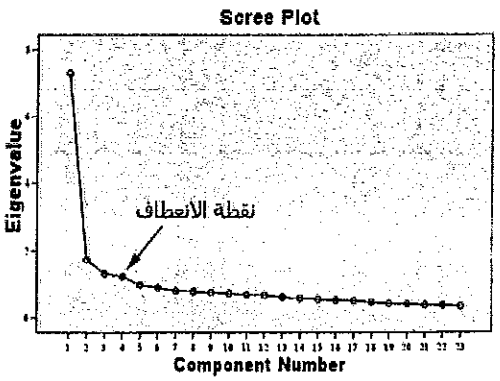

الخرج 6.15

يعرض الخرج 7.15 نسخة منقحة من مصفوفة الارتباط المعاد إنتاجها والتي تم طلبها باستخدام الخيار في الشكل 6.15. يحوي النصف العلوي من الجدول معاملات الارتباط بين جميع المتحولات

(الأسئلة) استناداً إلى نموذج العوامل. يحوي القطر الرئيسي للمصفوفة قيم التشاركية لكل متحول بعد الاستخراج (يمكنك مقارنة هذه القيم مع الخرج 5.15).

وتختلف قيم معاملات الارتباط في المصفوفة المعاد إنتاجها عن تلك الموجودة في المصفوفة R، لأنها تنتج عن النموذج بدلاً من البيانات المشاهدة. إذا كان النموذج ملائماً تماماً للبيانات فإن علينا أن نتوقع أن تكون معاملات الارتباط المعاد إنتاجها هي نفس معاملات الارتباط الأصلية. لذلك، ومن أجل تقييم ملاءمة النموذج يمكننا أن ننظر إلى الفروق بين معاملات الارتباط المشاهدة ومعاملات الارتباط المستندة إلى النموذج. فعلى سبيل المثال، إذا أخذنا الارتباط بين السؤالين 1 و 2 فإن الارتباط المستند إلى البيانات المشاهدة هو 0.099- (المأخوذ من الخرج 1.15)، بينما الارتباط المستند إلى النموذج يساوي 0.112- وهو أعلى بقليل. يمكننا حساب الفرق كما يلي:

$$\text{residual} = r_{\text{observed}} - r_{\textit{from model}}$$

$$\text{residual}_{Q,Q,} = (-0.099) - (-0.112)$$

$$= 0.013 = 1.3E-02$$

يجب ملاحظة أن النصف السفلي من الجدول (المسمى Residual) يحوي قيم الفروق بين معاملات الارتباط المشاهدة ومعاملات الارتباط المتوقعة من النموذج. فإذا كان النموذج جيداً فإن هذه القيم يجب أن تكون صغيرة، ونرغب أن تكون أصغر من 0.05. وبدلاً من البحث في هذه المصفوفة الكبيرة، يعطي برنامج SPSS ملخصاً في الحاشية السفلية للجدول يبين عدد البواقي التي تكون قيمتها المطلقة أكبر من 0.05. ومن أجل المثال الحالي، هناك 91 باقياً (35%) تزيد قيمها على 0.05. ولا توجد قواعد سريعة وصارمة حول نسبة البواقي التي يجب أن تكون قيمها أدنى من 0.05. ولكن إذا كانت 50% من البواقي أو أكثر تزيد قيمها على 0.05 فربما تكون هناك أسباب داعية للقلق.

أفكار مهمة استخراج العوامل

- لكي تقرر عدد العوامل الواجب استخراجها، عليك النظر إلى الجدول المسمى Communalities والعمود المسمى Extraction. إذا كانت جميع القيم أكبر من 0.7 وعدد المتحولات أقل من 30 فإن الخيار الافتراضي في برنامج SPSS لاستخراج العوامل مناسب جداً (معيار Kaiser للاحتفاظ بالعوامل التي تكون قيمها الخاصة أكبر من 1). وإذا كان حجم العينة يتجاوز 250 والتشاركية الوسطى أكبر من 0.6 فإن الخيار الافتراضي مناسب جداً. يمكن استخدام مخطط المنحدر عندما يتجاوز عدد المشتركين 200.
- انظر إلى الحاشية السفلية للجدول المسمى Reproduced Correlations وابحث عن النسبة المئوية للبواقي غير الفائضة التي تزيد قيمتها على 0.05 (non redundant residuals with absolute value>0.05)، يجب أن تكون هذه النسبة أقل من 50%، وكلما كانت النسبة أصغر كان ذلك أفضل.

Reproduced Correlations

		Q01	Q02	Q03	Q04	Q05	Q19	Q20	Q21	Q22	Q23
Reproduced Correlation	Q01	.435[b]	-.112	-.372	.447	.376	-.204	.342	.449	-2.54E-02	4.463E-02
	Q02	-.112	.414[b]	.380	-.134	-.122	.357	-.301	-.254	.333	.246
	Q03	-.372	.380	.530[b]	-.398	-.345	.403	-.440	-.468	.275	.158
	Q04	.447	-.134	-.399	.469[b]	.399	-.231	.353	.480	-4.97E-02	4.179E-02
	Q05	.376	-.122	-.345	.399	.343[b]	-.207	.292	.412	-6.03E-02	2.794E-02
	Q06	.218	-3.34E-02	-.200	.278	.273	-.147	-2.06E-02	.244	-.209	-8.17E-02
	Q07	.366	-.148	-.373	.419	.380	-.254	.219	.430	-.179	-3.72E-02
	Q08	.412	2.193E-03	-.270	.390	.312	-.104	.164	.282	-9.89E-02	-.136
	Q09	-4.25E-02	.430	.352	-7.31E-02	-7.97E-02	.363	-.218	-.191	.417	.323
	Q10	.172	-8.12E-02	-.181	.212	.205	-.137	5.763E-03	.188	-.197	-.110
	Q11	.423	-9.74E-02	-.357	.419	.348	-.198	.200	.342	-.269	-.202
	Q12	.402	-.219	-.440	.448	.397	-.302	.354	.503	-.136	1.064E-02
	Q13	.347	-.122	-.342	.395	.360	-.231	.183	.384	-.203	-7.88E-02
	Q14	.362	-.155	-.373	.411	.370	-.254	.241	.431	-.159	-2.16E-02
	Q15	.311	-.158	-.337	.343	.306	-.236	.175	.336	-.230	-.141
	Q16	.440	-.217	-.458	.488	.400	-.299	.373	.494	-.152	-4.93E-02
	Q17	.439	-4.80E-02	-.331	.434	.359	-.162	.196	.347	-.145	-.140
	Q18	.369	-.149	-.376	.424	.388	-.259	.215	.439	-.193	-3.16E-02
	Q19	-.204	.357	.403	-.231	-.207	.343[b]	-.308	-.324	.294	.196
	Q20	.342	-.301	-.440	.353	.292	-.308	.484[b]	.457	-6.76E-02	2.125E-02
	Q21	.449	-.254	-.468	.480	.412	-.324	.457	.650[b]	-9.59E-02	3.198E-02
	Q22	-2.54E-02	.333	.275	-4.97E-02	-6.03E-02	.294	-6.76E-02	-9.59E-02	.464[b]	.408
	Q23	4.463E-02	.246	.158	4.179E-02	2.794E-02	.196	2.125E-02	3.198E-02	.408	.412[b]
Residual[a]	Q01		1.291E-02	3.503E-02	-1.13E-02	2.694E-02	1.500E-02	-.128	-.120	-7.80E-02	-4.91E-02
	Q02	1.291E-02		-6.15E-02	2.166E-02	2.930E-03	-.153	9.905E-02	4.922E-02	-.102	-.147
	Q03	3.503E-02	-6.15E-02		1.893E-02	3.485E-02	-6.11E-02	.115	7.125E-02	-7.09E-02	-8.01E-03
	Q04	-1.13E-02	2.166E-02	1.893E-02		1.785E-03	4.510E-02	-.110	-6.98E-02	-4.87E-02	-7.56E-02
	Q05	2.694E-02	2.930E-03	3.485E-02	1.785E-03		4.136E-02	-9.24E-02	-7.76E-02	-7.22E-02	-6.96E-02
	Q06	-8.72E-04	-4.08E-02	-2.66E-02	1.197E-04	-1.55E-02	-2.01E-02	.122	2.875E-02	4.344E-02	1.304E-02
	Q07	-6.11E-02	-1.12E-02	-9.13E-03	-1.00E-02	-4.07E-02	-1.46E-02	1.628E-03	5.261E-02	1.040E-02	-3.31E-02
	Q08	-8.11E-02	-5.18E-02	1.106E-02	-4.07E-02	-4.36E-02	-5.59E-02	1.145E-02	1.407E-02	1.979E-02	8.616E-02
	Q09	-4.95E-02	-.115	-5.10E-02	-5.15E-02	-1.60E-02	-.114	5.965E-02	5.467E-02	-.161	-.152
	Q10	4.194E-02	-2.28E-02	-1.29E-02	3.359E-03	5.291E-02	9.852E-03	7.830E-02	4.732E-03	8.599E-02	4.844E-02
	Q11	-6.60E-02	-4.84E-02	8.099E-03	-6.05E-02	-6.01E-02	-2.07E-03	6.679E-02	4.747E-03	4.741E-02	.116
	Q12	-5.67E-02	2.376E-02	3.036E-02	-6.06E-03	-5.01E-02	3.574E-02	-5.83E-02	-6.21E-02	-3.10E-02	-5.71E-02
	Q13	7.634E-03	-2.12E-02	2.367E-02	-5.11E-02	-5.81E-02	4.134E-03	4.083E-02	-9.81E-03	7.402E-03	2.583E-02
	Q14	-2.39E-02	-9.23E-03	1.909E-03	-5.97E-02	-5.51E-02	-2.55E-04	-1.52E-02	-3.16E-02	-1.08E-02	-2.69E-02
	Q15	-6.49E-02	-7.26E-03	2.494E-02	-8.76E-03	-4.49E-02	2.655E-02	3.088E-02	-3.59E-02	6.223E-02	7.911E-02
	Q16	5.880E-02	4.966E-02	3.929E-02	-4.95E-02	-5.04E-03	3.159E-02	-.108	-7.30E-02	-3.59E-03	-3.22E-02
	Q17	-6.86E-02	-3.90E-02	3.147E-03	-5.18E-02	-4.89E-02	-1.23E-03	9.384E-03	1.801E-02	1.900E-02	4.880E-02
	Q18	-2.04E-02	-1.49E-02	9.988E-04	-4.24E-02	-6.56E-02	2.621E-03	1.985E-02	-8.86E-03	2.343E-02	-4.88E-02
	Q19	1.500E-02	-.153	-6.11E-02	4.510E-02	4.136E-02		5.985E-02	4.882E-02	-6.01E-02	-7.31E-02
	Q20	-.128	9.905E-02	.115	-.110	-9.24E-02	5.985E-02		1.034E-02	-3.19E-02	-5.59E-02
	Q21	-.120	4.922E-02	7.125E-02	-6.98E-02	-7.76E-02	4.882E-02	1.034E-02		-3.31E-02	-8.99E-02
	Q22	-7.80E-02	-.102	-7.09E-02	-4.87E-02	-7.22E-02	-6.01E-02	-3.19E-02	-3.31E-02		-.177
	Q23	-4.91E-02	-.147	-8.01E-03	-7.56E-02	-6.96E-02	-7.31E-02	-5.59E-02	-8.99E-02	-.177	

Extraction Method: Principal Component Analysis.

a. Residuals are computed between observed and reproduced correlations. There are 91 (35.0%) nonredundant residuals with absolute values greater than 0.05.

b. Reproduced communalities

الخرج 7.15

3.6.15 دوران العوامل

لقد قمنا في التحليل الأول باستخدام الدوران المتعامد. وطلبنا إعادة تنفيذ التحليل باستخدام الدوران المائل. وقد تم في هذه الفقرة تقديم النتائج لكلا التحليلين بهدف توضيح الفروق بين الخرجين. وتعتبر هذه المقارنة مفيدة لعرض الحالات التي يمكن فيها تفضيل نوع معين من الدوران.

1.1.6.15 الدوران المتعامد (Varimax)

يعرض الخرج 8.15 مصفوفة المكونات المدوّرة (وتدعى أيضاً مصفوفة العوامل المدوّرة في التحليل العاملي) وهي مصفوفة لقيم تحميل العوامل لكل متحول على كل عامل. تحوي هذه المصفوفة نفس

المعلومات التي تحويها مصفوفة المكونات في الخرج 5.15 باستثناء أن حسابها يتم بعد الدوران. وهناك عدة أمور يجب أخذها بعين الاعتبار حول تنسيق هذه المصفوفة. أولاً، لم يتم عرض قيم التحميل التي كانت أصغر من 0.4 وذلك لأننا طلبنا عدم إظهار هذه القيم باستخدام الخيار في الشكل 10.15. لو لم نحدد هذا الخيار أو أننا لم نغير قيمة المعيار إلى 0.4 فإن الخرج سيكون مختلفاً. ثانياً، يتم عرض المتحولات حسب ترتيب حجم قيم التحميل للعوامل. وبشكل افتراضي، يقوم برنامج SPSS بترتيب المتحولات كما هي في محرر البيانات، ولكننا طلبنا فرز المتحولات حسب الحجم وذلك باستخدام الخيار في الشكل 10.15. إذا لم يكن هذا الخيار محدداً فإن الخرج الذي تحصل عليه سيكون مختلفاً. أخيراً، ومن أجل جميع الأجزاء الباقية من الخرج فقد حذفنا تسميات المتحولات، أما من أجل هذه المصفوفة فقد سمحنا بعرض تسميات المتحولات للمساعدة في عملية التفسير.

Rotated Component Matrix[a]

	Component			
	1	2	3	4
I have little experience of computers	.800			
SPSS always crashes when I try to use it	.684			
I worry that I will cause irreparable damage because of my incompetenece with computers	.647			
All computers hate me	.638			
Computers have minds of their own and deliberately go wrong whenever I use them	.579			
Computers are useful only for playing games	.550			
Computers are out to get me	.459			
I can't sleep for thoughts of eigen vectors		.677		
I wake up under my duvet thinking that I am trapped under a normal distribtion		.661		
Standard deviations excite me		-.567		
People try to tell you that SPSS makes statistics easier to understand but it doesn't	.473	.523		
I dream that Pearson is attacking me with correlation coefficients		.516		
I weep openly at the mention of central tendency		.514		
Statiscs makes me cry		.496		
I don't understand statistics		.429		
I have never been good at mathematics			.833	
I slip into a coma whenever I see an equation			.747	
I did badly at mathematics at school			.747	
My friends are better at statistics than me				.648
My friends are better at SPSS than I am				.645
If I'm good at statistics my friends will think I'm a nerd				.586
My friends will think I'm stupid for not being able to cope with SPSS				.543
Everybody looks at me when I use SPSS				.428

Extraction Method: Principal Component Analysis.
Rotation Method: Varimax with Kaiser Normalization.
a. Rotation converged in 8 iterations.

Component Transformation Matrix

Component	1	2	3	4
1	.635	.585	.443	-.242
2	.137	-.167	.488	.846
3	.758	-.513	-.403	.008
4	.067	.605	-.635	.476

Extraction Method: Principal Component Analysis.
Rotation Method: Varimax with Kaiser Normalization.

الخرج 8.15

إن المنطق الأصلي وراء إخفاء قيم التحميل التي تكون أقل من 0.4 مستند على اقتراح Stevens (1992) بأن تكون نقطة القطع مناسبة لأغراض التفسير (تمثل القيم التي تكون أكبر من 0.4 قيماً واقعية). وهذا يعني أننا أخفينا عدة قيم مهمة دون شك (انظر الفقرة 2.6.3.15) ولكن الدلالة بحد ذاتها غير مهمة هنا.

لنقارن هذه المصفوفة مع الحل غير المدوّر (الخرج 5.15). قبل الدوران، كانت معظم المتحولات ذات تحميل مرتفع على العامل الأول. على كل حال، لقد وضّح تدوير بنية العوامل عدة أمور بشكل كبير، هناك أربعة عوامل والمتحولات محمّلة بشكل مرتفع جداً على العامل الأول فقط (باستثناء متحول أو سؤال واحد فقط). إن إخفاء قيم التحميل التي تكون أصغر من 0.4 وترتيب المتحولات حسب التحميل يجعل التفسير أكثر سهولة (لأن ذلك لن يتطلب البحث عن القيم الكبيرة في المصفوفة).

الخطوة التالية هي النظر إلى محتوى الأسئلة ذات التحميل على نفس العامل لمحاولة تحديد موضوعٍ مشترك بينها. إذا كان العامل الرياضي الناتج عن التحليل يمثل بنية من العالم الحقيقي فإن المواضيع المشتركة بين الأسئلة ذات التحميل المرتفع يمكن أن تساعدنا على تحديد هذه البنية. تبدو جميع الأسئلة ذات التحميل المرتفع على العامل الأول متعلقة باستخدام الحواسب أو برنامج SPSS، لذلك يمكننا تسمية هذا العامل بالخوف من الحواسب (fear of computers). وتبدو جميع الأسئلة ذات التحميل على العامل الثاني متعلقة بالمعالم المختلفة للإحصاء، لذلك يمكننا تسمية هذا العامل بالخوف من الإحصاء (fear of statistics). وتبدو الأسئلة الثلاثة ذات التحميل على العامل الثالث متعلقة بالرياضيات، لذلك يمكننا تسمية هذا العامل بالخوف من الرياضيات (fear of mathematics). وأخيراً، وتبدو الأسئلة ذات التحميل على العامل الرابع متعلقة ببعض مكونات التقييم الاجتماعي من قبل الأصدقاء، لذلك يمكننا تسمية هذا العامل بتقييم الند (peer evaluation). ويكشف هذا التحليل كما يبدو، عن أن الاستبيان الأولي مكون في الواقع من 4 مقاييس فرعية: الخوف من الحواسب، الخوف من الإحصاء، الخوف من الرياضيات، والخوف من التقييم السلبي من قِبَل الأنداد. وهنا لدينا احتمالان، الأول هو أن الاستبيان (SAQ) قد فشل في قياس ما هو مصمم لأجله (قلق SPSS بالتحديد) ولكنه تمكن من قياس بعض البنى المتعلقة به. والاحتمال الثاني هو أن هذه البنى الأربع هي مكونات جزئية لقلق SPSS. وعلى كل حال، لم يُشِر التحليل العاملي إلى الاحتمال الصحيح.

أما القسم الأخير من الخرج فهو مصفوفة تحويل العوامل (انظر الفقرة 6.3.15). توفر هذه المصفوفة معلومات عن الزاوية التي يجب تدوير العوامل بها للحصول على حل. إذا لم يكن الدوران ضرورياً فإن هذه المصفوفة ستكون محايدة. وإذا كان الدوران المتعامد هو الحل المناسب تماماً فإننا نتوقع أن تكون المصفوفة متناظرة (القيم فوق القطر الرئيسي مساوية للقيم تحت القطر الرئيسي). وفي الواقع، ليس من السهل تفسير المصفوفة، مع أن المصفوفات غير المتناظرة يمكن أن تؤخذ كسبب لمحاولة استخدام الدوران المائل. ومن المفضل للمحلل المبتدئ إهمال مصفوفة التحويل للعوامل.

2.1.6.15 الدوران المائل

عند تنفيذ الدوران المائل تنقسم مصفوفة العوامل إلى مصفوفتين: مصفوفة النمط (pattern matrix) ومصفوفة البنية (structure matrix) (انظر المربع 1.15). في الدوران المتعامد تكون هاتان المصفوفتان متطابقتين. تحوي مصفوفة النمط قيم التحميل للعوامل ويمكن مقارنتها بمصفوفة العوامل التي وضحناها في الدوران المتعامد. أما مصفوفة البنية فتأخذ العلاقة بين العوامل بعين الاعتبار (وفي الحقيقة هي جداء مصفوفة النمط بالمصفوفة التي تحوي معاملات الارتباط بين العوامل). ويفسر معظم الباحثين مصفوفة النمط لأنها أبسط عادة، ولكن هناك حالات يتم فيها إخفاء القيم في مصفوفة النمط بسبب العلاقات بين العوامل. لذلك تكون مصفوفة البنية بمثابة تحقق مضاعف.

في مصفوفة النمط لهذه البيانات (الخرج 9.15) يبدو ظهور نفس العوامل الأربعة (على الرغم من أن قيم التحميل لبعض المتحولات أصبح صغيراً جداً). ويبدو أن العامل الأول يمثل الخوف من الإحصاء ، والعامل الثاني يمثل الخوف من تقييم الأنداد، والعامل الثالث يمثل الخوف من الحواسب ، والعامل الرابع يمثل الخوف من الرياضيات.

Pattern Matrix[a]

	Component			
	1	2	3	4
I cant sleep for thoughts of eigen vectors	.701			
I wake up under my duvet thinking that I am trapped under a normal distribtion	.589			
Standard deviations excite me	-.502			
I dream that Pearson is attacking me with correlation coefficients	.407			
Statistcs makes me cry				
I weep openly at the mention of central tendency				
I don't understand statistics				
My friends are better at SPSS than I am		.643		
My friends are better at statistics than me		.630		
If I'm good at statistics my friends will think I'm a nerd		.610		
My friends will think I'm stupid for not being able to cope with SPSS		.518		
Everybody looks at me when I use SPSS				
I have little experience of computers			.885	
SPSS always crashes when I try to use it			.713	
All computers hate me			.653	
I worry that I will cause irreparable damage because of my incompetenece with computers			.650	
Computers have minds of their own and deliberately go wrong whenever I use them			.588	
Computers are useful only for playing games			.585	
People try to tell you that SPSS makes statistics easier to understand but it doesn't	.410		.462	
Computers are out to get me			.411	
I have never been good at mathematics				-.902
I did badly at mathematics at school				-.774
I slip into a coma whenever I see an equation				-.774

Extraction Method: Principal Component Analysis.
Rotation Method: Oblimin with Kaiser Normalization.
a. Rotation converged in 22 iterations.

الخرج 9.15

وتختلف مصفوفة البنية (الخرج 10.15) من حيث أن التباين التشاركي ليس مهملاً. وتصبح الصورة أكثر تعقيداً لأنه باستثناء العامل الثاني، فإن لعدة متحولات تحميلاً عالياً على أكثر من عامل واحد.

وقد حدث ذلك بسبب العلاقة بين العاملين الأول والثالث، وبين العاملين الثالث والرابع. يوضح هذا المثال سبب تفضيل مصفوفة النمط للأغراض التفسيرية: إنها تحوي معلومات عن المساهمة الوحيدة لمتحول ما على عامل ما.

Structure Matrix

	Component			
	1	2	3	4
I wake up under my duvet thinking that I am trapped under a normal distribtion	.695		.477	
I can't sleep for thoughts of eigen vectors	.683			
Standard deviations excite me	-.624	.413	-.407	
I weep openly at the mention of central tendency	.565		.516	-.491
I dream that Pearson is attacking me with correlation coefficients	.550		.487	-.484
Statiscs makes me cry	.523		.413	-.500
I don't understand statistics	.463		.453	
My friends are better at SPSS than I am		.659		
My friends are better at statistics than me		.658		
If I'm good at statistics my friends will think I'm a nerd		.583		
My friends will think I'm stupid for not being able to cope with SPSS		.554		
Everybody looks at me when I use SPSS	-.426	.455		
I have little experience of computers			.777	
SPSS always crashes when I try to use it	.401		.761	
All computers hate me			.723	
I worry that I will cause irreparable damage because of my incompetenece with computers			.723	-.429
Computers have minds of their own and deliberately go wrong whenever I use them	.423		.671	
People try to tell you that SPSS makes statistics easier to understand but it doesn't	.574		.606	
Computers are out to get me			.561	-.442
Computers are useful only for playing games			.556	
I have never been good at mathematics				-.856
I slip into a coma whenever I see an equation			.453	-.822
I did badly at mathematics at school			.451	-.819

Extraction Method: Principal Component Analysis.
Rotation Method: Oblimin with Kaiser Normalization.

الخرج 10.15

القسم الأخير من الخرج هو مصفوفة الترابط بين العوامل (الخرج 11.15)، وتحوي هذه المصفوفة معاملات الارتباط بين العوامل. وكما هو متوقع من مصفوفة البنية فإنه ليس للعامل الثاني علاقة مع أي من العوامل الأخرى (قيم معاملات الارتباط منخفضة)، ولكن العوامل الأخرى مترابطة فيما بينها لحد ما (وخاصة العاملين الأول والثالث، والعاملين الثالث والرابع). ويدلنا وجود هذه الارتباطات على إمكانية ارتباط البنى المقاسة. لو كانت البنى مستقلة لكان علينا أن نتوقع أن يوفر الدوران المائل حلاً مماثلاً للدوران المتعامد، ولكانت مصفوفة الارتباط للمكونات محايدة (جميع قيم معاملات الارتباط للعوامل تساوي 0). لذلك فإن هذه المصفوفة الأخيرة تعطينا مؤشراً على إمكانية افتراض الاستقلال بين العوامل، ومن أجل المثال الحالي يبدو أننا لا نستطيع افتراض الاستقلال. لذلك يجب علينا عدم الثقة بنتائج الدوران المتعامد، وتفضيل نتائج الدوران المائل.

على المستوى النظري، لا تدعو التبعية بين العوامل إلى القلق، فنحن نتوقع علاقة قوية نوعاً ما بين الخوف من الرياضيات والخوف من الإحصاء والخوف من الحواسب. وبشكل عام سيعاني الأشخاص ذوي المستوى المتدني في الرياضيات والتعامل مع التقنيات من مشاكل في الإحصاء. على كل حال، لا نتوقع أن ترتبط هذه البنى مع الخوف من تقييم الأنداد (لأن البنية الأخيرة ذات قاعدة

اجتماعية). ولذلك يرتبط هذا العامل بشكل ضعيف مع بقية العوامل، وهكذا نجد أن الأمور تسير على ما يرام على المستوى النظري.

Component Correlation Matrix

Component	1	2	3	4
1	1.000	-.153	.360	-.277
2	-.153	1.000	-.193	.093
3	.360	-.193	1.000	-.464
4	-.277	.093	-.464	1.000

Extraction Method: Principal Component Analysis.
Rotation Method: Oblimin with Kaiser Normalization.

الخرج 11.15

أفكار مهمة التفسير

- إذا قمت بتنفيذ دوران متعامد فانظر إلى الجدول المسمى Rotated Components Matrix. لاحظ المكون الذي يكون تحميل المتحول عليه هو الأعلى وذلك من أجل جميع المتحولات. ولاحظ المتحولات ذات التحميل العالي على كل عامل وذلك من أجل جميع العوامل (ونقصد بالتحميل العالي أن تكون قيمته المطلقة أكبر من 0.4). حاول إيجاد معنى لما تمثله العوامل وذلك بالبحث عن المواضيع المشتركة بين المتحولات ذات التحميل على العامل.
- إذا قمت بتنفيذ دوران مائل فانظر إلى الجدول المسمى Pattern Matrix. لاحظ المكون الذي يكون تحميل المتحول عليه هو الأعلى وذلك من أجل جميع المتحولات. ولاحظ المتحولات ذات التحميل العالي على كل عامل وذلك من أجل جميع العوامل (ونقصد بالتحميل العالي أن تكون قيمته المطلقة أكبر من 0.4). تحقق من النتيجة التي حصلت عليها بتنفيذ نفس المهام على مصفوفة البنية (الجدول المسمى Structure Matrix). حاول إيجاد معنى لما تمثله العوامل وذلك بالبحث عن المواضيع المشتركة بين المتحولات ذات التحميل على العامل.

4.6.15 علامات العامل

بعد الوصول إلى حل مناسب وتدوير الحل يمكننا أن ننظر إلى علامات العامل. يعرض الخرج 12.15 مصفوفة علامات المكونات B (انظر الفقرة 4.2.15) التي يتم منها حساب علامات العامل ومصفوفة التباين المشترك لعلامات العامل. إن مصفوفة علامات المكونات ليست مفيدة بحد ذاتها، ولكنها يمكن أن تكون مفيدة في فهم طريقة حساب علامات العامل. أما مصفوفة التباين المشترك للعلامات فهي مفيدة. تدلنا هذه المصفوفة على العلاقة بين علامات العوامل (إنها مصفوفة ارتباط غير قياسية). إذا كانت علامات العوامل غير مرتبطة فإن هذه المصفوفة يجب أن تكون محايدة. ومن أجل المثال الحالي فإن جميع قيم التباينات المشتركة هي 0 مما يدل على أن العلامات الناتجة غير مرتبطة.

Component Score Coefficient Matrix

	Component			
	1	2	3	4
Q01	-.053	.173	.089	.110
Q02	.102	-.129	.086	.282
Q03	.087	-.195	.013	.137
Q04	-.011	.170	.045	.107
Q05	.021	.131	.014	.083
Q06	.383	-.211	-.088	.014
Q07	.213	.004	-.078	.038
Q08	-.129	-.074	.460	.013
Q09	.025	-.029	.108	.354
Q10	.244	-.161	-.021	-.036
Q11	-.066	-.087	.379	-.059
Q12	.097	.161	-.116	.051
Q13	.224	-.065	-.019	.013
Q14	.180	.040	-.084	.043
Q15	.114	-.055	.061	-.058
Q16	-.015	.146	.046	.014
Q17	-.057	-.067	.372	.005
Q18	.242	-.001	-.104	.043
Q19	.048	-.115	.061	.199
Q20	-.195	.359	-.061	-.002
Q21	-.039	.270	-.064	.059
Q22	-.036	.162	-.040	.302
Q23	.032	.211	-.162	.379

Extraction Method: Principal Component Analysis.
Rotation Method: Varimax with Kaiser Normalization.
Component Scores.

الخرج 12.15

في التحليل الأصلي، طلبنا أن يتم حساب العلامات باعتماد طريقة Anderson-Rubin. وتجد هذه العلامات في محرر البيانات. لذلك سيكون لدينا 4 أعمدة جديدة من البيانات (عمود لكل عامل) تحمل التسميات FAC1_1 وFAC2_1 وFAC3_1 وFAC4_1 على الترتيب. إذا طلبت علامات العوامل في الدوران المائل فستظهر هذه العلامات في محرر البيانات ضمن 4 أعمدة جديدة أخرى تحمل التسميات FAC1_2 وFAC2_2 وFAC3_2 وFAC4_2. يمكن عرض هذه العلامات في نافذة العارض باستخدام أمر القائمة Analyze ⇒ Reports ⇒ Case Summaries... (انظر الفقرة 6.8.5).

ونظراً لوجود أكثر من 1500 حالة فإننا قد نطلب أن يقتصر إظهار الخرج على 10 أو 20 حالة فقط. يعرض الخرج 13.15 علامات العامل للمشتركين العشرة الأوائل. ومن الواضح أن المشترك رقم 9 يحقق أعلى العلامات من أجل العوامل الأربعة، وبالتالي فإن هذا الشخص قلق جداً من الإحصاء والرياضيات والحواسب، ولكنه أقل خوفاً من تقييم الند (العامل الرابع). يمكن استخدام علامات العامل بهذه الطريقة لتقييم الخوف النسبي لشخص ما مقارنة مع شخص آخر، أو يمكننا جمع العلامات معاً للحصول على علامة واحدة لكل مشترك (ونفترض أنها تمثل قلق SPSS ككل). كما يمكننا استخدام علامات العامل في التراجع عندما ترتبط مجموعات من المتحولات التنبؤية بشكل قوي بحيث يكون هناك ارتباط خطي متعدد.

Case Summaries[a]

	Case Number	FAC1_1	FAC2_1	FAC3_1	FAC4_1
1	1	.10587	-.92816	-1.82760	-.45953
2	2	-.58279	-.18932	-.04137	.29332
3	3	-.54761	.02953	.19918	-.97142
4	4	.74661	.72268	-.68654	-.18547
5	5	.25169	-.51489	-.63354	.68301
6	6	1.91614	-.27356	-.68201	-.52709
7	7	-.26051	-1.40947	-.00431	.91008
8	8	-.28572	-.91761	-.08947	1.03746
9	9	1.71750	1.15102	3.15659	.81082
10	10	-.69151	-.73318	.18376	1.49541

a. Limited to first 10 cases.

الخرج 13.15

5.6.15 الخلاصة

لقد كشفت التحاليل عن 4 مقاييس قاعدية في الاستبيان والتي يمكن (وربما لا يمكن) أن تكون متعلقة بالمكونات الجزئية الحقيقية لقلق SPSS. ويبدو أن الدوران المائل للحل هو الأفضل نظراً لوجود العلاقات المتبادلة بين العوامل. إن استخدام التحليل العاملي هو استكشافي بحت، ويجب استخدامه لتوجيه الفرضيات المستقبلية وعدم اعتماده لاتخاذ القرارات بخصوص النتائج التي ترغب بالحصول عليها. المشكلة التالية تتعلق بوثوقية المقياس (وفي مثالنا الحالي: الاستبيان).

7.15 تحليل الوثوقية

1.7.15 قياسات الوثوقية

إذا استخدمت التحليل العاملي لتقييم صلاحية استبيان ما، فمن المفيد التحقق من وثوقية هذا المقياس. وتعني الوثوقية (Reliability) أنه يجب على المقياس أن يعكس بصورة ثابتة البنية التي يقيسها. ويمكن النظر إلى ذلك بأنه عند تَساوي بقية الأمور، فإن الشخص يجب أن يحصل على

نفس العلامة في الاستبيان وذلك إذا قام بإكماله في زمنين مختلفين، ويدعى ذلك بوثوقية الاختبار-إعادة الاختبار (Test-Retest reliability). لذلك إذا حصل شخص ما على علامة مرتفعة في الاستبيان (SAQ) فإنه يجب أن يحصل على نفس العلامة إذا تم اختباره بعد شهر من الاختبار الأول (بشرط أن لا يخضع لأي علاج للخوف من الإحصاء خلال هذا الشهر). هناك طريقة أخرى للنظر إلى الوثوقية وهي أنه إذا أخذنا شخصين متماثلين من حيث البنية التي يتم قياسها فإننا سنحصل على نفس العلامة. لذلك إذا أخذنا شخصين يخافان من الإحصاء بنفس الدرجة فيجب أن يحصلا على درجتين متقاربتين نوعاً ما في الاستبيان. وإذا أخذنا شخصين يحبان الإحصاء فيجب أن تكون علامة أحدهما (وهي متدنية) مماثلة لعلامة الشخص الآخر. أما إذا أخذنا شخصين أحدهما يحب الإحصاء والآخر يصاب بالهلع عند ذكره، وحصلا على نفس العلامة في الاستبيان، فإن هذا الاستبيان لن يكون مقياساً دقيقاً للقلق أو الخوف من الإحصاء. وبالمصطلحات الإحصائية فإن الطريقة المألوفة للنظر إلى الوثوقية مبنية على فكرة أن العناصر المنفردة (أو مجموعات العناصر) يجب أن تعطي نتائج متوافقة مع الاستبيان الكلي. لذلك إذا أخذنا شخصاً يخاف من الإحصاء فإن علامته ستكون مرتفعة في الاستبيان، وإذا كان الاستبيان موثوقاً فإنه إذا أخذنا بعض العناصر بشكل عشوائي من الاستبيان فإن علامة الشخص في هذه العناصر يجب أن تكون مرتفعة أيضاً.

وأبسط طريقة لتنفيذ ذلك عملياً هي استخدام وثوقية النصف المشطور (Split-half reliability). تقسم هذه الطريقة مجموعة البيانات بشكل عشوائي إلى نصفين. يتم بعد ذلك حساب علامة لكل مشترك استناداً لكل نصف من المقياس. إذا كان المقياس موثوقاً جداً فإن علامة شخص ما في أحد نصفي المقياس يجب أن تكون مساوية (أو مماثلة) لعلامته في النصف الآخر، لذلك فإن علامات المشتركين من كلا النصفين للاستبيان يجب أن تكون مرتبطة بشكل تام (أو بشكل مرتفع جداً). والارتباط بين النصفين هو الإحصائية المحسوبة بطريقة النصف المشطور، حيث تدل القيم الكبيرة للارتباط على الوثوقية. والمشكلة مع هذه الطريقة هي وجود عدة طرق لتقسيم مجموعة من البيانات إلى نصفين، ولذلك يمكن أن تكون النتائج هي نتاج الطريقة التي تم بها تقسيم البيانات. للتغلب على هذه المشكلة، اقترح Cronbach (1951) مقياساً مكافئاً لتقسيم البيانات إلى قسمين بكل الطرق الممكنة ثم حساب معامل الارتباط لكل تقسيم. ويكون متوسط هذه القيم مكافئاً لقيمة ألفا α، وهي المقياس الأكثر شيوعاً لسلم الوثوقية:

$$\alpha = \frac{N^2 \cdot \overline{Cov}}{\sum s^2_{item} + \sum Cov_{item}} \qquad (6.15)$$

تبدو العلاقة معقدة، ولكنها ليست كذلك. إن أول ما يجب ملاحظته هو أنه من أجل كل عنصر في المقياس فإننا نقوم بحساب التباين ضمن العنصر والتباين المشترك بين عنصر معين وأي عنصر آخر على المقياس. وبطريقة أخرى، نقوم بإنشاء مصفوفة التباين-التباين المشترك لجميع العناصر. وفي هذه المصفوفة، تمثل العناصر القطرية التباين ضمن كل عنصر بينما تمثل العنصر غير القطرية التباين المشترك بين كل زوج من العناصر. يمثل بسط المعادلة مربع عدد العناصر مضروباً بمتوسط التباين

المشترك بين العناصر، أما المقام فهو مجموع جميع التباينات للعنصر والتباينات المشتركة للعنصر (أي مجموع جميع العناصر في مصفوفة التباين–التباين المشترك).

وهناك نسخة قياسية من هذا المعامل أيضاً، وهي تستخدم بشكل أساسي نفس المعادلة باستثناء أنه يتم استخدام معاملات الارتباط بدلاً من التباينات المشتركة، ويكون مقام المعادلة هو مجموع العناصر في مصفوفة الارتباط للعناصر. تكون قيمة α العادية مناسبة عندما يتم جمع العناصر على مقياس ما للحصول على علامة وحيدة لذلك المقياس (بينما لا تكون قيمة α القياسية مناسبة في هذه الحالة). أما قيمة α القياسية فهي مفيدة عندما يتم جعل العناصر على مقياس ما قياسية قبل أن يتم جمعها.

2.7.15 تفسير Cronbach's α

غالباً ما نجد في الكتب والمقالات العلمية أن القيم 0.8÷0.7 هي قيم مقبولة من أجل Cronbach's α، وتدل القيم الأدنى على مقياس غير موثوق. وقد لاحظ Kline (1999) أنه على الرغم من أن القيمة المقبولة 0.8 هي مناسبة للاختبارات الإدراكية مثل اختبارات الذكاء، فإن القيمة 0.7 هي مناسبة لاختبارات القابلية والقدرة. أما من أجل البنى النفسية فإن قيماً أدنى من 0.7 يمكن أن تكون مقبولة وذلك بسبب تنوع البنى التي يتم قياسها.

على كل حال، لاحظ Cortina (1993) أنه من الواجب إتباع الإرشادات العامة بحذر لأن قيمة α تعتمد على عدد العناصر في المقياس. نلاحظ أن بسط المعادلة يتضمن مربع عدد العناصر. ولذلك كلما ازداد عدد العناصر في المقياس فإن α تزداد. ولهذا فمن الممكن الحصول على قيم كبيرة لأن عدد العناصر كبير وليس لأن المقياس موثوق. فعلى سبيل المثال، يقدم Cortina بيانات من مقياسين مختلفين فيهما α=0.8. يحوي المقياس الأول 3 عناصر، ومتوسط الارتباط بين العناصر هو 0.57، بينما يضم المقياس الثاني 10 عناصر مع قيمة متوسطة للارتباط بين هذه العناصر تبلغ 0.28. ومن الواضح أن التوافق الداخلي لهذين المقياسين مختلف بشكل كبير جداً، ومع ذلك فإن قيمة Cronbach's α تدل على نفس المستوى من الوثوقية.

هناك تفسير شائع آخر لقيمة α وهي أنها تقيس وحدانية البعد (Unidimensionality)، أو المدى الذي يقيس إليه المقياس عاملاً قاعدياً واحداً أو بنية واحدة. وينبع هذا التفسير من حقيقة أنه عند وجود عامل واحد في البيانات فإن α تقيس قوة ذلك العامل. وقد بيّن Grayson (2004) أن مجموعات البيانات التي لها نفس قيمة α يمكن أن تكون مختلفة البنية بشكل كبير. وأظهر أنه يمكن الوصول إلى قيمة α=0.8 في مقياس ذي بعد قاعدي واحد، مع عاملين مرتبطين بشكل متوسط وعاملين غير مرتبطين. كما بيّن Cortina (1993) أنه بوجود أكثر من 12 عنصر، ومعاملات ارتباط مرتفعة نوعاً ما (r>0.5)، فإن قيم α يمكن أن تصل إلى المجال بين 0.65 و 0.84. وتوضح هذه النتائج بشكل مثير أنه لا يمكن استخدام α كمقياس لوحدانية البعد. وقد اقترح Cronbach أنه

عند وجود عدة عوامل فإنه يجب تطبيق المعادلة بشكل منفصل على العناصر المتعلقة بالعوامل المختلفة. أي أنه إذا كان للاستبيان مقاييس جزئية فإنه يجب تطبيق α بشكل منفصل على كل من هذه المقاييس الجزئية.

التحذير الأخير هو حول العناصر ذات الصياغة العكسية (Reverse phrasing). فعلى سبيل المثال يحوي الاستبيان (SAQ) الذي تعاملنا معه في هذا الفصل عنصراً (السؤال الثالث) تمت صياغته بطريقة عكسية لصياغة بقية العناصر. العنصر هو "الانحرافات المعيارية تثيرني (Standard deviations excite me)". قارن هذا العنصر مع أي عنصر آخر ولاحظ أنه يتطلب الإجابة العكسية. فعلى سبيل المثال، العنصر الأول هو "علم الإحصاء يبكيني (Statistics make me cry)". فإذا كان الشخص لا يحب علم الإحصاء فإنه يوافق تماماً على هذه العبارة وسيأخذ العلامة 5 على مقياس الاستبيان. أما من أجل العنصر الثالث فإذا كان الشخص يكره علم الإحصاء فمن غير المرجح أن تثيره الانحرافات المعيارية لذلك فهو غير موافق أبداً على هذه العبارة وسيحصل على العلامة 1 على المقياس. وهذه العناصر ذات الصياغة العكسية مهمة لتقليل انحياز الإجابات، وعلى المشتركين قراءة العناصر في حال صياغتها بطريقة أخرى. وفي التحليل العاملي لا تعتبر الصياغة العكسية مشكلة، فكل ما يحدث هو الحصول على قيمة سلبية لتحميل العامل من أجل العناصر المصاغة عكسياً (ويمكنك التحقق من ذلك بالنظر إلى الخرج 8.15 لرؤية التحميل السلبي للعامل من أجل العنصر الثالث). على كل حال، لهذه العناصر العكسية دور في تحليل الوثوقية. ولمعرفة السبب علينا العودة لمعادلة Cronbach's α. ففي تلك المعادلة يحوي البسط متوسط التباين المشترك بين العناصر. فإذا كان العنصر مصاغاً بشكل عكسي فإن علاقته عكسية مع بقية العناصر، ولذلك فإن التباين المشترك بين هذا العنصر والعناصر الأخرى سيكون سالباً. وبما أن متوسط التباين المشترك هو مجموع التباينات المشتركة مقسوماً على عدد العناصر فإن وجود القيم السالبة سيقلل مجموع التباينات المشتركة وبالتالي يقلل قيمة α (لأن بسط المعادلة يصبح أصغر). وفي الحالات القصوى يصبح مطال القيم السالبة أكبر من مطال القيم الموجبة. وليس لقيمة α السالبة معنى، ولكن إن حدث ذلك فعلينا التحقق لمعرفة العناصر المصاغة عكسياً ضمن الاستبيان (المقياس).

إذا كان لدينا عناصر مصاغة عكسياً فعلينا عكس الطريقة التي يتم بها منح العلامة قبل تنفيذ تحليل الوثوقية. وتتم هذه العملية بسهولة. لنأخذ بيانات SAQ، يتم حالياً منح العلامات للعنصر حسب الترتيب التالي: 1=غير موافق أبداً، و2=غير موافق، و3=لا أعرف، و4=موافق، و5=موافق تماماً. وهذا السلم مناسب للعناصر التي تمت صياغتها بحيث تعبر الموافقة عن الخوف من الإحصاء، ولكن من أجل العنصر الثالث (الانحرافات المعيارية تثيرني) فإن عدم الموافقة تعبر عن الخوف من الإحصاء. ولتحقيق انعكاس ذلك رقمياً ينبغي علينا عكس المقياس بحيث يتم منح العلامات حسب الترتيب التالي: 1=موافق تماماً، و2=موافق، و3=لا أعرف، و4=غير موافق، و5=غير موافق أبداً. وبهذه الطريقة يحصل الشخص القلق على 5 علامات من أجل هذا العنصر (لأنه لا يوافق أبداً على العبارة).

ولتنفيذ عكس المقياس نأخذ القيمة العظمى على مقياس الإجابة (وهي 5 في هذا المثال) ونضيف إليها 1 ثم نطرح علامة العنصر الثالث لكل شخص من تلك القيمة. فإذا كانت علامة شخص ما هي 5 فإن علامته الجديدة تصبح 1=5-6، وإذا كانت علامته 3 فإن علامته الجديدة تصبح 3=3-6. وتأخذ هذه العملية وقتاً طويلاً، لذلك يمكننا أن نطلب من برنامج SPSS القيام بذلك عن طريق أمر القائمة Transform ⇒ Compute... (انظر الفقرة 4.3.3). وكل ما علينا فعله هو إدخال اسم المتحول الذي نريد تعديله (Q03) في الحيز المسمى Target Variable (انظر الشكل 11.15). يمكنك استخدام اسم مختلف للمتحول، سيقوم برنامج SPSS عندئذ بإنشاء متحول جديد، وعليك استخدام المتحول الجديد في تحليل الوثوقية. ننتقل بعد ذلك إلى حيز إدخال الصيغة الرياضية Numerical Expression ونكتب الصيغة التي نريد استخدامها لحساب المتحول الجديد. في هذا المثال علينا أن نطرح العلامة الأصلية للعنصر الثالث لكل شخص من العدد 6. لذلك نكتب ببساطة 6-Q03. إذا استخدمت نفس الاسم للمتحول فانقر الزر OK حيث تحصل على مربع حوار للتأكد من استبدال المتحول الموجود، أنقر الزر OK إذا كنت موافقاً، حيث تحل القيم الجديدة محل القيم القديمة. يوضح الشكل 11.15 هذه العملية.

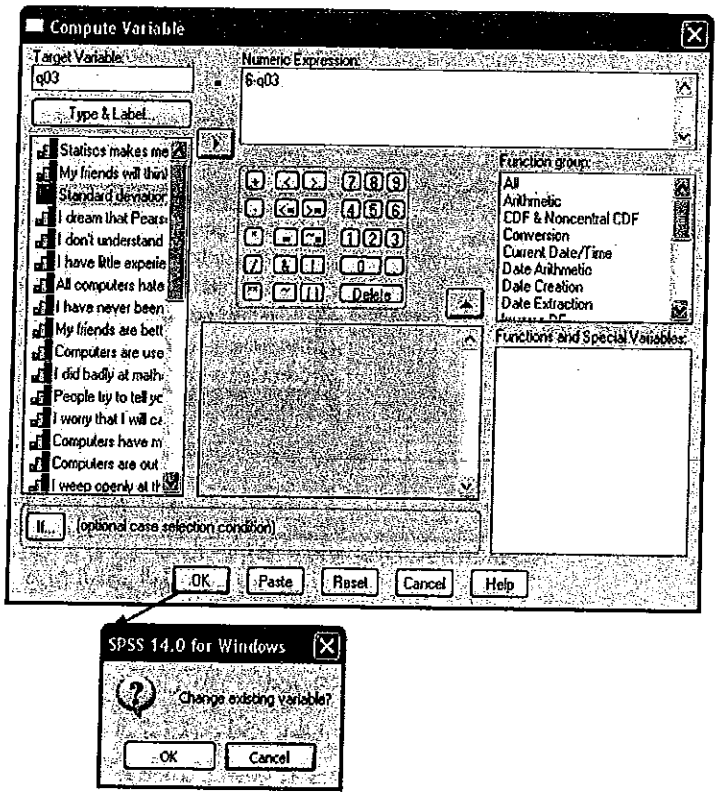

الشكل 11.15 ترتيب العلامات بشكل عكسي للعنصر الثالث (Q03) في برنامج SPSS

3.7.15 تحليل الوثوقية في برنامج SPSS

لنختبر الوثوقية للاستبيان SAQ باستخدام البيانات الموجودة في الملف SAQ.sav بعد أن نعكس ترتيب العلامات للعنصر الثالث (كما في الفقرة السابقة). يمكنك أيضاً تحميل الملف SAQ(Item 3 Reversed).sav الذي يحوي نفس البيانات ولكن بعد عكس العلامات للعنصر الثالث. تذكّر أننا قلنا أنه علينا تنفيذ تحليل الوثوقية على المقاييس الجزئية بشكل منفصل. إذا استخدمنا النتائج في حالة الدوران المتعامد (انظر الخرج 8.15) فإن لدينا 4 مقاييس جزئية هي:

- المقياس الجزئي الأول (الخوف من الحواسب) ويضم العناصر 6 و7 و10 و13 و14 و15 و18.
- المقياس الجزئي الثاني (الخوف من الإحصاء) ويضم العناصر 1 و3 و4 و5 و12 و16 و20 و21.
- المقياس الجزئي الثالث (الخوف من الرياضيات) ويضم العناصر 8 و11 و17.
- المقياس الجزئي الرابع (الخوف من تقييم الند) ويضم العناصر 2 و9 و19 و22 و23.

لتنفيذ كل تحليل للوثوقية على هذه البيانات ينبغي علينا أولاً فتح مربع الحوار المبين في الشكل 12.15 وذلك باستخدام أمر القائمة Analyze ⇒ Scale ⇒ Reliability Analysis... نختار بعد ذلك العناصر التي نريد تحليلها من اللائحة الموجودة في القسم الأيسر من مربع الحوار (ولنبدأ بعناصر المقياس الجزئي الأول الذي يعبر عن الخوف من الحواسب) وننقلها إلى الحيز المسمى Items.

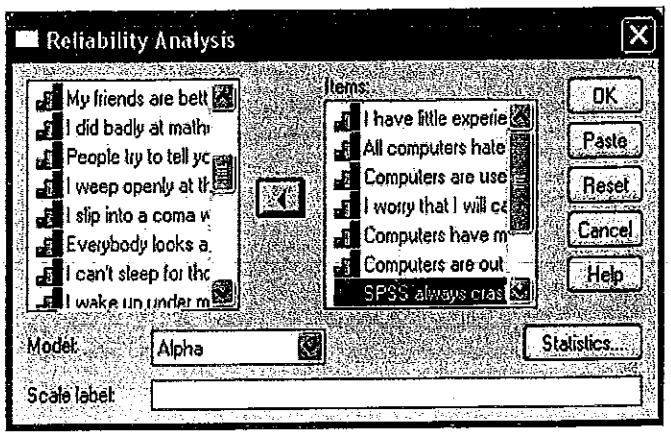

الشكل 12.15 مربع الحوار الرئيسي لتحليل الوثوقية

إذا حددنا الخيار List item labels فإن برنامج SPSS يعرض تسميات المتحولات في الخرج. يمكن تنفيذ عدة أنواع من تحليل الوثوقية، ولكن الخيار الافتراضي هو Alpha (Cronbach's α). يمكن تغيير الطريقة (واستخدام طريقة النصف المشطور مثلاً) باستخدام القائمة المنسدلة المسماة Model، ولكن الخيار الافتراضي هو خيار جيد ولا داعي لتغييره.

إذا نقرنا الزر ...Statistics نحصل على مربع الحوار المبين في الشكل 13.15 حيث يمكننا اختيار عدة أشياء، من أهمها بالنسبة للاستبيان الخيار Scale if item deleted. يوفر هذا الخيار قيمة α لكل عنصر في المقياس. ويدلنا على ما ستؤول إليه قيمة α إذا تم حذف ذلك العنصر. إذا كان الاستبيان موثوقاً فإننا لا نتوقع أن يؤثر أي عنصر وحيد بشكل كبير على الوثوقية. وبكلمات أخرى، لن يسبب أي عنصر وحيد انخفاضاً كبيراً في قيمة α. وإذا أثـّـر حذف ذلك العنصر بشكل كبير فإن لدينا أسباباً مقلقة وعلينا إهمال ذلك العنصر من الاستبيان. وبما أن القيمة 0.8 هي قيمة جيدة للمعامل α فإننا نأمل أن تكون جميع قيم α في حال حذف ذلك العنصر هي من مرتبة 0.8 أو أكثر.

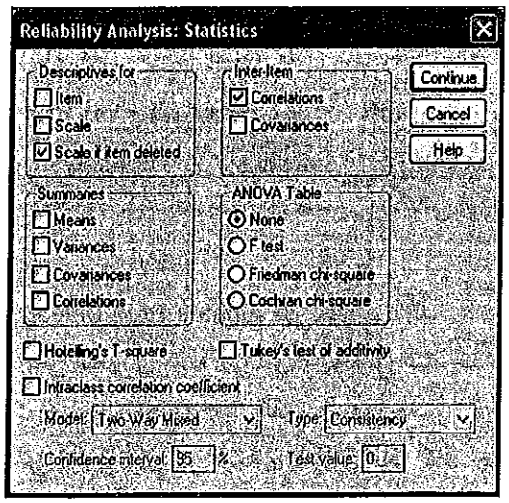

الشكل 13.15 الإحصائيات من أجل تحليل الوثوقية

يحوي القسم Inter-item خيارين لإعطاء معاملات الارتباط والقيم المتوسطة للعناصر على المقياس. وقد حصلنا على هذه القيم سابقاً في التحليل العاملي لذلك يمكننا عدم اختيار أي من الخيارين. على كل حال، إذا لم تنفذ التحليل العاملي سابقاً فمن المفيد اختيار الارتباطات بين العناصر لأن α الكلية تتأثر بعدد العناصر التي يتم تحليلها، وهكذا يمكنك العودة للتحقق فيما إذا كانت العناصر مترابطة جيداً فيما بينها. أما الخيارات مثل ANOVA Table فتقوم بمقارنة النزعة المركزية للعناصر المختلفة في الاستبيان باستخدام اختبار F (يقوم بتنفيذ ANOVA وحيد الاتجاه للقياسات المكررة على العناصر في الاستبيان)، أو اختبار كاي مربع لـــ Friedman (إذا كانت البيانات مرتبة)، أو اختبار كاي مربع لـــ Cochran (إذا كانت البيانات ثنائية، أي إذا كانت إجابات الاستبيان هي نعم/لا فقط).

يقوم اختبار Hotelling's T2 بنفس الشيء تقريباً ولكنه يعطي المكافئ متعدد المتغيرات للاختبار F. وهذه الاختبارات مفيدة إذا أردنا التحقق أن للعناصر خصائص توزيعية متشابهة (أي نفس قيمة المتوسط مثلاً)، ولكن حجم العينة المطلوب للتحليل العاملي سيجعل هذه الاختبارات تعطي نتائج ذات دلالة رغم وجود فروق صغيرة فقط بين المتوسطات لعناصر الاستبيان.

نستخدم مجموعة بسيطة من الخيارات في الشكل 13.15 لتنفيذ تحليل الوثوقية الأساسي. ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي ثم ننقر الزر OK لتنفيذ التحليل.

4.7.15 تفسير الخرج

يعرض الخرج 14.15 نتائج تحليل الوثوقية الأساسي للمقياس الجزئي "الخوف من الحواسب". إن القيم في العمود المسمى Corrected Item-Total Correlations هي الارتباطات بين كل عنصر والعلامة الكلية من الاستبيان. وفي مقياس موثوق يجب أن تكون كل العناصر مرتبطة مع العلامة الكلية. لذلك نبحث عن العناصر التي لا ترتبط مع العلامة الكلية من المقياس: إذا كانت أي من هذه القيم أصغر من 0.3 (بناءً على حجم العينة، فإذا كان حجم العينة كبيراً فإن قيماً أصغر لمعاملات الارتباط تكون مقبولة) فهناك إذاً مشكلة لأن هذا يعني أن عنصراً معيناً لا يرتبط بشكل جيد مع المقياس الكلي. وربما يتوجب علينا إهمال العناصر ذات معاملات الارتباط المنخفضة. من أجل المثال الحالي، كانت قيم معامل الارتباط بين كل عنصر والمقياس الكلي أكبر من 0.3، وهذه نتيجة مشجعة.

أما القيم في العمود المسمى Alpha if Item Deleted فهي قيم α الكلية عندما لا يتم تضمين العنصر في الحساب. وهكذا فهي تعكس التغير في قيمة α الذي سيحصل عند حذف عنصر معين. إن قيمة α الكلية هي 0.8234 ولذلك يجب أن تكون جميع القيم في هذا العمود قريبة من تلك القيمة. وما نبحث عنه عملياً هو قيم α التي تكون أكبر من قيمة α الكلية. فإذا كان حذف عنصر ما يزيد قيمة α فإن ذلك يعني أن حذف هذا العنصر يحسّن الوثوقية. ولذلك يجب حذف جميع العناصر التي يؤدي حذفها إلى تحسين ملموس في قيمة α الكلية. وكما نلاحظ في هذا المثال فإن حذف أي عنصر لن يزيد قيمة α الكلية (لن يحسّن الوثوقية) بشكل كبير، مع أن حذف العنصر 10 سيزيد قيمة α من 0.8234 إلى 0.8239، ولكن هذه الزيادة طفيفة جداً، وتعكس القيمتان درجة معقولة من الوثوقية.

وأخيراً، وربما الأهم، فإن قيمة Alpha في الجدول الأول من الخرج هي قيمة Cronbach's α الوثوقية الكلية للمقياس. ونكرر هنا ما قلناه سابقاً بأننا نبحث عن قيم α في المجال بين 0.7 و0.8 دون أن ننسى أثر عدد العناصر. إن قيمة α في هذه الحالة أكبر من 0.8، وهي في المنطقة التي أشار إليها Kline، ولذلك ربما تدل على وثوقية جيدة. والنقطة الأخيرة التي نريد قولها هنا هي أنه عند حذف أي عنصر في هذه المرحلة فعليك إعادة تنفيذ التحليل العاملي أيضاً للتأكد من أن حذف العنصر لم يؤثر على بنية العامل!

Reliability Statistics

Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items
.8234	.8214	7

Inter-Item Correlation Matrix

	q06	q07	q10	q13	q14	q15	q18
q06	1.0000	.5136	.3222	.4664	.4022	.3599	.5133
q07	.5136	1.0000	.2837	.4421	.4407	.3914	.5009
q10	.3222	.2837	1.0000	.3020	.2547	.2952	.2925
q13	.4664	.4421	.3020	1.0000	.4498	.3422	.5329
q14	.4022	.4407	.2547	.4498	1.0000	.3801	.4983
q15	.3599	.3914	.2952	.3422	.3801	1.0000	.3429
q18	.5133	.5009	.2925	.5328	.4983	.3429	1.0000

Item-Total Statistics

	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted
q06	15.8650	17.6141	.6187	.3981	.7906
q07	15.1684	17.7370	.6190	.3949	.7905
q10	15.8114	20.7360	.3999	.1665	.8239
q13	15.8429	18.8086	.6067	.3844	.7937
q14	15.2159	18.7188	.5768	.3504	.7980
q15	15.3259	19.3217	.4913	.2497	.8119
q18	15.5235	17.8324	.6474	.4475	.7855

الخرج 14.15

لننتقل الآن إلى المقياس الجزئي الثاني "الخوف من الإحصاء". لن ندخل مرة أخرى في تفاصيل الخرج المبين في الخرج 15.15، ولكننا نلخص بأن قيم معامل الارتباط بين كل عنصر والمقياس الكلي هي أكبر من 0.3، وأن قيمة α الكلية 0.8208 ممتازة لأنها أعلى من 0.8، وأن حذف أي عنصر لن يؤدي لتحسين هذه القيمة.

Reliability Statistics

Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items
.8208	.8234	8

Item-Total Statistics

	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted
q01	21.7569	21.4417	.5361	.3435	.8017
q03	20.7165	19.8250	.5492	.3093	.7996
q04	21.3450	20.4105	.5750	.3553	.7955
q05	21.4088	20.9422	.4944	.2724	.8066
q12	20.9716	20.6393	.5715	.3370	.7962
q16	21.2517	20.4507	.5973	.3686	.7928
q20	20.5068	21.1761	.4185	.2440	.8185
q21	20.9603	19.9385	.6061	.3988	.7908

الخرج 15.15

ولتوضيح أهمية منح العلامات بشكل عكسي قبل تنفيذ تحليل الوثوقية، فإن الخرج 16.15 يعرض تحليل الوثوقية للمقياس الجزئي الثاني "الخوف من الإحصاء" عند تنفيذه على البيانات الأصلية (دون تغيير طريقة منح العلامات للعنصر الثالث). لاحظ أن قيمة α الكلية هي أدنى بكثير (0.6055 مقارنة مع 0.8208). كما أن قيمة الارتباط بين العنصر والمقياس الكلي هي سالبة (وكما ترى فإن هذه الطريقة جيدة لالتقاط العناصر ذات الصياغة العكسية والتي لم يتم تعديل طريقة منحها العلامات). وأخيراً، لاحظ أنه إذا تم حذف العنصر Q03 فإن قيمة α تصبح 0.7996، وهذا يعني أن حذف هذا العنصر يحسّن الوثوقية بشكل كبير.

Reliability Statistics

Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items
.6055	.6413	8

Item-Total Statistics

	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted
q01	20.9277	12.1247	.5061	.3435	.5213
q03	20.7165	19.8250	-.5492	.3093	.7996
q04	20.5158	11.4467	.5260	.3553	.5048
q05	20.5795	11.7138	.4662	.2724	.5230
q12	20.1424	11.7393	.5006	.3370	.5154
q16	20.4224	11.5842	.5291	.3886	.5066
q20	19.6776	12.1073	.3528	.2440	.5576
q21	20.1311	11.1894	.5410	.3988	.4969

الخرج 16.15

ننتقل الآن إلى المقياس الجزئي الثالث "الخوف من الرياضيات". يعرض الخرج 17.15 الخرج الناتج عن التحليل. وكما نلاحظ فإن قيم معامل الارتباط بين كل عنصر والمقياس الكلي هي أكبر من 0.3، وأن قيمة α الكلية 0.8194 ممتازة لأنها أعلى من 0.8، وأن حذف أي عنصر لن يؤدي لتحسين هذه القيمة.

Reliability Statistics

Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items
.8194	.8195	3

Item-Total Statistics

	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted
q08	4.72	2.470	.684	.470	.740
q11	4.70	2.453	.682	.467	.742
q17	4.49	2.504	.652	.425	.772

الخرج 17.15

أخيراً، إذا نفذت تحليل الوثوقية من أجل المقياس الجزئي الرابع "الخوف من تقييم الند". فإنك تحصل على الخرج المبين في الخرج 18.15. إن قيم معامل الارتباط بين كل عنصر والمقياس الكلي هي أعلى بقليل من 0.3 باستثناء العنصر Q23 الذي تبلغ قيمته 0.2389. ويدل ذلك على توافق داخلي سيء نوعاً ما، ويحدد العنصر Q23 كمشكلة محتملة. أما القيم في العمود المسمى Cronbach's Alpha if Item Deleted فتشير إلى أن حذف أي عنصر لن يؤدي لتحسين قيمة α الكلية التي تبلغ 0.5699. وهذه القيمة منخفضة نسبياً مقارنة مع بقية المقاييس الجزئية، ومع أن هذه القيمة تبقى في نطاق ما يقوله Kline فإننا يجب أن نتوقع مثل هذه النتيجة عند التعامل مع بيانات متعلقة بالعلوم الاجتماعية. يبلغ عدد العناصر في هذا المقياس 5 مقارنة مع 7 (للمقياس الجزئي الأول) و8 (للمقياس الجزئي الثاني)، ولذلك فإن وثوقيته المنخفضة لن تتأثر كثيراً بعدد العناصر. إذا نظرنا إلى العناصر في هذا المقياس سنجد أنها تغطي مواضيع متنوعة للخوف من تقييم الند، وربما يفسر هذا الضعف النسبي للانسجام فيه. وقد يقودنا ذلك إلى إعادة التفكير بهذا المقياس الجزئي.

Reliability Statistics

Cronbach's Alpha	Cronbach's Alpha Based on Standardized Items	N of Items
.5699	.5724	5

Item-Total Statistics

	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Squared Multiple Correlation	Cronbach's Alpha if Item Deleted
q02	11.4609	8.1186	.3389	.1337	.5153
q09	10.2380	6.3955	.3907	.1674	.4765
q19	10.7923	7.3810	.3162	.1060	.5218
q22	10.1964	7.2824	.3776	.1441	.4870
q23	9.6499	7.9879	.2389	.0689	.5628

الخرج 18.15

أفكار مهمة الوثوقية

- الوثوقية هي انسجام المقياس.
- يمكن استخدام تحليل الوثوقية لقياس الانسجام في استبيان ما.
- تذكّر أن تعكس طريقة منح العلامات للعناصر التي تمت صياغتها عكسياً في الاستبيان الأصلي قبل تنفيذ التحليل.
- نفّذ تحاليل وثوقية منفصلة على كل مقياس جزئي في الاستبيان.
- تدل قيمة Cronbach's α على الوثوقية الكلية للاستبيان، والقيم القريبة من 0.8 هي جيدة (ومن أجل اختبارات القابلية والقدرة فإن القيمة 0.7 مقبولة).
- يدل العمود المسمى Cronbach's Alpha if Item Deleted على التحسّن في الوثوقية إذا تم حذف عنصر ما، حيث تدل القيم التي تكون أكبر من α الكلية على أن حذف العنصر سيؤدي لتحسين الوثوقية. ابحث عن العناصر التي تزيد قيمة α بشكل كبير.
- إذا حذفت عنصراً ما (أو بعض العناصر) فعليك إعادة تنفيذ التحليل العاملي للتحقق من أن بنية العامل بقيت ثابتة ولم تتغير.

8.15 ما الذي اكتشفناه عن الإحصاء

تعرفنا في هذا الفصل على التحليل العاملي، وهو تقنية لتحديد تجمعات المتحولات المرتبطة ببعضها البعض. وتعطي معظم الكتب انطباعاً بأن الإحصاء مثل كتاب الطبخ، يكفي إتباع التعليمات للحصول على قالب كاتو لذيذ. وربما يوضح التحليل العاملي (أكثر من أي اختبار آخر في هذا الكتاب) عدم صحة هذا الانطباع. فعالم الإحصاء مليء بالقواعد الاعتباطية (والقيمة 0.05 مثال تقليدي على ذلك) وفي معظم الأوقات ينبغي عليك التصرف وفق اجتهادك الشخصي. وقد رأينا في المرحلة الأولى من التحليل العاملي أنه علينا إجراء عملية مسح للبيانات للتحقق من أنها مرتبطة ببعضها البعض لحد ما وليس بشكل كبير. وللتحليل العاملي عدة مراحل تبدأ بالتحقق من بعض المسائل الأولية (مثل كفاية حجم العينة) مروراً باتخاذ القرار بعدد العوامل التي ينبغي الاحتفاظ بها، وصولاً إلى تحديد العناصر ذات التحميل الأكبر على كل عامل ومحاولة إيجاد معنى لكل عامل من العوامل. وبعد الانتهاء من ذلك علينا معرفة فيما إذا كانت العناصر هي قياسات موثوقة لما تريد قياسه فعلياً.

9.15 المصطلحات الأساسية التي اكتشفناها

تحليل ألفا لعواملها	(Alpha factoring)
طريقة Anderson-Rubin	(Anderson-Rubin method)
التباين التشاركي	(Common variance)
التشاركية	(Communality)

مصفوفة المكونات	(Component matrix)
التحليل العاملي التأكيدي	(Confirmatory factor analysis)
قيمة Cronbach's α	(Cronbach's α)
طريقة Direct oblimin	(Direct oblimin)
طريقة Equamax	(Equamax)
الاستخراج	(Extraction)
العامل	(Factor)
التحليل العاملي	(Factor analysis)
تحميل العوامل	(Factor loading)
مصفوفة العوامل	(Factor matrix)
علامات العامل	(Factor scores)
مصفوفة تحويل العوامل Λ	(Factor transformation matrix)
مقياس كفاية أخذ العينات KMO	(Kaiser-Meyer-Olkin measure of sampling adequacy)
معيار Kaiser	(Kaiser's criterion)
متحول مستتر	(Latent variable)
الدوران المائل	(Oblique rotation)
الدوران المتعامد	(Orthogonal rotation)
مصفوفة النمط	(Pattern matrix)
تحليل المكونات الأساسية	(Principal component analysis)
طريقة Promax	(Promax)
طريقة Quartimax	(Quartimax)
التباين العشوائي	(Random variance)
الوثوقية	(Reliability)
الدوران	(Rotation)
مخطط المنحدر	(Scree plot)

وثوقية النصف المشطور	(Split-half reliability)
مصفوفة البنية	(Structure matrix)
وثوقية الاختبار–إعادة الاختبار	(Test-retest reliability)
التباين الفريد	(Unique variance)
طريقة Varimax	(Varimax)

10.15 مهمات يجب تنفيذها

تبحث جامعة Sussex بشكل دائم عن أفضل الأشخاص لتعيينهم كمحاضرين لديها. وترغب بتعديل استبيان مستند إلى نظرية Bland عن المحاضرين ذوي طرق البحث. وتتوقع هذه النظرية أن يملك المحاضرون أصحاب طرق البحث المميزات التالية: (1) حبّ لعلم الإحصاء، (2) حماس للتصميم التجريبي، (3) حبّ التدريس، (4) غياب تام للمهارات الطبيعية المتعلقة بالعلاقات مع الأشخاص الآخرين. ويجب أن تكون هذه المميزات مترابطة. والاستبيان TOSSE موجود عملياً، ولكن الجامعة قامت بتعديل هذا الاستبيان ليصبح TOSSE-R، ووزعته على 239 محاضراً في طرق البحث حول العالم لمعرفة فيما إذا كان يدعم نظرية Bland. يوضح الشكل 14.15 هذا الاستبيان ويحوي الملف TOSSE-R.sav البيانات المتعلقة به. والمطلوب تنفيذ تحليل عاملي مع الدوران المناسب لمعرفة بنية العوامل في هذه البيانات.

SD= غير موافق أبداً، D= غير موافق، N= لا أعرف، A= موافق، SA= موافق تماماً

		SD	D	N	A	SA
1	استيقظت ذات مرة في مزرعة خضار وأنا أحضن حبة لفت معتقداً أنني أستخرج جذر Roy الأكبر	O	O	O	O	O
2	لو كان عندي مسدس لأطلقت النار على جميع الطلاب الذي أدرسهم	O	O	O	O	O
3	أحفظ قيم الاحتمال لتوزيع F عن ظهر قلب	O	O	O	O	O
4	أتعبد في ضريح Pearson	O	O	O	O	O
5	ما زلت أعيش مع أمي، وعندي بعض مشاكل النظافة الشخصية...	O	O	O	O	O
6	يدفعني تدريس الآخرين للرغبة بشرب زجاجة من مادة كيميائية قوية لأن الألم في المري المحترق هو شعور بالارتياح مقارنة مع التدريس	O	O	O	O	O
7	عندما أساعد الآخرين على فهم مجموع المربعات أحس بشعور رائع	O	O	O	O	O
8	أحب حالات المراقبة	O	O	O	O	O
9	أقوم بحساب 3 عمليات ANOVA ذهنياً قبل أن أنهض من فراشي صباح كل يوم	O	O	O	O	O
10	يمكن أن أقضي يومي كاملاً في شرح الإحصاء للآخرين	O	O	O	O	O
11	أشعر بالرضى عندما يخبرني الآخرون بأنني ساعدتهم في فهم دوران العوامل	O	O	O	O	O
12	يشعر الناس بالنعاس حالما أبدأ بالحديث	O	O	O	O	O

SD= غير موافق أبداً، D= غير موافق، N= لا أعرف، A= موافق، SA= موافق تماماً

		SD	D	N	A	SA
13	تصميم التجارب أمر ممتع	O	O	O	O	O
14	أفضل التفكير بالمتحولات التابعة المناسبة على الذهاب إلى المقهى	O	O	O	O	O
15	أشعر بالإثارة لمجرد ذكر التحليل العاملي	O	O	O	O	O
16	أفرح كثيراً لمجرد التفكير باختيار القياسات المكررة أو المستقلة	O	O	O	O	O
17	أستمتع بالجلوس في الحديقة والتأمل فيما إذا كنت سأراقب المشتركين في تجربتي القادمة	O	O	O	O	O
18	إن الوقوف أمام 300 شخص يفقدني السيطرة على أمعائي ...	O	O	O	O	O
19	أحب أن أساعد الطلاب	O	O	O	O	O
20	إن نقل المعرفة لشخص آخر هي أعظم هدية يمكن أن تقدمها إلي	O	O	O	O	O
21	أشعر بوخزة في الأربية (بين الفخذ والبطن) لمجرد التفكير بتصحيح Bonferroni	O	O	O	O	O
22	أرتجف عند التفكير بتصميم تجربتي القادمة	O	O	O	O	O
23	أقضي أوقات الفراغ في التحدث إلى الطيور ... التي تموت من الضجر	O	O	O	O	O
24	حاولت بناء آلة الزمن بنفسي لكي أعود إلى عام 1930 وأتابع Fisher زحفاً على ركبتي	O	O	O	O	O
25	أحب التدريس	O	O	O	O	O
26	أقضي معظم الوقت في مساعدة الطلاب	O	O	O	O	O
27	أحب التدريس لأن على الطلاب أن يتظاهروا بحبهم لي وإلا فسيحصلون على علامات متدنية	O	O	O	O	O
28	قطتي هي صديقي الوحيد	O	O	O	O	O

الشكل 14.15 الاستبيان TOSSE-R

يحوي الملف Answers(Chapter15).pdf الإجابات على هذه المهمة.

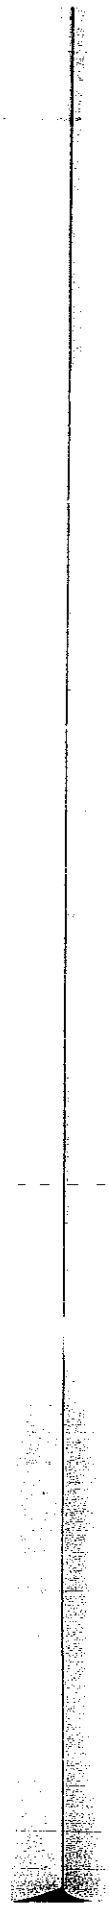

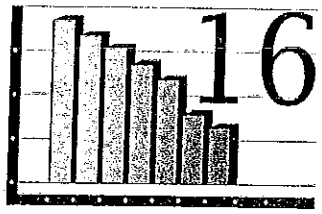

البيانات الفئوية

1.16 ماذا يخبرنا هذا الفصل

نهتم أحياناً بالمتحولات الفئوية (Categorical variables) وهي المتحولات التي دعوناها سابقاً بمتحولات التجميع، وتصف فئات من الكيانات. وقد تعاملنا مع هذه المتحولات في جميع فصول هذا الكتاب تقريباً. وهناك أنواع مختلفة من المتحول الفئوي (أنظر الفقرة 6.5.4). ولكن نظرياً يجب أن ينتمي الشخص أو الحالة إلى فئة واحدة فقط. ومن الأمثلة الجيدة عن المتحولات الفئوية يمكن أن نذكر الجنس (فالإنسان يكون من الناحية البيولوجية إما ذكراً أو أنثى) والحَمل (فالمرأة إما أن تكون حاملاً أو غير حامل) والتصويت في الانتخابات (يمكن للشخص أن يدلي بصوته من أجل مرشح واحد فقط). وفي جميع الحالات (باستثناء التراجع المنطقي) استخدمنا مثل هذه المتحولات الفئوية للتنبؤ بنوع ما من الخرج المستمر، ولكننا نرغب في بعض الحالات بالنظر إلى العلاقات بين مجموعات من المتحولات الفئوية. ويهتم هذا الفصل باثنتين من التقنيات لتنفيذ ذلك. ونبدأ مع الحالة البسيطة لمتحولين فئويين ونكتشف إحصائية كاي مربع (وهذا ليس اكتشافاً في الواقع، لأننا تعاملنا مع هذه الإحصائية سابقاً). ثم نوسّع هذا النموذج للنظر إلى العلاقات بين عدة متحولات فئوية.

2.16 نظرية تحليل البيانات الفئوية

سنبدأ هذا الفصل بالنظر إلى الحالة الأبسط التي يمكن أن نصادفها، وهي تحليل متحولين فئويين. إذا أردنا النظر إلى العلاقة بين متحولين فئويين فإنه لا يمكننا استخدام المتوسط أو أي إحصائية مشابهة لأننا لا نملك أي متحولات تم قياسها بشكل مستمر. إن محاولة حساب المتوسط لمتحول فئوي هي عملية بدون فائدة لأن القيم العددية المعطاة للفئات المختلفة هي اعتباطية، ومتوسط هذه القيم سيعتمد على عدد العناصر في كل فئة. لذلك عندما نقيس متحولات فئوية فقط فإننا نحلل تكرارها فقط، أي أننا نحلل عدد الأشياء التي تقع في كل تركيب من الفئات. لنأخذ مثالاً، اهتم أحد الباحثين في إمكانية تدريب الحيوانات على الرقص، فأخذ 200 قط وحاول تدريبها على الرقص ومنحها إما الطعام أو الحنان كمكافأة على التصرفات الشبيهة بالرقص. وفي نهاية الأسبوع أحصى

عدد القطط التي تستطيع الرقص وتلك التي لا تستطيع الرقص. لدينا متحولان فئويان في هذا المثال هما training (تم تدريب القط بمنحه إما الطعام أو الحنان) و dance (تعلم القط الرقص أو أنه لم يتعلم). وبتركيب الفئات نحصل على 4 فئات مختلفة. ينبغي علينا بعد ذلك حساب عدد القطط في كل فئة. يمكننا وضع التكرارات في جدول كالمبين في الجدول 1.16 (الذي يعرض بيانات هذا المثال) والذي يدعى جدول الأحداث المحتملة (Contingency table).

		Training التدريب		
هل يستطيع الرقص		الحنان Affection	الطعام Food	الكلي
	نعم	48	28	76
	لا	114	10	124
	الكلي	162	38	200

الجدول 1.16 جدول الأحداث المحتملة لبيانات القطط التي تعلمت الرقص بعد تدريبها بمنحها مكافآت مختلفة

1.2.16 اختبار كاي مربع لـ Pearson

إذا أردنا معرفة هل هناك علاقة بين متحولين فئويين (هل يتعلق عدد القطط التي تجيد الرقص بنوع التدريب المعتمد؟) فإنه يمكننا استخدام اختبار كاي مربع لـــ Pearson. وتعتمد هذه الإحصائية على فكرة بسيطة مفادها مقارنة التكرارات المشاهدة في فئات معينة مع التكرارات التي نتوقع الحصول عليها في هذه الفئات بمحض الصدفة. وقد رأينا في الفصول 1 و 5 و 8 أنه إذا قمنا بملاءمة نموذج ما (model) لأي مجموعة من البيانات (observed) فإننا نستطيع تقييم ذلك النموذج باستخدام معادلة بسيطة جداً (أو شكل آخر منها):

$$\text{deviation} = \Sigma\,(\text{observed} - \text{model})^2$$

وقد كانت هذه المعادلة الأساس لمجموع المربعات في التراجع وفي تحليل التباين (ANOVA). والآن عندما تكون لدينا بيانات فئوية فإنه يمكننا استخدام نفس المعادلة. هناك شكل مختلف قليلاً من هذه المعادلة حيث نقسم على علامات النموذج، وهي نفس العملية التي قمنا بها عند تقسيم مجموع المربعات على درجات الحرية في ANOVA. تدعى الإحصائية الناتجة كاي مربع χ^2 (Pearson's chi-square) وهي معطاة في المعادلة (1.16):

$$\chi^2 = \Sigma \frac{(\text{Observed}_{ij} - \text{Model}_{ij})^2}{\text{Model}_{ij}} \qquad (1.16)$$

البيانات المشاهدة في هذا المثال هي التكرارات الموجودة في الجدول 1.16، ولكن علينا إيجاد النموذج: في ANOVA يكون النموذج الذي نستخدمه هو متوسطات المجموعات، ولكن كما أشرنا سابقاً فإنه لا يمكننا التعامل مع قيم المتوسط عند وجود متحولات فئوية فقط، لذلك نستخدم "القيم المتوقعة". وهناك طريقة لتقدير القيم المتوقعة وهي أن نقول "لدينا 200 قط و 4 فئات، لذلك

تكون القيمة المتوقعة هي 200/4=50". تكون هذه الطريقة معقولة إذا كان لدينا نفس العدد من القطط في كل من فئتي التدريب، ولكن لدينا عملياً 38 قطاً في الفئة التي نالت الطعام كمكافأة، و162 قطاً في الفئة التي نالت الحنان. ويمكن أن نقول نفس الشيء عن فئتي الرقص، فأعداد القطط فيهما ليست متساوية. ولكي نأخذ ذلك بعين الاعتبار فإننا نحسب القيم المتوقعة لكل من الخلايا في الجدول (في هذا المثال لدينا 4 فئات) ونستخدم عمود القيم الكلية و صفّ القيم الكلية من أجل خلية معينة لحساب القيمة المتوقعة:

$$\text{Model}_{ij} = E_{ij} = \frac{\text{Row Total}_i \times \text{Column Total}_j}{n}$$

في هذه المعادلة يمثل n العدد الكلي للمشاهدات (200 في هذا المثال). يمكننا حساب القيم المتوقعة لكل من الخلايا الأربع ضمن الجدول (RT=القيمة الكلية في الصف، CT=القيمة الكلية في العمود):

$$\text{Model}_{Food,Yes} = \frac{RT_{\text{Yes}} \times CT_{Food}}{n} = \frac{76 \times 38}{200} = 14.44$$

$$\text{Model}_{Food,No} = \frac{RT_{\text{No}} \times CT_{Food}}{n} = \frac{124 \times 38}{200} = 23.56$$

$$\text{Model}_{Affection,Yes} = \frac{RT_{\text{Yes}} \times CT_{Affection}}{n} = \frac{76 \times 162}{200} = 61.56$$

$$\text{Model}_{Affection,No} = \frac{RT_{\text{No}} \times CT_{Affection}}{n} = \frac{124 \times 162}{200} = 100.44$$

لدينا الآن القيم المتوقعة للنموذج، وهكذا يمكننا تعويض جميع القيم في علاقة كاي مربع (المعادلة (1.16)):

$$\chi^2 = \frac{(28-14.44)^2}{14.44} + \frac{(10-23.56)^2}{23.56} + \frac{(48-61.56)^2}{61.56} + \frac{(114-100.44)^2}{100.44}$$
$$= \frac{(13.56)^2}{14.44} + \frac{(-13.56)^2}{23.56} + \frac{(-13.56)^2}{61.56} + \frac{(13.56)^2}{100.44}$$
$$= 25.35$$

يمكن بعد ذلك مقارنة هذه الإحصائية مع توزيع ذي خصائص معروفة. وكل ما علينا معرفته هو درجات الحرية والتي يمكن حسابها من العلاقة (r-1)(c-1) حيث r عدد الصفوف و c عدد الأعمدة. وفي هذه الحالة يكون عدد درجات الحرية 1=(2-1)(2-1). إذا كنا نقوم بتنفيذ الحسابات يدوياً فعلينا أن نجد القيمة الحرجة لتوزيع كاي مربع مع درجة حرية واحدة، وإذا كانت القيمة المشاهدة أكبر من تلك القيمة الحرجة فيمكننا أن نقول أن هناك علاقة مهمة بين المتحولين. وقد تم إعطاء القيم الحرجة في الملحق A4، ومن أجل درجة حرية واحدة فإن القيم الحرجة هي 3.48 من أجل p=0.05، و6.64 من أجل p=0.01. وبما أن القيمة المشاهدة (25.35) أكبر من هاتين القيمتين فإنه يمكننا القول أنها هامة عند المستوى p<0.01. على كل حال، إذا استخدمنا برنامج SPSS فإنه يعطي تقديراً لاحتمال الحصول على إحصائية كاي مربع قدرها 25.35 بمحض الصدفة.

2.2.16 نسبة الاحتمالية

هناك إحصائية بديلة لإحصائية كاي مربع لـــ Pearson وهي نسبة الاحتمالية التي تعتمد على نظرية الاحتمالية العظمى. والفكرة العامة لهذه النظرية هي أننا نجمع بعض البيانات وننشئ نموذجاً يكون فيه احتمال الحصول على مجموعة البيانات المشاهدة أعظمياً، ثم نقارن هذا النموذج مع احتمال الحصول على هذه البيانات تحت فرضية العدم. ولهذا تكون الإحصائية الناتجة مستندة إلى مقارنة التكرارات المشاهدة مع التكرارات المتوقعة من قِبَل النموذج:

$$L\chi^2 = 2\sum \text{Observed}_{ij} \cdot \ln\left(\frac{\text{Observed}_{ij}}{\text{Model}_{ij}}\right) \qquad (2.16)$$

حيث يدل الرمز ln على اللوغاريتم الطبيعي (وهو تابع رياضي قياسي تعرفنا عليه في الفصل 6). باستخدام نفس النموذج والقيم المشاهدة الموجودة في الفقرة السابقة فإننا نحصل على:

$$L\chi^2 = 2\left[28 \cdot \ln\left(\frac{28}{14.44}\right) + 10 \cdot \ln\left(\frac{10}{23.56}\right) + 48 \cdot \ln\left(\frac{48}{61.56}\right) + 114 \cdot \ln\left(\frac{114}{100.44}\right)\right]$$
$$= 24.94$$

ولهذه الإحصائية توزيع كاي مربع أيضاً بنفس عدد درجات الحرية مثل إحصائية كاي مربع لـــ Pearson. ويتم اختبارها بنفس الطريقة حيث نبحث عن القيمة الحرجة لتوزيع كاي مربع من أجل عدد درجات الحرية المناسب. وكما في الفقرة السابقة فإن قيمة الإحصائية ستكون هامة لأنها أكبر من القيمة الحرجة: 3.48 عند مستوى p=0.05 و6.63 عند مستوى p=0.01. في العينات الكبيرة تكون هذه الإحصائية قريبة جداً من إحصائية كاي مربع لـــ Pearson إلا أنها مفضلة عندما تكون العينات صغيرة.

3.2.16 تصحيح Yates

عندما يكون لدينا متحولان فئويان لكل منهما فئتان فقط فإن إحصائية كاي مربع لـــ Pearson تميل لإعطاء قيم دلالة صغيرة جداً (أي أنها تميل لارتكاب الخطأ من النوع الأول). لذلك اقترح Yates تصحيح صيغة Pearson لتأخذ الشكل التالي:

$$\chi^2 = \sum \frac{\left(\left|\text{Observed}_{ij} - \text{Model}_{ij}\right| - 0.5\right)^2}{\text{Model}_{ij}}$$

ومن أجل بيانات المثال الحالي فإننا نجد:

$$\chi^2 = \frac{(13.56 - 0.5)^2}{14.44} + \frac{(13.56 - 0.5)^2}{23.56} + \frac{(13.56 - 0.5)^2}{61.56} + \frac{(113.56 - 0.5)^2}{100.44}$$
$$= 23.52$$

وأهم ما يجب ملاحظته هو أن هذه الإحصائية تخفض قيمة الإحصائية كاي مربع ولذلك تجعلها أقل أهمية. وبالرغم من أن ذلك يبدو حلاً رائعاً للمشكلة فإن من الواضح أنها تصحح قيم كاي مربع بشكل مفرط وتجعلها صغيرة جداً.

3.16 فرضيات اختبار كاي مربع

يجب أن يكون بديهياً أن اختبار كاي مربع لا يعتمد على فرضيات مثل أن تكون البيانات موزعة طبيعياً (فالبيانات الفئوية غير مستمرة، وبالتالي لا يمكنها أن تكون موزعة طبيعياً). ولكن هناك فرضيتان هامتان لاختبار كاي مربع:

- لكي يكون الاختبار مفيداً، من الضروري أن يساهم كل شخص أو عنصر أو كيان في خلية واحدة فقط من خلايا جدول الأحداث المحتملة. لذلك لا يمكنك استخدام كاي مربع في تصميم للقياسات المكررة (إذا قمنا بتدريب بعض القطط بمنحها الطعام لمعرفة إمكانية أن تتعلم الرقص، ثم قمنا بتدريب نفس القطط بمنحها الحنان فإننا لا نستطيع تحليل البيانات الناتجة باستخدام اختبار كاي مربع).
- يجب أن تكون التكرارات المتوقعة أكبر من 5. وعلى الرغم من أننا نقبل في الجداول الكبيرة للأحداث المحتملة بوجود نسبة تصل إلى 20% من التكرارات المتوقعة التي تقل قيمتها عن 5 فإن النتيجة هي ضياع القدرة الإحصائية (لذلك قد يفشل الاختبار في اكتشاف أثر حقيقي). وحتى في الجداول الكبيرة للأحداث المحتملة فلا يجب أن يقل أحد الاحتمالات المتوقعة عن 1.

وأخيراً، فإن الفروق الصغيرة في تكرارات الخلايا قد تؤدي لربط مهم إحصائياً بين المتحولات. لذلك ينبغي علينا النظر إلى النسب المئوية في الصفوف والأعمدة لتفسير الآثار التي قد نحصل عليها. وتعكس هذه النسب المئوية أنماط البيانات بشكل أفضل بكثير من التكرارات ذاتها (لأن هذه التكرارات ستكون تابعة لحجم العينة في الفئات المختلفة).

4.16 تنفيذ كاي مربع في برنامج SPSS

هناك طريقتان يمكن استخدامهما لإدخال البيانات الفئوية: إما إدخال العلامات الصفّية، أو إدخال الحالات المثقّلة.

1.4.16 إدخال البيانات: العلامات الصفّية

إذا أدخلنا العلامات الصفية فهذا يعني أن كل صف من محرر البيانات يمثل الكيان صاحب البيانات (في هذا المثال، كل صفّ يمثل قطاً). لذلك علينا إنشاء متحولَي ترميز (training وdance) وتحديد الرموز العددية المناسبة لكل منهما. يمكن ترميز المتحول training بالرمز 0 ليمثل المكافأة بالطعام والرمز 1 ليمثل المكافأة بالحنان، وترميز المتحول dance بالرمز 0 ليمثل القط الذي يستطيع الرقص والرمز 1 ليمثل القط الذي لا يستطيع الرقص. ومن أجل كل قط فإننا نضع الرمز العددي المناسب في كل من العمودين. فإذا كان القط مدرباً باستخدام الطعام ولا يستطيع الرقص فإننا نضع الرمز 0 في العمود training والرمز 1 في العمود dance. يحوي الملف cats.sav البيانات لهذا المثال. وبما أن عدد القطط هو 200 فإن الملف يحوي 200 صف من البيانات.

2.4.16 إدخال البيانات: العلامات المثقّلة

نقوم بإنشاء متحولَي ترميز كما في الحالة السابقة (training و dance) إضافة إلى متحول ثالث يمثل عدد القطط التي تقع في كل تركيب من الفئات، أي أننا نُدخل بيانات التكرار أيضاً (عدد الحالات التي تقع في فئة معينة). يمكننا أن ندعو هذا المتحول frequent. يبين الشكل 1.16 محرر البيانات بعد إضافة المتحول الثالث. والآن بدلاً من وجود 200 صف من البيانات، لدينا 4 صفوف يمثل كل واحد منها أحد تراكيب الفئات ومتحولاً إضافياً يدل على عدد القطط في كل من هذه الفئات. وهكذا يمثل الصف الأول القطط التي نالت الطعام كمكافأة واستطاعت الرقص. ويدل المتحول frequent على عدد هذه القطط (28). لقد كانت هذه المعلومات تشغل 28 صفاً في الملف Cats.sav، وهي تشغل الآن صفاً واحداً. تخيّل إذاً التوفير في الوقت والجهد الذي تحققه باستخدام هذه الطريقة.

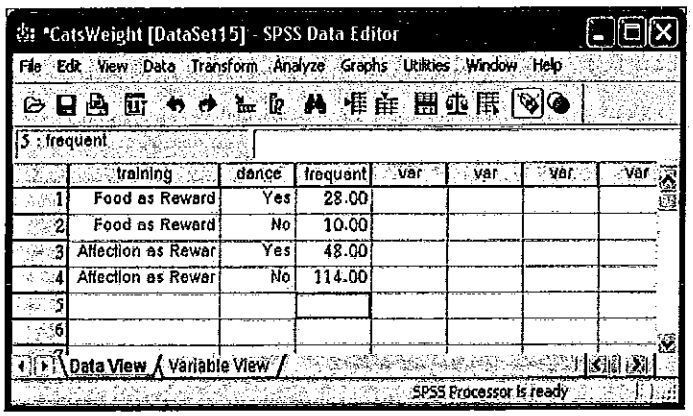

الشكل 1.16 إدخال البيانات باستخدام العلامات المثقّلة

لتحليل البيانات التي تم إدخالها بهذه الطريقة، علينا أن نخبر البرنامج أن المتحول frequent يمثل عدد الحالات التي تقع ضمن تركيب معين من الفئات. ويتم ذلك باستخدام أمر القائمة Data ⇒ Weight cases... للوصول إلى الوظيفة Weight cases المبينة في الشكل 2.16. نحدد الخيار Weight cases by ثم نختار المتحول الذي يحوي عدد الحالات (في هذا المثال frequent) وننقله إلى الحيز المسمى Frequency variable. توجه هذه العملية البرنامج لتثقيل تركيب من الفئات بالعدد الموجود في العمود المسمى frequent. يحوي الملف CatsWeight.sav البيانات التي تم إدخالها بهذه الطريقة.

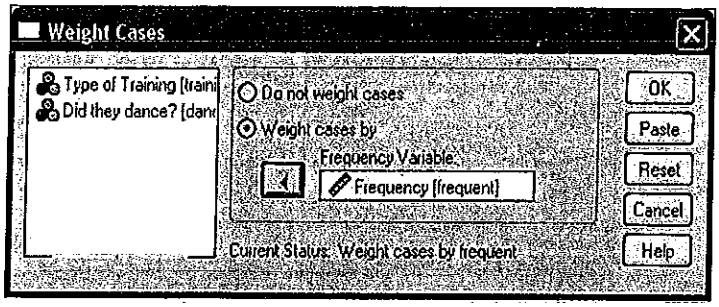

الشكل 2.16 مربع الحوار للوظيفة Weight cases

3.4.16 تنفيذ التحليل

إن تلخيص البيانات التي تقع في فئات يتم باستخدام الوظيفة crosstabs (والتي تعطي اختبار كاي مربع أيضاً) والتي يمكن الوصول إليها باستخدام أمر القائمة Analyze ⇒ Descriptive statistics ⇒ Crosstabs... يبين الشكل 3.16 مربعات الحوار للوظيفة Crosstabs. نختار أحد المتحولات في القسم الأيسر من مربع الحوار الرئيسي وننقله إلى الحيز المسمى Row(s). وفي هذا المثال اخترنا المتحول dance ليشكّل الصفوف في الجدول. بعد ذلك نختار المتحول الآخر training وننقله إلى الحيز المسمى Column(s). إضافة لذلك يمكننا اختيار متحول طبقة (حيث يمكننا فصل الصفوف في الجدول إلى فئات أخرى). إذا كان لدينا متحول فئوي ثالث فإنه يمكننا استخدام هذا المتحول لفصل جدول الأحداث المحتملة بحيث تمثل طبقات الجدول فئات مختلفة من هذا المتحول الثالث.

إذا نقرنا الزر Statistics... يظهر مربع الحوار الذي يسمح بتحديد الاختبارات الإحصائية المختلفة. ويشرح المربع 1.16 أهم الخيارات في مربع الحوار Statistics للبيانات الفئوية. نختار اختبار كاي مربع Chi-square ومعامل الأحداث المحتملة Contingency coefficient وPhi وLambda ثم ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

إذا نقرنا الزر Cells... يظهر مربع الحوار الذي يسمح بتحديد نوع البيانات التي سيتم إظهارها في الجدول. من المهم أن نطلب إظهار الأعداد المتوقعة Expected counts، إذ لكي تكون إحصائية كاي مربع دقيقة يجب أن تتجاوز تلك الأعداد المتوقعة قيمة معينة. والقاعدة الأساسية من أجل جدول الأحداث المحتملة ذي الأبعاد 2×2 أن لا تكون أي من الأعداد المتوقعة أقل من 5. وفي الجداول الكبيرة فإن القاعدة تنصّ على أن تكون جميع الأعداد المتوقعة أكبر من 1 وأن لا تزيد نسبة الأعداد المتوقعة التي تقل عن 5 عن النسبة 20%. من المفيد أيضاً إلقاء نظرة على النسب المئوية الكلية وللصفوف وللأعمدة لأن هذه القيم تكون عادة أسهل تفسيراً من قيم التكرار الفعلية وتعطي فكرة عن أصل الآثار المهمة. بعد الانتهاء من تحديد هذه الخيارات ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

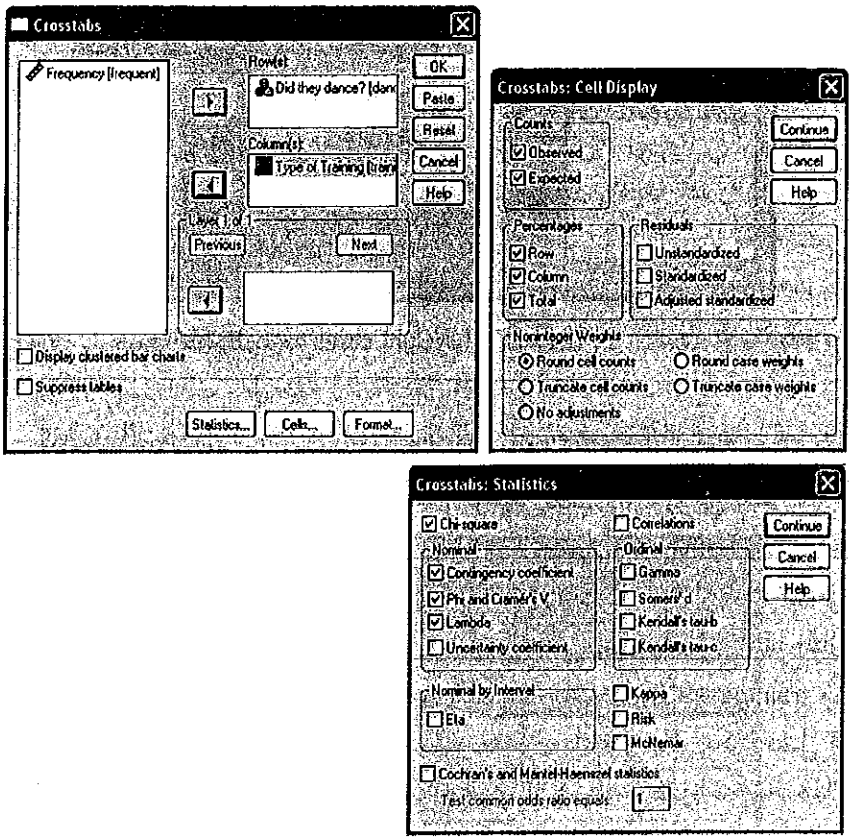

الشكل 3.16 مربعات الحوار للوظيفة Crosstabs

ننقر الزر ...Exact (إذا كانت مجموعة الاختبارات الدقيقة مثبتة مع البرنامج) ونحدد الخيار Exact (أنظر الفقرة 3.2.13). ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي، ثم ننقر الزر OK لتنفيذ التحليل.

المربع 1.16 الخيارات الإحصائية من أجل Crosstabs

- **الخيار Chi-square:** ينفّذ هذا الخيار اختبار كاي مربع الأساسي لـ Pearson (أنظر الفقرة 1.2.16). يكتشف اختبار كاي مربع فيما إذا كانت هناك علاقة ذات دلالة بين متحولين فئويين، ولكنه لا يدل على مدى قوة هذه العلاقة.
- **الخيار Phi and Cramer's V:** وهي مقاييس لقوة العلاقة بين متحولين فئويين. يُستخدم Phi مع جداول الأحداث المحتملة ذات الأبعاد 2x2 (أي أنها تحوي متحولين فئويين لكل منهما فئتان فقط). يتم حساب Phi بأخذ قيمة كاي مربع وتقسيمها على حجم العينة ثم حساب الجذر التربيعي للقيمة الناتجة. إذا كان أحد المتحولين الفئويين يحوي ثلاث فئات على الأقل فمن المفضل عندئذ استخدام Cramer's V، لأن Phi تفشل في الوصول إلى قيمتها الصغرى 0 في هذه الحالة.

- **الخيار Lambda:** تقيس λ Goodman and Kruskal التخفيض المتناسب في الخطأ الذي يتم تحقيقه عندما تُستخدم عناصر فئة ما لأحد المتحولات الفئوية للتنبؤ بعناصر الفئة للمتحول الآخر. عندما تكون قيمة λ=1 فهذا يعني أن أحد المتحولين الفئويين يتنبأ تماماً بالمتحول الآخر، أما عندما تكون λ=0 فهذا يعني أن أحد المتحولين الفئويين لا يتنبأ بالمتحول الآخر أبداً.
- **إحصائية Kendall:** تمت مناقشة هذه الإحصائية في الفقرة 5.5.4.

4.4.16 الخرج لاختبار كاي مربع

يحوي الجدول الذي يعطيه برنامج SPSS (الخرج 1.16) عدد الحالات التي تقع في كل تركيب من الفئات، وهو يشبه جدول الأحداث المحتملة الأصلي. ونرى في هذا الجدول أن 76 قطاً يجيدون الرقص (38% من العدد الكلي) منها 28 قطاً تم تدريبها باستخدام الطعام كمكافأة (أي 36.8% من العدد الكلي للقطط التي تجيد الرقص) و 48 قطاً تم تدريبها باستخدام الحنان كمكافأة (أي 63.2% من العدد الكلي للقطط التي تجيد الرقص). أما عدد القطط التي لا تجيد الرقص فيبلغ 124 قطاً (62% من العدد الكلي) منها 10 قطط تم تدريبها باستخدام الطعام كمكافأة (أي 8.1% من العدد الكلي للقطط التي لا تجيد الرقص) و 114 قطاً تم تدريبها باستخدام الحنان كمكافأة (أي 91.9% من العدد الكلي للقطط التي تجيد الرقص). يمكن قراءة أعداد القطط من الصفوف المسماة Count أما النسب المئوية فتتم قراءتها من الصفوف المسماة Did they dance? within %. يمكننا أيضاً أن نعرف النسب المئوية ضمن فئات التدريب وذلك بالنظر إلى الصفوف المسماة % within Type of Training?. وهذا يدلنا، على سبيل المثال، على أنه من بين القطط التي تلقت الطعام كمكافأة هناك نسبة 73.7% ممن تجيد الرقص ونسبة 62.3% ممن لا تجيد الرقص. وبشكل مشابه، فمن القطط التي تلقت الحنان كمكافأة هناك نسبة 29.6% فقط ممن تجيد الرقص ونسبة 70.4% ممن لا تجيد الرقص. والخلاصة هي أنه عند استخدام الطعام كمكافأة فإن معظم القطط ستجيد الرقص، أما عند استخدام الحنان كمكافأة فإن معظم القطط سترفض الرقص.

قبل الانتقال لإحصائية الاختبار ذاتها، علينا التحقق من أن فرضية كاي مربع محققة. تنص هذه الفرضية على أنه في جدول الأحداث المحتملة ذي الأبعاد 2×2 (وهي الحالة في هذا المثال) يجب أن تكون جميع التكرارات المتوقعة أكبر من 5. إذا نظرنا إلى الأعداد المتوقعة في الصفوف المسماة Expected count فإننا نجد أن القيمة الصغرى هي 14.4 (القطط التي تلقت الطعام كمكافأة وتجيد الرقص) وهي أكبر من 5 وبالتالي فإن الفرضية محققة. لو كانت إحدى القيم المتوقعة أقل من 5 فإن أفضل علاج سيكون جمع بيانات أكثر لزيادة نسبة الحالات التي تقع في كل فئة.

Did they dance? * Type of Training Crosstabulation

			Type of Training		
			Food as Reward	Affection as Reward	Total
Did they dance?	Yes	Count	28	48	76
		Expected Count	14.4	61.6	76.0
		% within Did they dance?	36.8%	63.2%	100.0%
		% within Type of Training	73.7%	29.6%	38.0%
		% of Total	14.0%	24.0%	38.0%
	No	Count	10	114	124
		Expected Count	23.6	100.4	124.0
		% within Did they dance?	8.1%	91.9%	100.0%
		% within Type of Training	26.3%	70.4%	62.0%
		% of Total	5.0%	57.0%	62.0%
Total		Count	38	162	200
		Expected Count	38.0	162.0	200.0
		% within Did they dance?	19.0%	81.0%	100.0%
		% within Type of Training	100.0%	100.0%	100.0%
		% of Total	19.0%	81.0%	100.0%

الخرج 1.16

كما رأينا سابقاً، فإن اختبار كاي مربع لـــ Pearson يفحص فيما إذا كانت هناك علاقة بين متحولين فئويين (في هذا المثال: وجود علاقة بين نوع التدريب وفيما إذا كان القط يجيد الرقص أم لا). وكجزء من الإجرائية Crosstabs يعطي برنامج SPSS جدولاً يتضمن إحصائية كاي مربع وقيمة دلالتها مع درجات الحرية (أنظر الخرج 2.16). إذا كانت قيمة الدلالة صغيرة لحد ما (وعادة يجب أن تكون قيمة الدلالة .Sig أصغر من 0.05) فإننا نرفض الفرضية بأن المتحولات مستقلة ونقبل الفرضية بأن المتحولات مرتبطة بشكل ما. ومن الجدول نجد قيمة كاي مربع 25.356 (وهي قريبة من القيمة التي حسبناها في الفقرة 1.2.16). وهذه القيمة عالية الدلالة ($p<0.001$) مما يدل على أن لنوع التدريب المستخدم أثر هام على إمكانية الرقص عند القطط.

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)
Pearson Chi-Square	25.356[b]	1	.000		
Continuity Correction[a]	23.520	1	.000		
Likelihood Ratio	24.932	1	.000		
Fisher's Exact Test				.000	.000
Linear-by-Linear Association	25.229	1	.000		
N of Valid Cases	200				

a. Computed only for a 2x2 table

b. 0 cells (.0%) have expected count less than 5. The minimum expected count is 14.44.

الخرج 2.16

يحوي الجدول السابق مجموعة من الإحصائيات الأخرى (التي تم تحديد عدد منها باستخدام مربع الحوار في الشكل 3.16). تصحيح الاستمرارية (Continuity correction) هو قيمة كاي مربع المصححة من قبل Yates (أنظر الفقرة 3.2.16) وهي تساوي القيمة التي حسبناها سابقاً (23.52). وكما أشرنا سابقاً فربما يكون من الأفضل إهمال هذا الاختبار ولكنه يؤكد على كل حال النتيجة التي حصلنا عليها من اختبار كاي مربع الأساسي. أما نسبة الاحتمالية (Likelihood ratio) فهي الإحصائية التي تعرفنا عليها في الفقرة 2.2.16، وهي تساوي تقريباً القيمة المحسوبة سابقاً (ضمن حدود خطأ التدوير). وتؤكد هذه الإحصائية قيمة كاي مربع من الاختبار الأساسي، وهي مفضلة في حالة العينات الصغيرة.

وتحت جدول كاي مربع (Chi-square Tests) هناك بعض الحواشي السفلية المتعلقة بفرضية الأعداد المتوقعة التي يجب أن تكون أكبر من 5، فإذا نسيت هذه الفرضية فإن برنامج SPSS يذكّرك بها حيث يعطي ملخصاً لعدد الأعداد المتوقعة التي كانت أصغر من 5. وفي هذا المثال لم يكن أي من الأعداد المتوقعة أصغر من 5 ولذلك فإن إحصائية كاي مربع يجب أن تكون دقيقة.

تشير النتيجة عالية الدلالة إلى وجود علاقة بين نوع التدريب وفيما إذا كان القط سيرقص أم لا. وما نقصده بالعلاقة هو أن نمط الاستجابات (أي نسبة القطط التي ترقص إلى نسبة القطط التي لا ترقص) في حالتي التدريب المعتمد هو مختلف بشكل كبير. وتعكس هذه النتيجة الهامة حقيقةَ أنه عند استخدام الطعام كمكافأة فإن حوالي 74% من القطط تعلمت الرقص و 26% من القطط لم تتعلم الرقص، بينما في حالة استخدام الحنان كمكافأة فإن العكس هو الصحيح، إذ رفضت 70% من القطط أن ترقص بينما قامت 30% من القطط بالرقص. لذلك يمكننا أن نستنتج أن نوع التدريب المستخدم يؤثر بشكل كبير على القطط، فهي سترقص من أجل الطعام وليس من أجل الحنان.

يمكن لبرنامج SPSS أن يقدم جدولاً آخر يحوي بعض للاختبارات الإحصائية الإضافية. وتقيس معظم هذه الاختبارات قوة العلاقة بين المتحولين الفئويين. وتعتمد هذه الإحصائيات على تعديل إحصائية كاي مربع لتأخذ بعين الاعتبار حجم العينة ودرجات الحرية، وهي تحاول حصر مجال إحصائية الاختبار في المجال من 0 إلى 1 (لتصبح شبيهة بمعامل الارتباط الذي تم شرحه في الفصل 4). ويعرض الخرج 3.16 هذه الإحصائيات.

Symmetric Measures

		Value	Approx. Sig.
Nominal by Nominal	Phi	.356	.000
	Cramer's V	.356	.000
	Contingency Coefficient	.335	.000
N of Valid Cases		200	

a. Not assuming the null hypothesis.

b. Using the asymptotic standard error assuming the null hypothesis.

الخرج 3.16

- **الإحصائية Phi:** هذه الإحصائية دقيقة من أجل جداول الأحداث المحتملة ذات الأبعاد 2x2. أما من أجل الجداول الأكبر فقد لا تقع قيمة Phi في المجال بين 0 و1، ولذلك يقترح Pearson استخدام معامل الأحداث المحتملة.
- **معامل الأحداث المحتملة Contingency coefficient:** يضمن هذا المعامل أن تقع القيمة بين 0 و1 ولكنه نادراً ما يصل إلى الحد العلوي 1، ولذلك اقترح Cramer استخدام الإحصائية Cramer's V.
- **الإحصائية Cramer's V:** عندما يكون لكل من المتحولين فئتان فقط فإن Phi وCramer's V تكونان متساويتين. أما إذا كان للمتحولين أكثر من فئتين فإن إحصائية Cramer يمكن أن تصل لقيمتها العظمى 1 بخلاف الإحصائيتين الأخريين، ولذلك فهي أكثر فائدة.

من أجل هذه البيانات، تبلغ إحصائية Cramer القيمة 0.36 (من أصل القيمة العظمى الممكنة 1). ويمثل ذلك علاقة متوسطة بين نوع التدريب وفيما إذا كان القط سيرقص أم لا (وإذا نظرنا إليها كمعامل ارتباط فإنها تمثل أثراً متوسط الحجم). وهذه القيمة عالية الدلالة ($p<0.001$) مما يعني أنه من غير المرجح أن تحدث هذه القيمة لإحصائية الاختبار بمحض الصدفة، ولذلك فإن قوة العلاقة كبيرة. تؤكد هذه النتائج ما أعطانا إياه اختبار كاي مربع، ولكنها تزيد على ذلك بإعطائنا فكرة عن حجم الأثر.

5.4.16 حساب حجم الأثر

مع أن الإحصائية Cramer's V هي حجم أثر مناسب (بمعنى أنها تقع بين 0 و 1 فيسهل تفسيرها) فإن هناك مقياساً متداولاً وأكثر فائدة لقياس حجم الأثر للبيانات الفئوية هو نسبة الأرجحية (Odds ratio). ونسب الأرجحية مفيدةٌ خاصةً في جداول الأحداث المحتملة ذات البعد 2x2 لأن تفسيرها يكون واضحاً جداً. ولكن لا تعتقد أنها صارمة لهذا الحد. فقد تحدثنا في فصول GLM عن حجم الأثر وقلنا أن فائدته تكون أكبر عندما يلخص المقارنة المركّزة. وجدول الأحداث المحتملة 2x2 هو المكافئ للمقارنة المركزة في حالة البيانات الفئوية.

ويتم حساب نسبة الأرجحية ببساطة. إذا نظرنا إلى المثال الحالي فإنه يمكننا أولاً حساب الأرجحية لرقص القط عندما يتلقى الطعام كمكافأة، وهي تساوي عدد القطط التي تناولت الطعام ورقصت مقسوماً على عدد القطط التي تناولت الطعام و لم ترقص:

$$\text{Odds}_{\text{dancing after food}} = \frac{\text{number that had food and danced}}{\text{number that had food but didn't dance}}$$

$$= \frac{28}{10}$$

$$= 2.8$$

نحسب بعد ذلك الأرجحية لرقص القط عندما يتلقى الحنان كمكافأة، وهي تساوي عدد القطط التي تلقت الحنان ورقصت مقسوماً على عدد القطط التي تلقت الحنان و لم ترقص:

$$\text{Odds}_{\text{dancing after affection}} = \frac{\text{number that had affection and danced}}{\text{number that had affection but didn't dance}}$$

$$= \frac{48}{114}$$

$$= 0.421$$

وتكون نسبة الأرجحية هي أرجحية الرقص عند تناول الطعام مقسومة على أرجحية الرقص عند تلقي الحنان:

$$\text{Odds ratio} = \frac{\text{Odds}_{\text{dancing after food}}}{\text{Odds}_{\text{dancing after affection}}}$$

$$= \frac{2.8}{0.421}$$

$$= 6.65$$

وتدلنا هذه النسبة على أنه إذا تم تدريب القط باستخدام الطعام كمكافأة فإن أرجحية أن يرقص هي 6.65 مرات أكبر. وكما ترى فإنها طريقة سهلة الفهم للتعبير عن الأثر المدروس.

6.4.16 تقديم نتائج كاي مربع

عندما نقدم نتائج كاي مربع لـــ Pearson فإننا نقدم ببساطة قيمة إحصائية الاختبار مع عدد درجات الحرية المرتبطة بها وقيمة الدلالة. ويتم ترميز هذه الإحصائية بالرمز χ^2. لقد بيّن خرج البرنامج SPSS أن قيمة $\chi^2=25.36$ وعدد درجات الحرية المرتبطة بها هو 1، وأنها ذات دلالة عند مستوى $p<0.001$. ومن المفيد تقديم جدول الأحداث المحتملة ونسب الأرجحية أيضاً. ولذلك يمكن أن نكتب:

- ✓ هناك علاقة هامة بين نوع التدريب وفيما إذا كان القط سيرقص أم لا: قيمة $\chi^2(1)=25.36$، $p<0.001$. ويبدو أن ذلك يمثل الحقيقة المستندة إلى نسبة الأرجحية والتي تساوي 6.65 مرات لاحتمال أن يرقص القط إذا تمت مكافأته بالطعام بدلاً من الحنان.

أفكار مهمة

- إذا أردت اختبار العلاقة بين متحولين فئويين فيمكنك تنفيذ ذلك باستخدام اختبار كاي مربع لـ Pearson أو إحصائية نسبة الاحتمالية (Likelihood ratio).
- ابحث في الجدول المسمى Chi-square Tests عن قيمة الدلالة الدقيقة Exact Sig. فإذا كانت أقل من 0.05 في الصف المسمى Pearson chi-square فإن هناك علاقة مهمة بين المتحولين الفئويين.

- انظر إلى الحاشية السفلية للجدول السابق وتأكد من عدم وجود تكرارات متوقعة أصغر من 5.
- انظر إلى الجدول المتصالب وابحث عن العلاقة بين المتحولين، أو احسب نسبة الأرجحية.
- لتقديم النتائج، اكتب قيمة الإحصائية χ^2 وعدد درجات الحرية المرتبطة بها وقيمة دلالتها. عليك أيضاً تقديم جدول الأحداث المحتملة.

5.16 عدة متحولات فئوية: التحليل الخطي اللوغاريتمي

تعرفنا في القسم السابق من هذا الفصل على الحالة التي تحوي متحولين فئويين فقط. ولكننا غالباً ما نرغب بتحليل جداول الأحداث المحتملة الأكثر تعقيداً والتي تحوي 3 متحولات فئوية على الأقل. فعلى سبيل المثال، ماذا يحصل إذا أخذنا المثال السابق (200 قط) وأضفنا البيانات لعينة مؤلفة من 70 كلباً؟ قد نرغب بمقارنة سلوك الكلاب والقطط. سيكون لدينا في هذه الحالة 3 متحولات: animal (قط أو كلب) وtraining (الطعام أو الحنان) وdance (يرقص أو لا يرقص). لا يمكن تحليل هذه البيانات باستخدام كاي مربع لـــ Pearson، ولذلك يتم تحليلها باستخدام تقنية تدعى التحليل الخطي اللوغاريتمي (Loglinear Analysis).

1.5.16 كاي مربع كتراجع

لنبدأ بإلقاء نظرة على كيفية التعبير عن مثال بسيط لإحصائية كاي مربع كنموذج تراجع. مع أننا نعرف ما يكفي عن اختبار كاي مربع، إلا أنه إذا أردنا أن نفهم الحالات الأكثر تعقيداً فعلينا اعتبار النموذج كنموذج خطي عام GLM (مثل التراجع). ولجميع النماذج الخطية العامة التي تعرفنا عليها في هذا الكتاب الشكل العام التالي:

$$\text{Outcome}_i = (\text{Model}_i) + \text{error}_i$$

فعلى سبيل المثال، رأينا في الفصل 5 أنه يمكن كتابة نموذج التراجع المتعدد بالشكل التالي (أنظر المعادلة (9.5)):

$$Y_i = (b_0 + b_1X_1 + \cdots + b_nX_n) + \varepsilon_i$$

وعندما تعاملنا مع ANOVA وحيد الاتجاه فإننا عدّلنا نموذج التراجع ليلائم المثال Viagra (أنظر المعادلة (2.8)):

$$\text{Libido}_i = (b_0 + b_2\text{High}_i + b_1\text{Low}_i) + \varepsilon_i$$

كما عبّرنا عن الاختبار t بطريقة مماثلة. وفي جميع الحالات تم استخدام المعادلة الأساسية ذاتها، ولكن تعقيد النموذج هو الذي يتغير فقط. ويمكننا استخدام نفس النموذج مع البيانات الفئوية

بنفس الطريقة للحصول على نموذج خطي. في المثال الحالي لدينا متحولان فئويان: training (الطعام أو الحنان) وdance (يستطيع الرقص أو لا يستطيع الرقص). ولكل من هذين المتحولين فئتان فقط ولهذا يمكننا تمثيل كل متحول فئوي بمتحول مزيف وحيد (أنظر الفقرة 1.10.5) حيث يمثل الرمز 0 إحدى الفئتين والرمز 1 الفئة الأخرى. وهكذا يمكننا ترميز المتحول الفئوي training بحيث يمثل الرمز 0 فئة الطعام والرمز 1 فئة الحنان، ويمكننا ترميز المتحول الفئوي dance بحيث يمثل الرمز 0 فئة الإجابة نعم والرمز 1 الإجابة لا (أنظر الجدول 1.16).

قد يكون هذا الوضع مألوفاً إذا عدنا إلى ANOVA العاملي (أنظر الفقرة 8.10) حيث كان لدينا متحولان تنبؤيان. وقد رأينا في تلك الحالة أنه عند وجود متحولين فإن النموذج الخطي العام يصبح (أنظر المعادلة (1.10)):

$$Outcome_i = (b_0 + b_1A_i + b_1B_i + b_3AB_i) + \varepsilon_i$$

حيث يمثل A المتحول الأول، و B المتحول الثاني، و AB التفاعل بين المتحولين. لذلك يمكننا بناء نموذج خطي باستخدام المتحولات المزيفة وهي نفس المتحولات المستخدمة في ANOVA العاملي:

$$Outcome_i = (Model_i) + error_i$$

$$Outcome_{ij} = (b_0 + b_1training_i + b_2dance_j + b_3Interaction_{ij}) + \varepsilon_{ij}$$

وبما أننا نستخدم بيانات فئوية فإن علينا استخدام لوغاريتم القيم لنجعل هذا النموذج خطياً (أنظر الفصل 6):

$$\ln(O_i) = \ln(Model_i) + \ln(error_i)$$

$$\ln(O_{ij}) = (b_0 + b_1training_i + b_2dance_j + b_3Interaction_{ij}) + \ln(\varepsilon_{ij})$$

يمكن للمتحولات training وdance وحد التفاعل Interaction أن تأخذ القيم 0 و1 وذلك حسب تركيب الفئات التي ننظر إليها (أنظر الجدول 2.16).

Training	dance	المزيف training	المزيف dance	حد التفاعل	التكرار
الطعام Food	نعم Yes	0	0	0	28
الطعام Food	لا No	0	1	0	10
الحنان Affection	نعم Yes	1	0	0	48
الحنان Affection	لا No	1	1	1	114

الجدول 2.16 مخطط الترميز لمثال القطط الراقصة

ولإيجاد ما تمثله القيم b في هذا النموذج يمكننا أن ننظر لما يحدث عندما نعوض المتحولات training وdance بقيمها 0 أو 1 كما فعلنا من أجل الاختبار t وANOVA. لنبدأ بالحالة التي تكون قيمة المتحولان المزيفان training وdance هي 0 والتي تمثل حالة القطط التي حصلت على الطعام

(Food) كمكافأة ورقصت (Yes). عندما استخدمنا هذا النوع من النماذج في الاختبار t وANOVA، كانت قيمة متحول النتيجة (Outcome) مأخوذة من البيانات المشاهدة، لقد استخدمنا قيم المتوسط للمجموعات (أنظر الفقرات 8.7 و2.2.8). أما في المتحولات الفئوية فليس للمتوسط معنى كما أننا لم نقم بقياس أي شيء على مقياس تراتبي أو على مستوى المجال، وكل ما لدينا هي قيم التكرار. لذلك نستخدم قيم التكرار المتوقعة كنتيجة. ومن أجل الحالة التي قررنا دراستها أولاً فإن قيمة التكرار هي 28 (أنظر الجدول 1.16 أو 2.16) وهكذا تصبح معادلة النموذج هي:

$$\ln(O_{F,Y}) = b_0 + b_1 \text{training}_{\text{Food}} + b_2 \text{dance}_{\text{Yes}} + b_3 \text{Interaction}_{\text{Food,Yes}}$$
$$\ln(28) = b_0 + b_1 \times 0 + b_2 \times 0 + b_3 \times 0$$
$$\ln(28) = b_0$$
$$b_0 = 3.332$$

لذلك فإن b_0 تمثل لوغاريتم القيمة المشاهدة عندما تكون قيم جميع الفئات مساوية للصفر. وهكذا فإن b_0 هي لوغاريتم القيمة المشاهدة للفئة المرجعية (في هذا المثال حالة القطط التي حصلت على الطعام ورقصت).

لنأخذ الآن حالة القطط التي تلقت الحنان ورقصت. في هذه الحالة تكون قيمة المتحول training هي 1 وقيمة المتحول dance هي 0 ويبقى حد التفاعل مساوياً 0، أما النتيجة فهي القيمة المشاهدة للتكرار وتساوي 48. ولذلك تصبح معادلة النموذج بالشكل:

$$\ln(O_{A,Y}) = b_0 + b_1 \text{training}_{\text{Affection}} + b_2 \text{dance}_{\text{Yes}} + b_3 \text{Interaction}_{\text{Affection,Yes}}$$
$$\ln(O_{A,Y}) = b_0 + b_1 \times 1 + b_2 \times 0 + b_3 \times 0$$
$$\ln(O_{A,Y}) = \ln(O_{F,Y}) + b_1$$
$$b_1 = \ln(O_{A,Y}) - \ln(O_{F,Y})$$
$$= \ln(48) - \ln(28)$$
$$= 3.871 - 3.332$$
$$= 0.539$$

نلاحظ أن b_1 تمثل الفرق بين لوغاريتم التكرار المشاهد للقطط التي تلقت الحنان ورقصت ولوغاريتم التكرار المشاهد للقطط التي تلقت على الطعام ورقصت. بمعنى آخر، ضمن مجموعة القطط التي رقصت فإن b_1 يمثل الفرق بين القطط التي تدربت بتلقي الحنان والقطط التي تلقت الطعام.

لنأخذ الآن حالة القطط التي تلقت الطعام ولم ترقص. في هذه الحالة تكون قيمة المتحول training هي 0 وقيمة المتحول dance هي 1 ويبقى حد التفاعل مساوياً 0، أما النتيجة فهي القيمة المشاهدة للتكرار وتساوي 10. ولذلك تصبح معادلة النموذج بالشكل:

$$\ln(O_{F,N}) = b_0 + b_1 training_{Food} + b_2 dance_{No} + b_3 Interaction_{Food,No}$$
$$\ln(O_{F,N}) = b_0 + b_1 \times 0 + b_2 \times 1 + b_3 \times 0$$
$$\ln(O_{F,N}) = \ln(O_{F,Y}) + b_2$$
$$b_2 = \ln(O_{F,N}) - \ln(O_{F,Y})$$
$$= \ln(10) - \ln(28)$$
$$= 2.303 - 3.332$$
$$= 1.029$$

نلاحظ أن b_2 تمثل الفرق بين لوغاريتم التكرار المشاهد للقطط التي تلقت الطعام و لم ترقص ولوغاريتم التكرار المشاهد للقطط التي تلقت على الطعام ورقصت. بمعنى آخر، ضمن مجموعة القطط التي تلقت الطعام فإن b_2 يمثل الفرق بين القطط التي رقصت والقطط التي لم ترقص.

لنأخذ الآن حالة القطط التي تلقت الحنان و لم ترقص. في هذه الحالة تكون قيمة المتحول training هي 1 وقيمة المتحول dance هي 1 ويكون حد التفاعل مساوياً 1، أما النتيجة فهي القيمة المشاهدة للتكرار وتساوي 114. ولذلك تصبح معادلة النموذج بالشكل:

$$\ln(O_{A,N}) = b_0 + b_1 training_{Affection} + b_2 dance_{No} + b_3 Interaction_{Affection,No}$$
$$\ln(O_{F,N}) = b_0 + b_1 \times 1 + b_2 \times 1 + b_3 \times 1$$
$$\ln(O_{A,N}) = \ln(O_{F,Y}) + [\ln(O_{A,Y}) \quad \ln(O_{F,Y})] + [\ln(O_{F,N}) - \ln(O_{F,Y})] + b_3$$
$$b_3 = \ln(O_{A,N}) - \ln(O_{F,N}) + \ln(O_{F,Y}) - \ln(O_{A,Y})$$
$$= \ln(114) - \ln(10) + \ln(28) - \ln(48)$$
$$= 1.895$$

لذلك فإن b_3 تقارن الفرق بين الحنان والطعام عندما لا تستطيع القطط الرقص مع الفرق بين الطعام والحنان عندما تستطيع القطط الرقص. بمعنى آخر، إن b_3 تقارن أثر التدريب عندما لا ترقص القطط مع أثر التدريب عندما ترقص القطط.

ويأخذ النموذج الشكل النهائي التالي:

$$\ln(O_{ij}) = (3.332 + 0.539 training_i - 1.029 dance_j + 1.895 Interaction_{ij}) + \ln(\varepsilon_{ij})$$

إن أهم ما يجب ملاحظته هنا هو أن كل شيء يماثل ANOVA العاملي باستثناء أننا نتعامل مع لوغاريتمات القيم المحوَّلة (قارن هذه الفقرة مع الفقرة 8.10 للتأكد من ذلك). وإذا كنت غير مقتنع بأن النموذج هو نموذج خطي عام (GLM) فيمكنك العودة للملف CatRegression.sav الذي يحوي متحولين مزيفين هما dance وtraining وحد التفاعل int إضافة للمتحول observed الذي يمثل قيم التكرار المشاهدة (الموجودة في الجدول 1.16) لكل تركيب من المتحولين dance وtraining. كما يحوي هذا الملف المتحول lno الذي يمثل اللوغاريتم الطبيعي لقيم التكرار

المشاهدة. وللتحقق ينبغي عليك تنفيذ التراجع المتعدد على البيانات في هذا الملف باستخدام المتحول lno كنتيجة، والمتحولات training وdance وint كمتحولات تنبؤية. يعرض الخرج 4.16 جدول المعاملات الناتج عن هذا التراجع. وأهم شيء يجب ملاحظته قيمة الحد الثابت b_0 التي تساوي 3.332 كما حسبناها سابقاً، وقيمة بيتا لنوع التدريب b_1 وهي 0.539، وللرقص b_2 وهي 1.030-، وجميع هذه القيم مطابقة لما حسبناه سابقاً ضمن أخطاء التدوير. وكذلك فإن معامل التفاعل b_3 هو 1.895. هناك نقطة هامة وهي أن جميع الأخطاء القياسية تساوي 0، أو بمعنى آخر ليس هناك أي خطأ في هذا النموذج. وذلك لأن التراكيب المختلفة لمتحولات الترميز تفسر بشكل كامل القيم المشاهدة. يُعرف هذا النموذج بالنموذج المشبع (Saturated model) وسنعود لهذه النقطة لاحقاً. وكل ما نأمله في هذه المرحلة إقناع القارئ بأنه يمكن التعبير عن كاي مربع بنموذج خطي.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients		
		B	Std. Error	Beta	t	Sig.
1	(Constant)	3.332	.000		6.3E+08	.000
	Type of Training	.539	.000	.307	8.1E+07	.000
	Did they dance?	-1.030	.000	-.725	-1.0E+08	.000
	Interaction	1.895	.000	1.361	1.7E+08	.000

a. Dependent Variable: LN (Observed values)

الخرج 4.16

يبحث اختبار كاي مربع بشكل أساسي فيما إذا كان متحولان ما مستقلين، ولذلك لا فائدة من الأثر المركب لهذين المتحولين، فما يهمنا هو الأثر الفريد لكل منهما. لذلك يمكننا التعبير عن كاي مربع من حيث المبدأ كنموذج مشبع باستثناء أننا لا نضع حد التفاعل. إذا حذفنا حد التفاعل من النموذج فإن معادلته تصبح:

$$\ln(Model_{ij}) = b_0 + b_1 training_i + b_2 dance_j$$

وفي هذا النموذج الجديد لا يمكننا التنبؤ بالقيم المشاهدة كما فعلنا في حالة النموذج المشبع وذلك لأننا فقدنا بعض المعلومات (ونعني حد التفاعل). ولذلك فإن النتيجة من هذا النموذج تتغير وكذلك فإن قيم بيتا تتغير. وقد رأينا سابقاً أن اختبار كاي مربع يعتمد على التكرارات المتوقعة. ولذلك إذا نظرنا لاختبار كاي مربع على أنه نموذج خطي فإن النتائج هي تلك القيم المتوقعة. إذا عدنا لبداية هذا الفصل نجد أننا حسبنا التكرارات المتوقعة بناءً على هذا النموذج. يمكننا إعادة حساب قيم بيتا اعتماداً على هذه القيم المتوقعة:

$$\ln(E_{ij}) = b_0 + b_1 training_i + b_2 dance_j$$

فمن أجل القطط التي حصلت على الطعام كمكافأة ورقصت تكون قيم المتحولين training وdance هي 0، وتأخذ المعادلة الشكل التالي:

$$\ln(E_{F,Y}) = b_0 + b_1 \text{training}_{\text{Food}} + b_2 \text{dance}_{\text{Yes}}$$
$$\ln(14.44) = b_0 + b_1 \times 0 + b_2 \times 0$$
$$\ln(14.44) = b_0$$
$$b_0 = 2.67$$

لذلك فإن b_0 في النموذج تمثل لوغاريتم القيمة المتوقعة عندما تكون قيم جميع الفئات مساوية للصفر.

عندما نأخذ حالة القطط التي تلقت الحنان ورقصت فإن قيمة المتحول training هي 1 وقيمة المتحول dance هي 0. وتتغير النتيجة لتصبح القيمة المتوقعة للتكرار وهي 61.56. ولذلك تصبح معادلة النموذج بالشكل:

$$\ln(E_{A,Y}) = b_0 + b_1 \text{training}_{\text{Affection}} + b_2 \text{dance}_{\text{Yes}}$$
$$\ln(E_{A,Y}) = b_0 + b_1 \times 1 + b_2 \times 0$$
$$\ln(E_{A,Y}) = b_0 + b_1$$
$$b_1 = \ln(E_{A,Y}) - \ln(E_{F,Y})$$
$$= \ln(61.56) - \ln(14.44)$$
$$= 1.45$$

وأهم ما يجب ملاحظته أن b_1 تمثل الفرق بين لوغاريتم التكرار المتوقع للقطط التي تلقت الحنان ورقصت ولوغاريتم التكرار المتوقع للقطط التي تلقت على الطعام ورقصت.

لنأخذ الآن حالة القطط التي تلقت الطعام و لم ترقص. في هذه الحالة تكون قيمة المتحول training هي 0 وقيمة المتحول dance هي 1 وتتغير النتيجة لتصبح القيمة المتوقعة للتكرار وتساوي 23.56. ولذلك تصبح معادلة النموذج بالشكل:

$$\ln(E_{F,N}) = b_0 + b_1 \text{training}_{\text{Food}} + b_2 \text{dance}_{\text{No}}$$
$$\ln(E_{F,N}) = b_0 + b_1 \times 0 + b_2 \times 1$$
$$\ln(E_{F,N}) = \ln(E_{F,Y}) + b_2$$
$$b_2 = \ln(E_{F,N}) - \ln(E_{F,Y})$$
$$= \ln(23.56) - \ln(14.44)$$
$$= 0.49$$

نلاحظ أن b_2 تمثل الفرق بين لوغاريتم التكرار المتوقع للقطط التي تلقت الطعام و لم ترقص ولوغاريتم التكرار المتوقع للقطط التي تلقت على الطعام ورقصت.

يمكننا أن نجري تحققاً مضاعفاً لهذه النتائج بالنظر إلى الخلية الأخيرة:

$$\ln(E_{A,N}) = b_0 + b_1 \text{training}_{\text{Affection}} + b_2 \text{dance}_{\text{No}}$$

$$\ln(E_{A,N}) = b_0 + b_1 \times 1 + b_2 \times 1$$

$$\ln(E_{A,N}) = b_0 + b_1 + b_2$$

$$\ln(100.44) = 2.67 + 1.45 + 0.49$$

$$4.61 = 4.61$$

ولذلك يكون نموذج كاي مربع النهائي هو:

$$\ln(O_{ij}) = \text{Model}_{ij} + \ln(\varepsilon_{ij})$$

$$\ln(O_{ij}) = 2.67 + 1.45 \cdot \text{training}_i + 0.49 \cdot \text{dance}_j + \ln(\varepsilon_{ij})$$

يمكننا إعادة ترتيب هذه المعادلة لنحصل على حد الخطأ (البواقي):

$$\ln(\varepsilon_{ij}) = \ln(O_{ij}) - \text{Model}_{ij}$$

في هذه الحالة، النموذج هو التكرارات المتوقعة التي تم حسابها من أجل اختبار كاي مربع، ولذلك فالبواقي هي الفروق بين التكرارات المشاهدة و التكرارات المتوقعة.

يوضح ذلك آلية عمل كاي مربع كنموذج خطي مثل التراجع وANOVA، حيث تدلنا قيم بيتا عن الفروق النسبية في التكرارات عبر فئات المتحولين الفئويين. يمكن التعبير عن الفئات لمتحول ما باستخدام المتحولات المزيفة (كما فعلنا في حالة التراجع وANOVA) وحساب قيم بيتا الناتجة بنفس الطريقة المتبعة في التراجع و ANOVA. في ANOVA تمثل قيم بيتا الفرق بين قيم المتوسط لفئة معينة مقارنة مع فئة مرجعية. أما في البيانات الفئوية فإن قيم بيتا تمثل نفس الشيء، والفرق الوحيد هو أننا نتعامل مع القيم المتوقعة بدلاً من قيم المتوسط. إن فهم هذه الفكرة (وهي أن التراجع واختبارات t وANOVA وتحليل البيانات الفئوية هي متماثلة من حيث الجوهر) يساعدنا كثيراً في الفقرة التالية.

2.5.16 التحليل الخطي اللوغاريتمي

رأينا في الفقرة السابقة أنه يمكن التعبير عن البيانات الفئوية بشكل نموذج خطي بشرط أن نستخدم لوغاريتم القيم (ومن هنا جاءت تسمية هذه التقنية بالتحليل الخطي اللوغاريتمي Loglinear analysis). ومما تعلمناه عن ANOVA والنماذج الخطية عموماً فإنه يمكننا أن نقول بأنه يمكننا توسيع أي نموذج خطي ليشمل أي عدد من المتحولات التنبؤية وحدود التفاعل الناتجة بين تلك المتحولات. ولذلك إذا أمكننا تمثيل تحليل فئوي بسيط لمتحولين بشكل نموذج خطي فإنه يمكننا توسيع النموذج البسيط ليشمل عدداً أكبر من المتحولات التنبؤية وحدود التفاعل بينها. لذلك وكما في حالة التراجع المتعدد وANOVA، فإننا إذا نظرنا للأشياء كنموذج خطي فإن توسيع النموذج ليشمل متحولات جديدة يصبح أسهل للفهم. فعلى سبيل المثال، إذا كان لدينا 3 متحولات تنبؤية (A وB وC) في ANOVA (يمكنك العودة للفقرة 3.12) فإننا نصل إلى 3 تفاعلات ثنائية الاتجاه (AB وAC وBC)

وتفاعل واحد ثلاثي الاتجاه (ABC). ولذلك يمكن كتابة النموذج الخطي الناتج بالشكل التالي:

$$Outcome_i = (b_0 + b_1A + b_2B + b_3C + b_4AB + b_5AC + b_6BC + b_7ABC) + \varepsilon_i$$

وبنفس الطريقة تماماً، إذا كان لدينا 3 متحولات في تحليل البيانات الفئوية فإننا نحصل على نموذج مماثل، ولكن بشرط التعبير عن النتيجة بشكل لوغاريتمي:

$$\ln(O_{ij}) = (b_0 + b_1A_i + b_2B_j + b_3C_k + b_4AB_{ij} + b_5AC_{ik} + b_6BC_{jk} + b_7ABC_{ijk}) + \ln(\varepsilon_{ijk})$$

إن حساب قيم بيتا والقيم المتوقعة من النموذج يصبح معقداً جداً ومربكاً، ولكن لا داعي للقلق من موضوع الحسابات إذ أن الحواسب موجودة لهذه الغاية. يعمل التحليل الخطي اللوغاريتمي على هذه المبادئ. وكما رأينا في حالة متحولين فقط، إذا كانت البيانات فئوية ووضعنا جميع الحدود الممكنة (الآثار الرئيسية وحدود التفاعل) فإن الخطأ يكون معدوماً، أي أن المتحولات التنبؤية تتوقع النتيجة بشكل تام (القيم المتوقعة). لذلك إذا بدأنا بالنموذج المعقد فإننا لن نحصل على أي خطأ. إن مهمة التحليل الخطي اللوغاريتمي هي محاولة إيجاد أبسط نموذج لملاءمة البيانات دون فقدان كبير للقدرة التوقعية. ولهذا فإن التحليل الخطي اللوغاريتمي يعمل على مبدأ الحذف التراجعي (نعم، نفس نوع الحذف المستخدم في التراجع المتعدد، أنظر الفقرة 3.3.5.5). ولهذا نبدأ بالنموذج المشبع ثم نحذف أحد المتحولات التنبؤية من النموذج ونستخدم النموذج الجديد للتنبؤ بالبيانات (حساب التكرارات المتوقعة كما في الاختبار كاي مربع) ثم نحسب جودة التوافق للنموذج مع البيانات (هل التكرارات المتوقعة قريبة من التكرارات المشاهدة؟). إذا كان تلاؤم النموذج الجديد غير مختلف بشكل كبير عن النموذج المعقد فإننا نهمل النموذج المعقد لصالح النموذج الجديد. بمعنى آخر، نفترض أن الحد الذي تم حذفه لم يكن ذا أثر كبير على قدرة النموذج التنبؤية بالقيم المشاهدة.

على كل حال، يقوم التحليل الخطي اللوغاريتمي بحذف الحدود بشكل هرمي وليس بشكل عشوائي. لذلك نبدأ بالنموذج المشبع ثم نحذف حد التفاعل ذا المرتبة الأعلى، ونقيّم أثر ذلك الحذف. إذا كان حذف حد التفاعل عديم الأثر على النموذج فإنه يمكننا التخلص من ذلك الحد والانتقال إلى حذف حدود التفاعل الأدنى مرتبة. وإذا كان حذف هذه الحدود عديم الأثر فإننا ننتقل إلى الآثار الرئيسية حتى نصل إلى أثر يؤثر على ملاءمة النموذج للبيانات.

ولكي نضع ذلك بشكل ملموس، نعود إلى المثال المقترح في بداية الفقرة 5.16 الذي يتضمن توسيع مثال تدريب القطط ليشمل عينة من الكلاب أيضاً. لدينا الآن 3 متحولات فئوية: animal (قط أو كلب) وtraining (طعام أو حنان) وdance (نعم أو لا). وكما في ANOVA فإننا نحصل على 3 آثار رئيسية، و3 حدود تفاعل يشمل كل منها متحولين فقط، وحد تفاعل واحد يشمل المتحولات الثلاثة. ولذلك نحصل على الآثار التالية: animal وtraining وdance وanimal×training وanimal×dance وtraining×dance وanimal×training×dance. عندما تحدثنا عن الحذف التراجعي كنت نقصد أن التحليل الخطي اللوغاريتمي يبدأ بتضمين جميع هذه الآثار، ثم يحذف حد التفاعل من المرتبة الأعلى (وفي هذا المثال حد التفاعل ثلاثي الاتجاه animal×training×dance)،

فينتج نموذج جديد بدون ذلك الحد، ويحسب منه التكرارات المتوقعة. يقارن بعد ذلك هذه التكرارات المتوقعة (أو تكرارات النموذج) مع التكرارات المشاهدة باستخدام المعادلة القياسية لإحصائية نسبة الاحتمالية (أنظر الفقرة 2.2.16). إذا غيّر النموذج الجديد إحصائية نسبة الاحتمالية بشكل كبير فإن لحذف ذلك الحد أثر كبير على تلاؤم النموذج، ونعلم أن ذلك الأثر هام إحصائياً. إذا كانت هذه هي الحالة الناتجة فإن برنامج SPSS يتوقف هنا ويخبرنا بوجود تفاعل ثلاثي الاتجاه ذي دلالة، ولن يختبر أي آثار أخرى لأن جميع الآثار من المرتبة الأدنى يتم استخدامها ضمن الآثار من المرتبة الأعلى. إذا لم يكن لحذف التفاعل من المرتبة الأعلى (التفاعل ثلاثي الاتجاه) أثر مهم على تلاؤم النموذج فإن برنامج SPSS ينتقل إلى التفاعلات من المرتبة الأدنى. ولذلك ينظر إلى التفاعلات animal×training وanimal×dance وtraining×dance بالتتالي ويبني النماذج التي لا تحوي هذه الحدود. ومن أجل كل نموذج، يقوم بحساب القيمة المتوقعة ويقارنها مع القيم المشاهدة باستخدام نسبة الاحتمالية. ومرة أخرى، إذا أعطى أحد هذه النماذج تغيّراً كبيراً في نسبة الاحتمالية فإن برنامج SPSS يحتفظ بالتفاعل الذي حاول حذفه ولا ينتقل للنظر إلى أي أثر رئيسي متضمن في ذلك التفاعل (فإذا كان التفاعل animal×training مهماً فإنه لن ينظر إلى الآثار الرئيسية لكل من animal وtraining). أما إذا لم تتغير نسبة الاحتمالية فإن التحليل يحذف حد التفاعل المعني ثم ينتقل إلى الآثار الرئيسية.

ذكرنا سابقاً أننا نستخدم إحصائية الاحتمالية (أنظر الفقرة 2.2.16) لتقييم كل نموذج. ومن المعادلة يجب أن يكون واضحاً أن هذه المعادلة تتلاءم لتناسب أي نموذج، فالقيم المشاهدة هي ذاتها، وتكرارات النموذج هي ببساطة التكرارات المتوقعة من النموذج الذي تم اختباره. فمن أجل النموذج المشبع تكون قيمة الإحصائية 0 دائماً (لأن التكرارات المشاهدة وتكرارات النموذج متساوية ولذلك فإن نسبة التكرارات المشاهدة إلى تكرارات النموذج تساوي 1 وبالتالي 0=(1)ln)، ولكن كما رأينا فإنها توفر في الحالات الأخرى مقياساً لجودة توافق النموذج مع التكرارات المشاهدة. ولاختبار فيما إذا غيّر النموذج الجديد نسبة الاحتمالية فإن كل ما نحتاجه هو حساب الفرق بين نسبتي الاحتمالية للنموذج الحالي وللنموذج السابق (بشرط أن تكون النماذج مبنية بشكل هرمي):

$$L\chi^2_{Change} = L\chi^2_{Current\ Model} - L\chi^2_{Previous\ Model}$$

لقد حاولنا في هذه الفقرة إعطاء فكرة عن عمل التحليل الخطي اللوغاريتمي دون الدخول في تفاصيل الحسابات. وسننتقل الآن لتلقي نظرة على كيفية تنفيذ التحليل الخطي اللوغاريتمي.

6.16 الفرضيات في التحليل الخطي اللوغاريتمي

يعتبر التحليل الخطي اللوغاريتمي توسيعاً لاختبار كاي مربع ولذلك فإن له فرضيات مشابهة، فأي كيان يجب أن يقع ضمن خلية واحدة فقط من جدول الأحداث المحتملة (أي يجب أن تكون خلايا

الجدول مستقلة)، ويجب أن تكون التكرارات المتوقعة كبيرة لحد كاف لكي يكون التحليل موثوقاً. وفي التحليل الخطي اللوغاريتمي لأكثر من متحولين، من الممكن وجود نسبة تصل إلى 20% من الخلايا لا تزيد فيها التكرارات المتوقعة على 5، بشرط أن تكون التكرارات المتوقعة في جميع الخلايا أكبر من 1. إذا انهارت هذه الفرضية فإن النتيجة ستكون انخفاضاً كبيراً في قدرة الاختبار، ومن الأفضل في هذه الحالة عدم إضاعة الوقت بهذا التحليل. ويمكن معالجة هذه المشاكل بإحدى الطرق التالية: (1) تقويض البيانات عبر أحد المتحولات (ويفضل أن يكون المتحول الأقل توقعاً لأن يكون صاحب أثر ما)، (2) تقويض المستويات لأحد المتحولات، (3) جمع بيانات أكثر، (4) القبول بفقدان القدرة.

إذا أردت تقويض البيانات عبر أحد المتحولات فيجب أن تأخذ الأمور التالية بعين الاعتبار:

- يجب أن يكون التفاعل من المرتبة الأعلى عديم الأهمية.
- يجب أن يكون أحد حدود التفاعل من المرتبة الأدنى التي تحوي المتحول الذي سيتم حذفه عديم الأهمية أيضاً.

لنأخذ المثال الحالي ولنفترض أننا نريد حذف المتحول animal. لكي يكون ذلك ممكناً يجب أن يكون حد التفاعل animal×training×dance عديم الأهمية، وأحد التفاعلين animal×training أو animal×dance عديم الأهمية أيضاً. يمكن أيضاً تقويض الفئات ضمن أحد المتحولات.

وأخيراً، يتغلب بعض الأشخاص على هذه المشكلة بإضافة حد ثابت إلى جميع الخلايا في الجدول، ولكن ليس هناك ما يدل على أن هذه الطريقة تصحح مشكلة القدرة.

7.16 تنفيذ التحليل الخطي اللوغاريتمي في برنامج SPSS

1.7.16 الاعتبارات الأولية

يتم إدخال البيانات من أجل التحليل الخطي اللوغاريتمي بنفس طريقة إدخال البيانات من أجل الاختبار كاي مربع (أنظر الفقرة 1.4.16 و2.4.16). يحوي الملف CatsandDogs.sav بيانات المثال الحالي. افتح الملف ولاحظ وجود ثلاثة متحولات (animal وtraining وdance) يحوي كل منها رموزاً تمثل الفئات المختلفة لهذه المتحولات. ونبدأ باستخدام الوظيفة crosstabs للحصول على جدول الأحداث المحتملة لهذه البيانات. يمكنك العودة للفقرة 3.4.16 لتنفيذ هذه المهمة. يبين الشكل 4.16 الشكل النهائي لمربع الحوار الرئيسي.

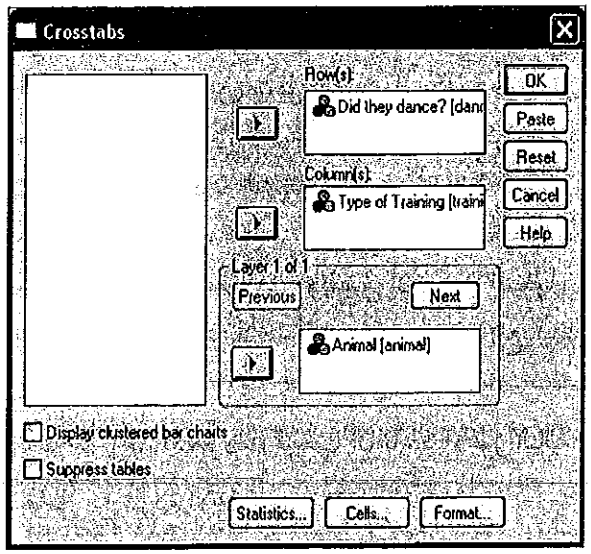

الشكل 4.16 الشكل النهائي لمربع الحوار الرئيسي

يعرض الخرج 5.16 الجدول المتصالب الذي يعطيه برنامج SPSS، ويحوي عدد الحالات التي تقع في كل تركيب من الفئات. إن القسم العلوي من هذا الجدول مماثل للخرج 1.16 لأن البيانات فيهما متماثلة. أما القسم السفلي فيحوي البيانات الخاصة بالكلاب والتي يمكن تلخيصها بطريقة مشابهة. يبلغ العدد الكلي للكلاب التي رقصت 49 (70% من العدد الكلي للكلاب) منها 20 كلباً تم تدريبها باستخدام الطعام كمكافأة (أي 40.8% من العدد الكلي للكلاب التي تجيد الرقص) و29 كلباً تم تدريبها باستخدام الحنان كمكافأة (أي 59.2% من العدد الكلي للكلاب التي تجيد الرقص). أما عدد الكلاب التي لا تجيد الرقص فيبلغ 21 (30% من العدد الكلي للكلاب) منها 14 كلباً تم تدريبها باستخدام الطعام كمكافأة (أي 66.7% من العدد الكلي للكلاب التي لا تجيد الرقص) و7 كلاب تم تدريبها باستخدام الحنان كمكافأة (أي 33.3% من العدد الكلي للكلاب التي تجيد الرقص). يمكن قراءة أعداد الكلاب من الصفوف المسماة Count أما النسب المئوية فتتم قراءتها من الصفوف المسماة within Did they dance? %. والخلاصة أن نسبة الكلاب التي رقصت (70%) أعلى من نسبة الكلاب التي لم ترقص (30%). وحوالي نصف الكلاب التي رقصت قد تمت مكافأتها بالحنان، والنصف الآخر بالطعام. وهكذا يبدو أن الكلاب مستعدة للرقص أكثر من القطط (70% مقارنة مع 38%) وأنها لا تهتم بنوع التدريب المعتمد.

قبل الانتقال لإحصائية الاختبار ذاتها، علينا التحقق من أن فرضيات التحليل الخطي اللوغاريتمي محققة، وخاصة أن لا تكون أي من القيم المتوقعة أقل من 1، وأن لا تزيد نسبة الأعداد المتوقعة التي تقل عن 5 على 20%. إذا نظرنا إلى الأعداد المتوقعة في الصفوف المسماة Expected count فإننا نجد أن القيمة الصغرى هي 10.2 (الكلاب التي تلقت الطعام كمكافأة و لم ترقص) وهي أكبر من 5 وبالتالي فإن الفرضية محققة.

Did they dance? * Type of Training * Animal Crosstabulation

Animal				Type of Training: Food as Reward	Type of Training: Affection as Reward	Total
Cat	Did they dance?	Yes	Count	28	48	76
			Expected Count	14.4	61.6	76.0
			% within Did they dance?	36.8%	63.2%	100.0%
			% within Type of Training	73.7%	29.6%	38.0%
			% of Total	14.0%	24.0%	38.0%
		No	Count	10	114	124
			Expected Count	23.6	100.4	124.0
			% within Did they dance?	8.1%	91.9%	100.0%
			% within Type of Training	26.3%	70.4%	62.0%
			% of Total	5.0%	57.0%	62.0%
	Total		Count	38	162	200
			Expected Count	38.0	162.0	200.0
			% within Did they dance?	19.0%	81.0%	100.0%
			% within Type of Training	100.0%	100.0%	100.0%
			% of Total	19.0%	81.0%	100.0%
Dog	Did they dance?	Yes	Count	20	29	49
			Expected Count	23.8	25.2	49.0
			% within Did they dance?	40.8%	59.2%	100.0%
			% within Type of Training	58.8%	80.6%	70.0%
			% of Total	28.6%	41.4%	70.0%
		No	Count	14	7	21
			Expected Count	10.2	10.8	21.0
			% within Did they dance?	66.7%	33.3%	100.0%
			% within Type of Training	41.2%	19.4%	30.0%
			% of Total	20.0%	10.0%	30.0%
	Total		Count	34	36	70
			Expected Count	34.0	36.0	70.0
			% within Did they dance?	48.6%	51.4%	100.0%
			% within Type of Training	100.0%	100.0%	100.0%
			% of Total	48.6%	51.4%	100.0%

الخرج 5.16

2.7.16 التحليل الخطي اللوغاريتمي

بعد أن تحققنا من أن فرضية الاختبار محققة يمكننا أن ننتقل إلى التحليل الأساسي. إن أفضل طريقة لتنفيذ التحليل الخطي اللوغاريتمي هي استخدام أمر القائمة Analyze ⇒ Loglinear Statistics ⇒ Model Selection... للوصول إلى مربع الحوار الرئيسي المبين في الشكل 5.16. نختار المتحول الذي نريد تضمينه في التحليل وننقله إلى الحيز المسمى Factor(s). عند وجود متحول ما في هذا الحيز يصبح الزر Define Range... نشطاً. وكما في الاختبار t وعدد من الاختبارات اللابارامترية التي صادفناها في الفصل 13 علينا أن نرشد برنامج SPSS إلى الرموز التي استخدمناها لتعريف المتحولات الفئوية. نختار أحد المتحولات في الحيز Factor(s) وننقر الزر Define Range... لفتح مربع الحوار الذي يسمح بتحديد الرموز الدنيا والعظمى التي استخدمناها لذلك المتحول. في هذا المثال لدينا 3 متحولات لها نفس الرموز (لكل متحول فئتان فقط ولذلك فإن الرموز هي 0 و1) ولهذا نختار المتحولات الثلاثة وننقر الزر Define Range... ونكتب القيمة 0 في الحيز Minimum

والقيمة 1 في الحيز Maximum. عند الانتهاء من تعريف الرموز ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي.

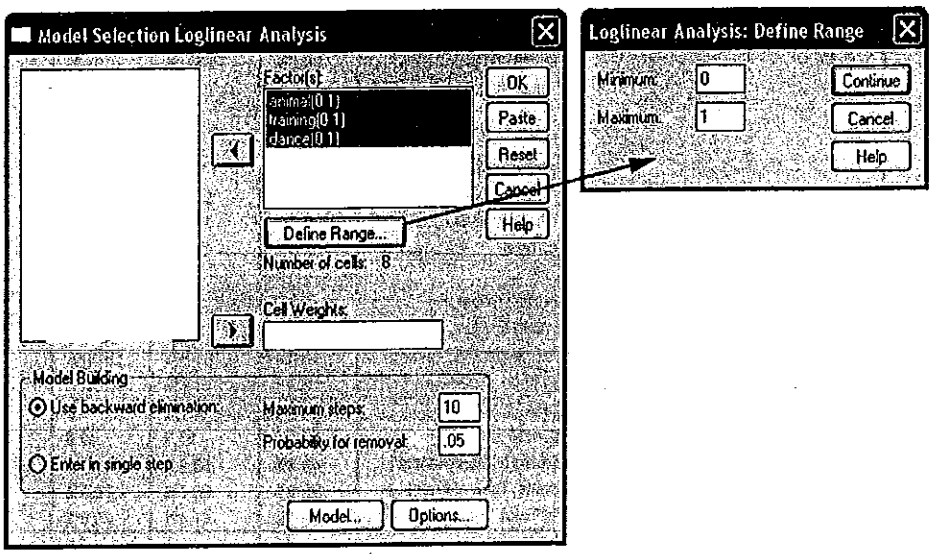

الشكل 5.16 مربع الحوار الرئيسي للتحليل الخطي اللوغاريتمي

إن الخيارات الافتراضية في مربع الحوار الرئيسي هي رائعة، والشيء الرئيسي الذي يجب ملاحظته هو أن الخيار الافتراضي لطريقة بناء النموذج هو استخدام الحذف التراجعي (Backward elimination). ويمكنك اختيار طريقة مختلفة هي Enter in single step وهي طريقة لاهرمية يتم فيها إدخال جميع الآثار وتقييمها كما في طريقة الإدخال القسري في التراجع المتعدد. في التحليل الخطي اللوغاريتمي تحظى الآثار المركبة بأولوية على الآثار من المرتبة الأدنى ولذلك لا ننصح باستخدام الطرق اللاهرمية.

إذا نقرنا الزر ...Model فإنه يفتح مربع حوار مشابه تماماً لتلك التي رأيناها في ANOVA (أنظر الشكل 2.10). بشكل افتراضي يقوم برنامج SPSS باستخدام النموذج المشبع، ولكن يمكنك تعريف النموذج الخاص بك وذلك بتحديد الآثار الرئيسية المنفصلة وحدود التفاعل. وما لم تكن لديك أسباب قوية جداً لعدم استخدام النموذج المشبع فيمكنك إبقاء كل شيء عاى حاله!

عند نقر الزر ...Options يفتح مربع الحوار المبين في الشكل 6.16. هناك عدة خيارات يمكن التلاعب بها (ولكن الخيارات الافتراضية ممتازة). الخياران الوحيدان اللذان يمكن اختيارهما: الخيار Parameter estimates الذي يعطي جدول تقديرات البارامتر لكل أثر (ونقصد بها العلامة المعيارية ومجال الثقة المرتبط بها)، والخيار Association table الذي يعطي إحصائية كاي مربع لجميع الآثار في النموذج. ويمكن أن يكون ذلك مفيداً في بعض الحالات، ولكن كما قلنا سابقاً،

إذا كانت التفاعلات من المراتب العليا مهمة فلا ينبغي الاهتمام بالآثار من المراتب الدنيا. وعندما ننتهي من ضبط الخيارات ننقر الزر Continue للعودة إلى مربع الحوار الرئيسي، ثم ننقر الزر OK لتنفيذ التحليل.

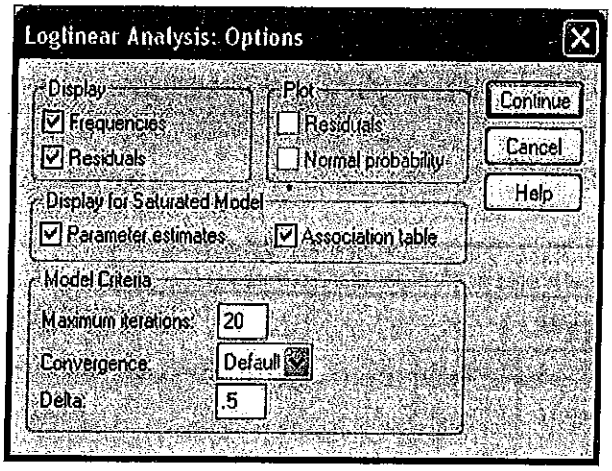

الشكل 6.16 خيارات التحليل الخطي اللوغاريتمي

8.16 الخرج من التحليل الخطي اللوغاريتمي

يعرض الخرج 6.16 الخرج الأولي من التحليل الخطي اللوغاريتمي. ويبدأ بالإشارة إلى وجود 270 حالة (تذكّر أن عدد القطط يساوي 200 وعدد الكلاب يساوي 70). يعرض البرنامج بعد ذلك جميع العوامل في النموذج وعدد المستويات في كل منها (في هذا المثال لدينا مستويان لكل عامل). ويبدأ البرنامج بملاءمة النموذج المشبع (الذي يحوي جميع الحدود بما فيها التفاعل من المرتبة الأعلى animal×training×dance). ثم يعطي الأعداد المشاهدة والمتوقعة لكل من تراكيب الفئات في هذا النموذج. ويجب أن تكون هذه القيم مماثلة لجدول الأحداث المحتملة الأصلي باستثناء أنه تمت إضافة 0.5 لكل خلية (وهذه القيمة الافتراضية مناسبة جداً، ولكن إذا أردت تغييرها فيمكنك ذلك بتعديل القيمة Delta في مربع الحوار المبين في الشكل 6.16). والجزء الأخير من هذا الخرج الأولي يعطينا احصائيتين لجودة التلاؤم (إحصائية كاي مربع لـ Pearson وإحصائية نسبة الاحتمالية، وقد تحدثنا عنهما في بداية هذا الفصل). وفي هذا الإطار تختبر هذه الاختبارات الفرضية بأن التكرارات المتوقعة من النموذج هي مختلفة بشكل كبير عن التكرارات الفعلية في البيانات (التكرارات المشاهدة). والآن، إذا كان النموذج يلائم البيانات بشكل جيد فإن التكرارات المتوقعة والتكرارات المشاهدة يجب أن تكون متشابهة جداً (غير مختلفة بشكل كبير). ولذلك نريد أن تكون هذه الإحصائيات بدون دلالة. أما النتيجة ذات الدلالة فتعني أن النموذج مختلف جداً عن البيانات (أي أنه تلاؤم غير جيد). وفي العينات الكبيرة يجب أن تعطي هذه الإحصائيات نفس النتائج ولكن

إحصائية نسبة الاحتمالية هي المفضلة في العينات الصغيرة. وفي هذا المثال، تبلغ قيمة كل من الإحصائيتين 0 وينتج عنهما قيمة احتمال p هي INF- وهي طريقة أخرى للتعبير عن أن الاحتمال مرتفع جداً. وبمعنى آخر فإن النموذج في هذه المرحلة يتوقع البيانات بشكل تام. وإذا قرأتَ الفقرة النظرية فإن هذه النتيجة لن تكون مفاجئة أبداً. وكما أوضحنا فإن النموذج المشبع هو تلاؤم تام للبيانات وتكون نسبة الاحتمالية الناتجة هي 0. والشيء الممتع في التحليل الخطي اللوغاريتمي هو معرفة الأجزاء التي يمكن حذفها من النموذج دون أن تتأثر جودة التلاؤم للنموذج بشكل كبير.

Hierarchical Loglinear Analysis

Warnings

For Design 1, .500 has been added to all observed cells for this saturated model. This value may be changed by using the CRITERIA = DELTA subcommand.

Data Information

		N
Cases	Valid	270
	Out of Range[a]	0
	Missing	0
	Weighted Valid	270
Categories	animal	2
	training	2
	dance	2

a. Cases rejected because of out of range factor values.

Design 1

Convergence Information

	animal*training*dance
Generating Class	
Number of Iterations	1
Max. Difference between Observed and Fitted Marginals	.000
Convergence Criterion	.250

Cell Counts and Residuals

animal	training	dance	Observed Count[a]	Observed %	Expected Count	Expected %	Residuals	Std. Residuals
Cat	Food as Reward	Yes	28.500	10.6%	28.500	10.6%	.000	.000
		No	10.500	3.9%	10.500	3.9%	.000	.000
	Affection as Reward	Yes	48.500	18.0%	48.500	18.0%	.000	.000
		No	114.500	42.4%	114.500	42.4%	.000	.000
Dog	Food as Reward	Yes	20.500	7.6%	20.500	7.6%	.000	.000
		No	14.500	5.4%	14.500	5.4%	.000	.000
	Affection as Reward	Yes	29.500	10.9%	29.500	10.9%	.000	.000
		No	7.500	2.8%	7.500	2.8%	.000	.000

a. For saturated models, .500 has been added to all observed cells.

Goodness-of-Fit Tests

	Chi-Square	df	Sig.
Likelihood Ratio	.000	0	.
Pearson	.000	0	.

الخرج 6.16

يدلنا القسم التالي من الخرج (الخرج 7.16) على مكونات النموذج التي يمكن حذفها. يحوي القسم الأول من الخرج جدولاً يحمل التسمية K-way and Higher Order Effects ويعرض إحصائيتي نسبة الاحتمالية وكاي مربع عندما تأخذ K القيم 3 و2 و1. يحوي السطر الثالث (K=3) نتيجة اختبار حذف الأثر ثلاثي الاتجاه والآثار من المرتبة الأعلى على جودة التلاؤم للنموذج. في هذا المثال، يعتبر التفاعل ثلاثي الاتجاه هو الأثر ذو المرتبة الأعلى الموجود في النموذج ولذلك فإن هذا السطر يختبر حذف التفاعل ثلاثي الاتجاه (animal×training×dance). إذا نظرنا إلى العمودين sig. فإننا ندرك أن الإحصائيتين كاي مربع ونسبة الاحتمالية متفقتان على أن حذف هذا التفاعل سيؤثر بشكل كبير على تلاؤم النموذج (لأن قيمة الاحتمال أصغر من 0.05). يحوي السطر الثاني (K=2) نتيجة اختبار حذف التفاعلات ثنائية الاتجاه (animal×training وanimal×dance وtraining×dance) والآثار من المرتبة الأعلى على جودة التلاؤم للنموذج. في هذا المثال، هناك أثر واحد من مرتبة أعلى (التفاعل ثلاثي الاتجاه) ولذلك فإن هذا السطر يختبر فيما إذا كان حذف التفاعلات ثنائية الاتجاه والتفاعل ثلاثي الاتجاه سيؤثر على تلاؤم النموذج. نلاحظ أن هذا الاختبار عالي الدلالة (ويجب أن لا يفاجئنا ذلك لأن هذا الاختبار يحوي التفاعل ثلاثي الاتجاه، وكما رأينا فقد كان عالي الأهمية) وهذا يعني أن لحذف التفاعلات ثنائية الاتجاه والتفاعل ثلاثي الاتجاه أثر ضار كبير على النموذج. يحوي السطر الأول (K=1) نتيجة اختبار حذف التفاعلات وحيدة الاتجاه (الآثار الرئيسية لكل من المتحولات animal وtraining وdance) والآثار من المرتبة الأعلى على جودة التلاؤم للنموذج. في هذا المثال، هناك العديد من الآثار من المرتبة الأعلى (وهي التفاعلات ثنائية الاتجاه والتفاعل ثلاثي الاتجاه) ولذلك فإن هذا السطر يختبر فيما إذا كان حذف جميع الحدود سيؤثر على تلاؤم النموذج. نلاحظ أن هذا الاختبار عالي الدلالة (وهذا ما نتوقعه لأن هذا الاختبار يحوي التفاعل ثلاثي الاتجاه عالي الأهمية). إذا لم يكن لهذا الاختبار دلالة (أي أن قيمة prob أكبر من 0.05) فإن ذلك يدلنا على أن حذف جميع الحدود من النموذج لن يؤثر على تلاؤم النموذج، وبمعنى آخر إن الأثر المركب للمتحولات وللتفاعلات هو عديم الأهمية.

يعبّر القسم التالي من الخرج عن نفس الشيء ولكنه لا يتضمن الآثار من المرتبة الأعلى. يحمل هذا الجدول التسمية K-way Effects ويعرض الاختبارات عندما تأخذ K القيم 1 و2 و3. لذلك يختبر السطر الأول (K=1) فيما إذا كان لحذف الآثار الرئيسية (التفاعلات وحيدة الاتجاه) أثر ضار على النموذج. إن قيم الاحتمال أصغر من 0.05، وهذا يعني أنه إذا حذفنا الآثار الرئيسية للمتحولات animal وtraining وdance من النموذج فإن جودة التوافق للنموذج ستتأثر بشكل كبير (بمعنى آخر، تعتبر هذه الآثار متحولات تنبؤية مهمة للبيانات). يختبر السطر الثاني (K=2) فيما إذا كان لحذف التفاعلات ثنائية الاتجاه أثر ضار على النموذج. إن قيم الاحتمال أصغر من 0.05، وهذا يعني أنه إذا حذفنا التفاعلات animal×training وanimal×dance وtraining×dance من النموذج فإن جودة التلاؤم للنموذج ستتأثر بشكل كبير. وبمعنى آخر، يعتبر أحد هذه الآثار التفاعلات على الأقل متحولاً تنبؤياً مهماً للبيانات. يختبر السطر الثالث (K=3) فيما إذا كان لحذف التفاعل ثلاثي

الاتجاه أثر ضار على النموذج. إن قيم الاحتمال أصغر من 0.05، وهذا يعني أنه إذا حذفنا التفاعل animal×training×dance من النموذج فإن جودة التلاؤم للنموذج ستتأثر بشكل كبير. وبمعنى آخر، يعتبر التفاعل ثلاثي الاتجاه متحولاً تنبؤياً مهماً للبيانات. يجب أن يكون هذا السطر مماثلاً للسطر الثالث من الجدول السابق (الجدول العلوي في الخرج 7.16) لأنه يختبر الأثر من المرتبة الأعلى وفي ذلك الجدول لم تكن هناك آثار من مرتبة أعلى متضمنة في هذا الاختبار (أنظر وقارن).

K-Way and Higher-Order Effects

	K	df	Likelihood Ratio		Pearson		Number of Iterations
			Chi-Square	Sig.	Chi-Square	Sig.	
K-way and Higher Order Effects[a]	1	7	200.163	.000	253.656	.000	0
	2	4	72.267	.000	67.174	.000	2
	3	1	20.305	.000	20.778	.000	4
K-way Effects[b]	1	3	127.896	.000	186.382	.000	0
	2	3	51.962	.000	46.396	.000	0
	3	1	20.305	.000	20.778	.000	0

a. Tests that k-way and higher order effects are zero.

b. Tests that k-way effects are zero.

الخرج 7.16

وما تدلنا عليه هذه النتيجة هو أن التفاعل ثلاثي الاتجاه ذو دلالة، ويؤثر حذفه من النموذج بشكل كبير على جودة ملاءمة النموذج للبيانات. ونعلم أيضاً أن لحذف جميع التفاعلات ثنائية الاتجاه أثر كبير على النموذج، ولكن يجب أن نتذكر أن التحليل الخطي اللوغاريتمي يتم بشكل هرمي ولذلك فإن هذه التفاعلات ثنائية الاتجاه لا تهمنا لأن التفاعل ثلاثي الاتجاه ذو دلالة (سننظر إلى التفاعلات ثنائية الاتجاه إذا كان التفاعل ثلاثي الاتجاه بدون دلالة).

إذا حددت الخيار Association table في الشكل 6.16 فإنك ستحصل على الجدول المبين في الخرج 8.16. ويقوم هذا الخيار بتجزئة الجدول السابق إلى مكوناته الأساسية. فعلى سبيل المثال عرفنا من الجدول السابق أن حذف التفاعلات ثنائية الاتجاه سيؤثر على النموذج بشكل كبير ولكننا لم نعرف التفاعل ثنائي الاتجاه صاحب الأثر. وهذا ما يدلنا عليه هذا الجدول الذي يحوي اختبار كاي مربع لكل من التفاعلات ثنائية الاتجاه وللآثار الرئيسية، ويحوي العمود .sig قيم الاحتمال لهذه التفاعلات ويدلنا على الأثر ذي الدلالة (إذا كانت قيمة الاحتمال .sig أصغر من 0.05 فالأثر مهم). ونلاحظ من الجدول أن جميع التفاعلات ثنائية الاتجاه مهمة. وبشكل مشابه، رأينا في الجدول السابق أن حذف الآثار وحيدة الاتجاه (الآثار الرئيسية للمتحولات animal وtraining وdance) يؤثر بشكل كبير على تلاؤم النموذج. ويؤكد هذا الجدول تلك النتائج لأن قيم الاحتمال .sig للأثر الرئيسي لكل من المتحولَين animal وtraining هي أصغر من 0.05، بينما الأثر الرئيسي للمتحول dance عديم الأهمية لأن قيمة الاحتمال أكبر من 0.05. ولكن علينا أن

نهمل كل هذه النتائج بسبب الطبيعة الهرمية للتحليل الخطي اللوغاريتمي وذلك لأن التفاعل من المرتبة الأعلى (animal×training×dance) يحوي جميع هذه الآثار.

Partial Associations

Effect	df	Partial Chi-Square	Sig.	Number of Iterations
animal*training	1	13.760	.000	2
animal*dance	1	13.748	.000	2
training*dance	1	8.611	.003	2
animal	1	65.268	.000	2
training	1	61.145	.000	2
dance	1	1.483	.223	2

الخرج 8.16

إذا حددت الخيار Parameter estimates في الشكل 6.16 فإنك ستحصل على الجدول المبين في الخرج 9.16. ويدلنا ببساطة على نفس الشيء كما في الجدول السابق (يعطي التقديرات المنفصلة لكل أثر) ولكنه يستخدم العلامة المعيارية z بدلاً من اختبار كاي مربع. ويمكن أن يكون ذلك مفيداً لأننا نحصل على مجالات الثقة، ولأن قيمة z تعطي مقارنة مفيدة بين الآثار (إذا أخذنا القيم المطلقة فإن قيمة z الأكبر تعني أثراً أكثر أهمية). لذلك إذا نظرنا على قيم z فإننا نرى أن الأثر الرئيسي للمتحول animal هو الأكثر أهمية في النموذج (z=4.84) يليه التفاعل animal×training (z=-4.82) ثم التفاعل animal×training×dance (z=4.32). ولا داعي للتذكير بأن ما يهمنا هو التفاعل ثلاثي الاتجاه.

Parameter Estimates

Effect	Parameter	Estimate	Std. Error	Z	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
animal*training*dance	1	.360	.083	4.320	.000	.197	.523
animal*training	1	-.402	.083	-4.823	.000	-.565	-.239
animal*dance	1	-.197	.083	-2.364	.018	-.360	-.034
training*dance	1	.104	.083	1.261	.211	-.059	.268
animal	1	.404	.083	4.843	.000	.240	.567
training	1	-.328	.083	-3.937	.000	-.492	-.165
dance	1	.232	.083	2.782	.005	.069	.395

الخرج 9.16

يتعامل الجزء الأخير من الخرج (الخرج 10.16) مع الحذف التراجعي. ويبدأ مع التفاعل من المرتبة العليا (وفي هذه الحالة التفاعل animal×training×dance) حيث يحذفه من النموذج ليعرف أثره، فإذا لم يكن له أثر كبير فإنه ينتقل إلى الأثر من المرتبة العليا التالي (وفي هذه الحالة التفاعلات ثنائية الاتجاه). على كل حال، لقد رأينا سابقاً أن لحذف التفاعل ثلاثي الاتجاه أثر كبير، ويتأكد ذلك في المرحلة الحالية من الجدول المسمى Deleted Effect. ولذلك فإن التحليل يتوقف عند هذه المرحلة،

حيث لا يتم حذف التفاعل ثلاثي الاتجاه ويقوم برنامج SPSS بتقييم هذا النموذج النهائي. يدل القسم المسمى Generating Class على أن النموذج الذي يلاءم البيانات بأفضل شكل هو النموذج الذي يتضمن التفاعل ثلاثي الاتجاه، وبسبب الطبيعة الهرمية للتحليل فإن هذا التفاعل هو الحد الوحيد الذي سنقوم بتفسيره. أخيراً يقوم برنامج SPSS بتقييم النموذج النهائي باستخدام إحصائية نسبة الاحتمالية، ونبحث عن إحصائية اختبار غير مهمة تدل على أن القيم المتوقعة الناتجة عن النموذج لا تختلف بشكل كبير عن القيم المشاهدة (أي أن النموذج ملائم للبيانات بشكل جيد). وفي هذا المثال فإن النتيجة غير مهمة مما يدل على أن النموذج ملائم للبيانات بشكل جيد.

الخطوة التالية هي تفسير هذا التفاعل. إن أول شيء مفيد يمكن أن نقوم به هو رسم التكرارات عبر جميع الفئات المختلفة. يجب أن يتم رسم هذه التكرارات كنسب مئوية من القيمة الكلية (ويمكن العثور على هذه القيم في الجدول المتصالب في الخرج 5.16 في الصفوف المسماة % of Total) يعرض الشكل 7.16 المخططات الناتجة، ونلاحظ أن القطط سترقص (أو ستفعل أي شيء آخر) مقابل الطعام، وليس من أجل الحنان. أما الكلاب فسترقص عند مكافأتها بالحنان (وعملياً فإن عدد الكلاب التي ترقص أكبر من تلك لا ترقص بغض النظر عن المكافأة، ولكن الأثر يصبح أكثر وضوحاً عند مكافأتها بالحنان). وفي الحقيقة تُبدي القطط والكلاب استجابات متشابهة عند استخدام الطعام، ولكن القطط لا تفعل شيئاً عند مكافأتها بالحنان.

9.16 متابعة التحليل الخطي اللوغاريتمي

هناك طريقة بديلة لتفسير التفاعل ثلاثي الاتجاه وهي تنفيذ تحليل كاي مربع على المستويات المختلفة لأحد المتحولات. فعلى سبيل المثال، لتفسير التفاعل animal×training×dance يمكننا تنفيذ اختبار كاي مربع على كل من المتحولين training وdance ولكن بشكل منفصل على فئتي المتحول animal (وهما القطط والكلاب)، ثم مقارنة النتائج. حاول تنفيذ ذلك باستخدام الوظيفة split file (أنظر الفقرة 4.3). إن نتائج هذا التحليل لحالة القطط مبينة في الخرج 2.16، أما بالنسبة لحالة الكلاب فإن النتائج مبينة في الخرج 11.16. ونلاحظ وجود علاقة مهمة بين نوع التدريب وفيما إذا كانت الكلاب سترقص أم لا، وهذه العلاقة أقل قوة (χ_2=3.93 مقارنة مع χ_2=25.2 في حالة القطط). ويعكس ذلك حقيقة أن الكلاب سترقص إذا تم منحها الحنان أكثر مما لو تمت مكافأتها بالطعام.

Backward Elimination Statistics

Step Summary

Step[b]		Effects	Chi-Square[a]	df	Sig.	Number of Iterations
0	Generating Class[c]	animal*training*dance	.000	0	.	
	Deleted Effect 1	animal*training*dance	20.305	1	.000	4
1	Generating Class[c]	animal*training*dance	.000	0	.	

a. For 'Deleted Effect', this is the change in the Chi-Square after the effect is deleted from the model.

b. At each step, the effect with the largest significance level for the Likelihood Ratio Change is deleted, provided the significance level is larger than .050.

c. Statistics are displayed for the best model at each step after step 0.

Convergence Information[a]

Generating Class	animal*training*dance
Number of Iterations	0
Max. Difference between Observed and Fitted Marginals	.000
Convergence Criterion	.250

a. Statistics for the final model after Backward Elimination.

Cell Counts and Residuals

animal	training	dance	Observed Count	Observed %	Expected Count	Expected %	Residuals	Std. Residuals
Cat	Food as Reward	Yes	28.000	10.4%	28.000	10.4%	.000	.000
		No	10.000	3.7%	10.000	3.7%	.000	.000
	Affection as Reward	Yes	48.000	17.8%	48.000	17.8%	.000	.000
		No	114.000	42.2%	114.000	42.2%	.000	.000
Dog	Food as Reward	Yes	20.000	7.4%	20.000	7.4%	.000	.000
		No	14.000	5.2%	14.000	5.2%	.000	.000
	Affection as Reward	Yes	29.000	10.7%	29.000	10.7%	.000	.000
		No	7.000	2.6%	7.000	2.6%	.000	.000

Goodness-of-Fit Tests

	Chi-Square	df	Sig.
Likelihood Ratio	.000	0	.
Pearson	.000	0	.

الخرج 10.16

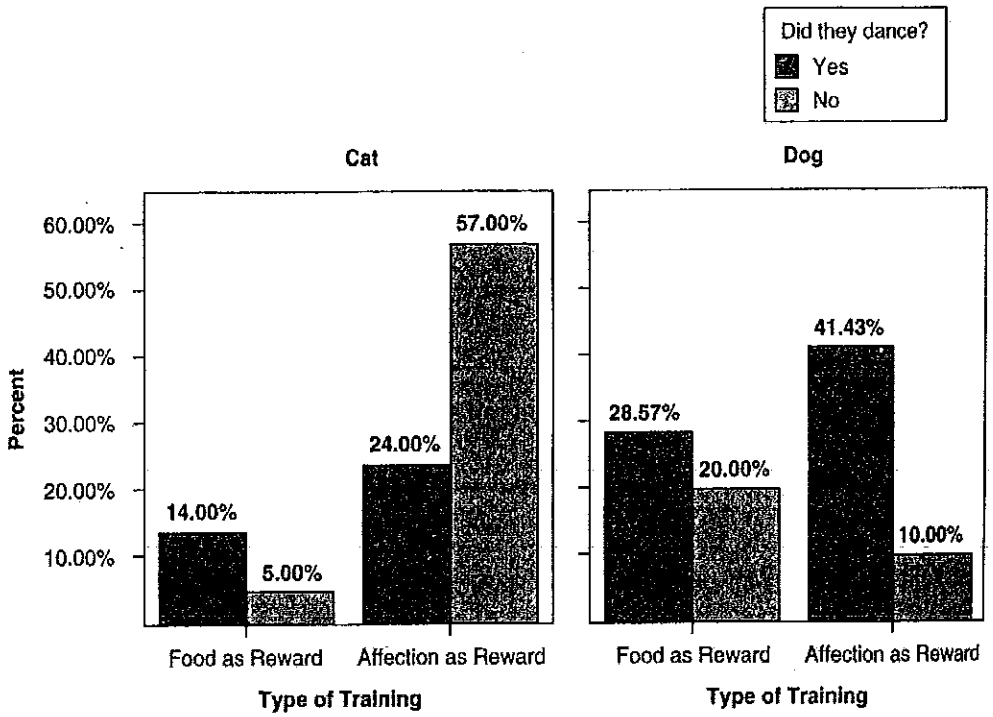

الشكل 7.16

Chi-Square Tests[d]

	Value	df	Asymp. Sig. (2-sided)	Exact Sig. (2-sided)	Exact Sig. (1-sided)	Point Probability
Pearson Chi-Square	3.932[b]	1	.047	.068	.042	
Continuity Correction[a]	2.966	1	.085			
Likelihood Ratio	3.984	1	.046	.068	.042	
Fisher's Exact Test				.068	.042	
Linear-by-Linear Association	3.876[c]	1	.049	.068	.042	.030
N of Valid Cases	70					

a. Computed only for a 2x2 table

b. 0 cells (.0%) have expected count less than 5. The minimum expected count is 10.20.

c. The standardized statistic is -1.969.

d. Animal = Dog

الخرج 11.16

10.16 حجم الأثر في التحليل الخطي اللوغاريتمي

كما في حالة كاي مربع لـــ Pearson، فإن أفضل طريقة لتقديم الآثار هي بدلالة نسبة الأرجحية. إن نسب الأرجحية أسهل فهماً في حالة جداول الأحداث المحتملة ذات الأبعاد 2x2، ولذلك إذا كانت هناك تفاعلات هامة من مراتب أعلى، أو كانت للمتحولات 3 فئات أو أكثر فمن المفضل

تقسيم هذه الآثار إلى جداول 2x2 وحساب نسب الأرجحية التي تعكس طبيعة التفاعل. لذلك وعلى سبيل المثال سنقوم بحساب نسب الأرجحية لكل من القطط والكلاب بشكل منفصل. لقد حسبنا نسبة الأرجحية للقطط سابقاً (أنظر الفقرة 5.4.16)، ومن أجل حالة الكلاب يمكننا أن نحسب الأرجحية لرقص الكلب عندما يتلقى الطعام كمكافأة، وهي تساوي عدد الكلاب التي تناولت الطعام ورقصت مقسوماً على عدد الكلاب التي تناولت الطعام و لم ترقص:

$$\text{Odds}_{\text{dancing after food}} = \frac{\text{number that had food and danced}}{\text{number that had food but didn't dance}}$$

$$= \frac{20}{14}$$

$$= 1.43$$

نحسب بعد ذلك الأرجحية لرقص الكلب عندما يتلقى الحنان كمكافأة، وهي تساوي عدد الكلاب التي تلقت الحنان ورقصت مقسوماً على عدد الكلاب التي تلقت الحنان و لم ترقص:

$$\text{Odds}_{\text{dancing after affection}} = \frac{\text{number that had affection and danced}}{\text{number that had affection but didn't dance}}$$

$$= \frac{29}{7}$$

$$= 4.14$$

وتكون نسبة الأرجحية هي أرجحية الرقص عند تناول الطعام مقسومة على أرجحية الرقص عند تلقي الحنان:

$$\text{Odds ratio} = \frac{\text{Odds}_{\text{dancing after food}}}{\text{Odds}_{\text{dancing after affection}}}$$

$$= \frac{1.43}{4.14}$$

$$= 0.35$$

ويدلنا ذلك أنه إذا تم تدريب الكلب باستخدام الطعام كمكافأة فإن أرجحية أن يرقص هي 0.35 مرات أكبر. وهناك طريقة أخرى للتعبير عن ذلك وهي أن نقول أن نسبة الأرجحية هي 1/0.35=2.90 مرة أقل. نقارن هذه القيمة مع نسبة الأرجحية للقطط 6.65. وكما ترى فإن مقارنة نسب الأرجحية هي طريقة راقية لتقديم التفاعل ثلاثي الاتجاه في النموذج.

11.16 تقديم النتائج للتحليل الخطي اللوغاريتمي

عند تقديم نتائج التحليل الخطي اللوغاريتمي علينا تقديم إحصائية نسبة الاحتمالية للنموذج النهائي والتي يتم ترميزها عادة χ^2. ومن أجل الحدود الهامة علينا تقديم التغير في كاي مربع أو العلامة المعيارية z للأثر ومجال الثقة المرتبط بها. إذا قسمنا التفاعلات من المرتبة العليا إلى تحاليل لاحقة فإن

علينا تقديم إحصائيات كاي مربع لكل منها (ونسب الأرجحية). فعلى سبيل المثال يمكننا أن نكتب:

- ✓ أعطى التحليل الخطي اللوغاريتمي ثلاثي الاتجاه نموذجاً نهائياً يحتفظ بجميع الآثار. وكانت نسبة الاحتمالية لهذا النموذج $\chi^2(0)=0$, p=1. وهذا يدل على أن التفاعل من المرتبة العليا (التفاعل animal×training×dance) كان مهماً، $\chi^2(1)=20.31$, $p<0.001$. ولتقسيم هذا الأثر، تم إجراء اختبارات كاي مربع على المتحولين training وdance ولكن بشكل منفصل على فئتي المتحول animal (وهما القطط والكلاب). فمن أجل القطط كانت هناك علاقة مهمة بين نوع التدريب وفيما إذا كان القط سيرقص أم لا: $\chi^2(1)=25.36$, $p<0.001$ وهذه النتيجة صحيحة أيضاً من أجل الكلاب: $\chi^2=3.93$, $p<0.05$. وقد دلت نسب الأرجحية على أن القطط سترقص لو تم تدريبها باستخدام الطعام بأرجحية 6.65 مرات على تدريبها باستخدام الحنان، أما الكلاب فتكون هذه الأرجحية 0.35 مرة (أو 2.90 مرة أقل). لذلك يبدو أن التحليل الخطي اللوغاريتمي يكشف عن فرق جوهري بين الكلاب والقطط: من المرجح أن القطط سترقص من أجل الطعام وليس من أجل الحنان، بينما الكلاب سترقص من أجل الحنان وليس من أجل الطعام.

أفكار مهمة

- إذا أردت اختبار علاقة بين أكثر من متحولين فئويين فعليك استخدام التحليل الخطي اللوغاريتمي (Loglinear analysis).
- التحليل الخطي اللوغاريتمي هو تحليل هرمي، إذ يحوي النموذج الأولي جميع الآثار الرئيسية والتفاعلات. ويبدأ بحذف التفاعل من الدرجة العليا لمعرفة فيما إذا كان له أثر مهم على النموذج. فإذا كان له أثر هام فلن يتم حذفه وسيتم إهمال جميع المراتب من المراتب الأدنى (لن يتم حذف أي منها).
- انظر إلى الجدول المسمى Generating Class لمعرفة الآثار التي تم الاحتفاظ بها في النموذج. أنظر بعد ذلك إلى الجدول المسمى Deleted Effect لمعرفة الدلالة الفردية لكل من الآثار التي تم الاحتفاظ بها (أنظر إلى العمود المسمى .sig حيث تدل القيم الأصغر من 0.05 على الدلالة).
- انظر إلى إحصائية اختبار جودة التوافق (Goodness-of fit test) من أجل النموذج النهائي، فإذا كان النموذج جيد التوافق مع البيانات فإن هذه الإحصائية يجب أن تكون بدون دلالة (يجب أن تكون قيمة .sig أكبر من 0.05).
- انظر إلى الجدول المتصالب لتفسير الآثار المهمة (وتعتبر الخلايا % of Total أفضل معيار يمكن النظر إليه).

12.16 ما الذي اكتشفناه عن الإحصاء؟

تم في هذا الفصل إلقاء نظرة مختصرة جداً على تحليل البيانات الفئوية. وقد حاولنا فيه عرض كيفية التعامل مع البيانات الفئوية كأي نوع آخر من البيانات، حيث نبحث عن نموذج للتلاؤم ونحسب الانحراف بين النموذج والبيانات المشاهدة، ونستخدم ذلك لتقييم النموذج المعتمد. وقد حاولنا توضيح أن النموذج المستخدم هو نفس النموذج المعتمد في بقية الفصول في هذا الكتاب، إنه نموذج خطي (تراجع). عندما يكون لدينا متحولان فقط فإننا نستخدم اختبار كاي مربع لـ Pearson أو اختبار نسبة الاحتمالية لمعرفة فيما إذا كانت هناك علاقة بين المتحولين. أما في المتحولات الأكثر تعقيداً فإننا نوسّع هذه النماذج إلى ما يسمى النموذج الخطي اللوغاريتمي، وهو يشبه ANOVA للبيانات الفئوية، فمن أجل كل متحول لدينا أثر رئيسي ولدينا أيضاً التفاعلات بين المتحولات. يقوم التحليل الخطي اللوغاريتمي بتقييم هذه الآثار بشكل هرمي ليدلنا على أفضل الآثار التي يمكن أن تتوقع النتيجة.

13.16 المصطلحات الأساسية التي اكتشفناها

المتحول الفئوي	(Categorical variable)
اختبار كاي مربع	(Chi-square test)
جدول الأحداث المحتملة	(Contingency table)
إحصائية Cramer's V	(Cramer's V)
إحصائية Goodman and Kruskal's λ	(Goodman and Kruskal's λ)
التحليل الخطي اللوغاريتمي	(Loglinear analysis)
نسبة الأرجحية	(Odds ratio)
الإحصائية Phi	(Phi)
النموذج المشبع	(Saturated model)
تصحيح Yates للاستمرارية	(Yates's continuity correction)

14.16 مهمات يجب تنفيذها

- يعتقد بعض العاملين في إحدى دور النشر أنهم يلعبون كرة القدم بشكل جيد. ولمعرفة فيما إذا كان أداؤهم أفضل من المحاضرين في جامعة Sussex تمت دعوة هؤلاء العاملين للمشاركة في بعض المباريات. وقد سُمح لكل لاعب باللعب في مباراة واحدة فقط. وبعد عدة مباريات تم إحصاء عدد اللاعبين الذين سجلوا أهدافاً. يحوي الملف SageEditorsCan'tPlayFootball.sav

البيانات لهذه المهمة. نفّذ اختبار كاي مربع لمعرفة فيما إذا كان عدد العاملين أو عدد المحاضرين الذين سجلوا أهدافاً هو الأكبر.

- اهتم أحد الباحثين بمعرفة فيما إذا كانت البروج الفلكية هي محض خيال. ولذلك طلب من 2201 شخصاً تدوين بروجهم (وبذلك يكون لهذا المتحول 12 فئة تمثل البروج الفلكية) وفيما إذا كانوا يؤمنون بالبروج الفلكية أم لا (ولهذا المتحول فئتان فقط). ثم أرسل لهم جميعاً نفس التوقع الفلكي لما سيحدث معهم خلال الشهر القادم على أنه البرج لكل شخص. وفي نهاية الشهر التالي أجرى مقابلة مع كل منهم تتمحور حول مدى التقارب بين مجريات حياتهم خلال ذلك الشهر مع البرج المختلق، وقام بتصنيف البرج بأنه صحيح أو خاطئ. يحوي الملف Horoscope.sav البيانات لهذه المهمة. نفّذ التحليل الخطي اللوغاريتمي على هذه البيانات لمعرفة هل هناك علاقة بين برج الشخص واعتقاده بالأبراج، وفيما إذا كان البرج المختلق صحيحاً أم لا.

يحوي الملف Answers(chapter16).pdf الإجابات على هذه المهمات.

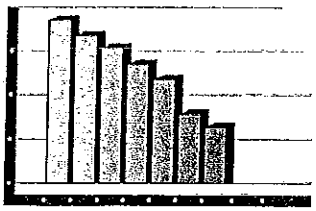

المسرد

يحوي هذا المسرد تعاريف مختصرة لجميع المصطلحات الأساسية الواردة في هذا الكتاب. تدل الكلمات المكتوبة بخط مائل على مصطلحات معرّفة في مكان آخر في هذا المسرد.

قيمة *-2LL*: وهي حاصل جداء *لوغاريتم الاحتمال* بالعدد 2-. تُستخدم هذه النسخة في التراجع الخطي.

المستوى ألفا *(α-Level)*: احتمال ارتكاب *الخطأ من النوع الأول* (وتكون هذه القيمة عادة 0.05).

المتوسط المعدّل *(Adjusted mean)*: ضمن إطار *تحليل التباين المشترك*، هو قيمة متوسط المجموعة المعدّل من أجل *المتغير المشترك*.

القيمة المتوقعة المعدّلة *(Adjusted predicted value)*: مقياس لتأثير حالة معينة من البيانات. وهي القيمة المتوقعة من نموذج ما لحالة ما يتم تقديرها دون تضمين تلك الحالة في البيانات. يتم حساب هذه القيمة بإعادة تقدير النموذج بغياب الحالة المعنية ثم استخدام النموذج الجديد للتنبؤ بقيمة الحالة المستثناة. إذا لم يكن للحالة أثر كبير على النموذج فإن قيمتها المتوقعة ستكون ذاتها تقريباً بغض النظر عن تضمينها في النموذج أو استثنائها منه. يدعى الفرق بين القيمة المتوقعة من النموذج لحالة ما عند تضمينها فيه والقيمة المتوقعة من النموذج عند استثناء تلك الحالة بـــ DFFit.

قيمة R^2 المعدّلة *($Adjusted\ R^2$)*: مقياس لفقدان القدرة التنبؤية أو *التقلص* في التراجع. وتدلنا قيمة R^2 المعدّلة على مقدار التباين في النتيجة الذي يساهم به النموذج إذا كان مشتقاً من المجتمع الذي أُخذت منه العينة.

تحليل ألفا لعواملها *(Alpha factoring)*: إحدى طرق *التحليل العاملي*.

تحليل التباين المشترك *ANCOVA (Analysis of covariance)*: إجرائية إحصائية تستخدم *النسبة F* لاختبار التلاؤم الكلي لنموذج خطي يتحكم بالأثر الذي يملكه أحد *المتغيرات المشتركة* (على الأقل) على *متحول النتيجة*. وفي البحث التجريبي يميل هذا النموذج الخطي ليكون معرّفاً بدلالة قيم المتوسط للمجموعات، ولذلك يكون *تحليل التباين* الناتج اختباراً إجمالياً لما إذا كانت قيم المتوسط للمجموعات ستختلف بعد حذف التباين في متحول النتيجة والذي يبرره أحد المتغيرات المشتركة.

تحليل التباين ANOVA *(Analysis of variance)*: إجرائية إحصائية تستخدم *النسبة F* لاختبار التلاؤم الكلي لنموذج خطي. وفي البحث التجريبي يميل هذا النموذج الخطي ليكون معرّفاً بدلالة قيم المتوسط للمجموعات، ولذلك يكون تحليل التباين الناتج اختباراً إجمالياً لما إذا كانت قيم المتوسط للمجموعات مختلفة.

طريقة *Anderson-Rubin*: طريقة لحساب *علامات العامل* تعطي علامات غير مرتبطة وقياسية ذات متوسط 0 وانحراف معياري 1.

الارتباط الذاتي *(Autocorrelation)*: عندما تكون *البواقي* لحالتي مراقبة في نموذج التراجع مرتبطة.

المعامل b_i: معامل غير قياسي للتراجع. ويدل على قوة العلاقة بين *متحول تنبؤي* معين i ونتيجة ما بوحدات القياس للمتحول التنبؤي. إنه التغير في النتيجة المرتبط بتغير مقداره وحدة واحدة في المتحول التنبؤي.

المعامل β_i: معامل قياسي للتراجع. ويدل على قوة العلاقة بين *متحول تنبؤي* معين *i* ونتيجة ما بشكل *قياسي*. إنه التغير في النتيجة (مقدراً بعدد *الانحرافات المعيارية*) المرتبط بتغير مقداره انحراف معياري واحد في المتحول التنبؤي.

المستوى بيتا *(β-Level)*: احتمال ارتكاب *الخطأ من النوع الثاني* (ويقترح Cohen, 1992 قيمة عظمى قدرها 0.02).

اختبار *Bartlett* للكروية *(Bartlett's test of sphericity)*: اختبار لفرضية *الكروية*. يفحص هذا الاختبار فيما إذا كانت *مصفوفة التباين–التباين المشترك* متناسبة مع *المصفوفة المحايدة*. لذلك فهو يختبر فعلياً فيما إذا كانت العناصر القطرية في مصفوفة التباين–التباين المشترك متساوية (أي أن تباينات المجموعات متساوية)، وكانت العناصر غير القطرية قريبة من الصفر (أي أن *المتحولات التابعة* غير *مرتبطة*). وقد صرح Jeremy Miles الذي نفّذ الكثير من عمليات التحليل متعددة المتغيرات بأنه لم يعثر أبداً على مصفوفة عديمة الدلالة باستخدام هذا المعيار، لذلك يمكنك التساؤل عن الفائدة العملية لهذا الاختبار.

التصميم بين المجموعات *(Between-Group design)*: اسم آخر *للتصميم المستقل*.

التصميم بين المواضيع *(Between-Subject design)*: اسم آخر *للتصميم المستقل*.

***ثنائي النمط (Bimodal)*:** وصف لتوزيع من الحالات المشاهدة ذات *النمطين*.

الارتباط ثنائي التسلسل *(Biserial correlation)*: مقياس معياري لقوة العلاقة بين متحولين عندما يكون أحدهما *ثنائياً*. ويُستخدم معامل الارتباط ثنائي التسلسل عندما يكون أحد المتحولين ثنائياً مستمراً (أي أن هناك استمراراً خفياً بين الفئات).

الارتباط ثنائي المتغيرات *(Bivariate correlation)*: ارتباط بين متحولين.

التراجع حسب الكتلة *(Blockwise regression)*: اسم آخر *للتراجع الهرمي*.

تصحيح *(Bonferroni Corredtion)*: تصحيح مطبق على المستوى ألفا للتحكم *بمعدل الخطأ من النوع الأول* عند تنفيذ عدة اختبارات متعددة الدلالة. يجب أن يستخدم كل اختبار منفّـذ معياراً للدلالة للمستوى ألفا (عادة 0.05) مقسوماً على عدد الاختبارات المنفذة. وهو معيار بسيط ولكنه فعال، ويميل ليكون صارماً جداً عند تنفيذ مجموعة من الاختبارات.

أثر الضجر *(Boredom effect)*: يدل على إمكانية تأثر الأداء في المهمات بالضجر (الفرضية هي وجود أثر سلبي) وانخفاض التركيز عند وجود عدة مهمات، أو مهمة ممتدة على فترة زمنية طويلة.

اختبار *Box*: اختبار لفرضية *تجانس مصفوفات التباين المشترك*. إذا كانت المصفوفات متساوية فإن هذا الاختبار يجب أن يكون عديم الدلالة. وهذا الاختبار عرضة للانحراف عن *الطبيعية متعددة المتغيرات* ولذلك يمكن أن يكون عديم الدلالة لأن فرضية الطبيعية متعددة المتغيرات غير محققة، وليس لأن *مصفوفات التباين-التباين المشترك* متماثلة عبر المجموعات. لذلك فمن الضروري تكوين فكرة عما إذا كانت البيانات تحقق فرضية الطبيعية متعددة المتغيرات (وهو أمر صعب جداً) قبل تفسير نتيجة اختبار Box.

مخطط رسم الصندوق *(Boxplot)*: تمثيل بياني لبعض المميزات الهامة لمجموعة من المشاهدات. في مركز المخطط يوجد *الوسط* محاطاً بصندوق، وبين الحدين العلوي والسفلي تقع نسبة 50% الوسطى من المشاهدات (*المجال بين الربعيّ*). يمتد خطان من الحدين العلوي والسفلي إلى العلامتين القصوى والدنيا على الترتيب.

نسبة *Brown-Forsythe F*: نسخة من *النسبة* F مصممة لتكون دقيقة عند خرق *فرضية تجانس التباين*.

المتحول الفئوي *(Categorical variable)*: متحول مكون من فئاتٍ من الكائنات أو الكيانات.

توزيع كاي مربع *(Chi-square distribution)*: *توزيع احتمالي* لمجموع المربعات لعدة متحولات موزعة طبيعياً. ويتم استخدامه لاختبار الفرضيات حول البيانات الفئوية.

اختبار كاي مربع *(Chi-square test)*: مع أنه يمكن تطبيق هذا المصطلح على أي *إحصائية اختبار* ذات *توزيع كاي مربع* فإنه يدل عادة على اختبار كاي مربع لـــ Pearson لاستقلال متحولين فئويين. ويختبر بشكل أساسي فيما إذا كان متحولان فئويان يشكلان جدولَ أحداثٍ محتملة هما مرتبطان.

اختبار *Cochran's Q*: توسيع لاختبار McNemar وهو بشكل أساسي Friedman's ANOVA من أجل *البيانات الثنائية*.

معامل التحديد *(Coefficient of determination)*: نسبة التباين في متحول ما التي يبررها متحول آخر. ويساوي مربع *معامل* Pearson *للارتباط*.

التباين التشاركي *(Common variance)*: تباين مشترك بين متحولين أو أكثر.

التشاركية (Communality): نسبة *التباين التشاركي* في تباين متحول ما. ويستخدم هذا المصطلح بشكل أساسي في *التحليل العاملي*. إذا لم يكن للمتحول *تباين فريد* (أو *تباين عشوائي*) فإن قيمة التشاركية فيه تساوي 1، وإذا كان المتحول لا يشارك أي جزء من تباينه مع أي متحول آخر فإن قيمة التشاركية فيه تساوي 0.

الفصل التام (Complete separation): إحدى حالات *التراجع المنطقي* والتي يمكن فيها التنبؤ بمتحول النتيجة عن طريق أحد المتحولات التنبؤية أو تركيب من المتحولات التنبؤية.

مصفوفة المكونات (Component matrix): مصطلح عام يدل على *مصفوفة البنية* في *تحليل المكونات الرئيسية* في برنامج SPSS.

التناظر المركب (Compound symmetry): الشرط الذي يبقى صحيحاً عندما يكون كل من التباين في الحالات التجريبية متساوياً (وهو نفس *فرضية تجانس التباين*) *والتباين المشترك* بين زوج من الحالات متساوياً أيضاً.

مجال الثقة (Confidence interval): عند حساب إحصائية ما لعينة من المشاهدات (كالمتوسط مثلاً) فإن مجال الثقة هو مجال من القيم حول تلك الإحصائية يُعتقد بأنه يحوي القيمة الصحيحة لتلك الإحصائية (كالمتوسط للمجتمع مثلاً) باحتمال معين (عادة 95%).

التحليل العاملي التأكيدي CFA (Confirmatory factor analysis): نسخة من *التحليل العاملي* يتم فيها اختبار فرضيات محددة حول البنية والعلاقات بين *المتحولات المستترة* المختفية في البيانات.

المتحول المُربك (Confounding variable): متحول (تم قياسه أو لم يتم قياسه) عدا *المتحولات التنبؤية* وهتم به لأنه قد يؤثر على *متحول النتيجة*.

جدول الأحداث المحتملة (Contingency table): جدول يمثل التصنيف المتصالب لاثنين أو أكثر من *المتحولات الفئوية*. يتم ترتيب المستويات لكل متحول في شبكة، وتحوي كل خلية من هذه الشبكة عدد المشاهدات التي تقع في كل فئة.

مسافة Cook (Cook's distance): مقياس للتأثير الكلي لحالة ما على النموذج. وقد اقترح Cook & Weisberg (1982) أن القيم التي تكون أكبر من 1 هي سبب للقلق.

الموازنة (Counterbalancing): عملية تغيير منهجي للترتيب الذي يتم به تنفيذ الحالات التجريبية. في الحالة الأبسط التي تحوي حالتين تجريبيتين (A, B)، تقتضي عملية الموازنة أن يُنهي نصف المشتركين الحالة التجريبية A تليها الحالة التجريبية B، بينما يقوم النصف الآخر من المشتركين بإنهاء الحالة B تليها الحالة A. والهدف هو إزالة الانحياز المنهجي الناتج عن *آثار الممارسة* أو *آثار الضجر*.

التباين المشترك (Covariance): مقياس للعلاقة الوسطية بين متحولين، ويساوي متوسط الجداء المتصالب للانحراف (أي الجداء المتصالب مقسوماً على عدد أقل بواحد من عدد المشاهدات).

نسبة التباين المشترك CVR *(Covariance ratio)*: مقياس لما إذا كانت حالة ما تؤثر على التباين للبارامترات في *نموذج التراجع*. عندما تكون هذه القيمة قريبة من 1 فإن للحالة تأثير ضئيل جداً على التباينات لبارامترات النموذج. وقد نصح Belset et al. (1980) بما يلي: إذا كانت CVR لحالة ما أكبر من المقدار 1+[3(k+1)/n] فإن حذف تلك الحالة سيؤثر سلبياً على دقة بعض بارامترات النموذج، ولكنها إذا كانت أصغر من 1-[3(k+1)/n] فإن حذف تلك الحالة سيحسّن دقة بعض بارامترات النموذج (k عدد المتحولات التنبؤية، و n حجم العينة).

المتغير المشترك *(Covariate)*: متحول له علاقة (من حيث *التباين المشترك*) أو ارتباط محتمل مع *متحول النتيجة* الذي يتم قياسه.

معامل R^2_{cs} *Cox and Snell's*: نسخة من *معامل التحديد* من أجل *التراجع المنطقي*. ويعتمد على *لوغاريتم الاحتمال* لنموذج ما ((LL(new)) ولوغاريتم الاحتمال للنموذج الأصلي ((LL(baseline)) وحجم العينة. ويشتهر هذا المعامل بعدم وصوله إلى قيمته العظمى 1.

إحصائية *Cramer's V*: مقياس لقوة العلاقة بين *متحولين فئويين*، ويُستخدم عندما يملك أحد المتحولين أكثر من فئتين. وهذه الإحصائية هي شكل من أشكال Phi وتُستخدم لأنه عندما يملك أحد المتحولين أو كلاهما أكثر من فئتين فإن Phi تفشل في الوصول إلى القيمة الدنيا 0 (التي تدل على عدم وجود علاقة).

معيار α *Cronbach's*: قياس لوثوقية مقياس ما، ومعرّف بالعلاقة:

$$\alpha = \frac{N^2.\overline{Cov}}{\sum s^2_{item} + \sum Cov_{item}}$$

يمثل بسط المعادلة مربع عدد العناصر مضروباً بمتوسط التباين المشترك بين العناصر (متوسط العناصر غير القطرية في *مصفوفة التباين-التباين المشترك*). أما المقام فيمثل مجموع جميع العناصر في *مصفوفة التباين-التباين المشترك*.

انحرافات الجداء المتصالب *(Cross-product deviations)*: مقياس للعلاقة الكلية بين متحولين، ويساوي جداء الانحراف لأحد المتحولين عن متوسطه بالانحراف للمتحول الآخر عن متوسطه.

التحقق المتصالب *(Cross-validation)*: تقييم لدقة نموذج ما عبر عينات مختلفة. وهي خطوة هامة في *التعميم*. في *نموذج التراجع* هناك طريقتان أساسيتان للتحقق المتصالب: R^2 *المعدّلة* أو تقسيم البيانات حيث يتم تقسيم البيانات بشكل عشوائي إلى نصفين وتقدير نموذج التراجع لكل نصف ثم المقارنة.

المنحى التكعيبي *(Cubic trend)*: إذا تم وصل قيم المتوسط في الحالات المرتّبة بخط فإن المنحى التكعيبي يظهر من خلال تغيرين في الاتجاه لهذا الخط. ولكي يتم ذلك يجب أن يكون عدد الحالات المرتّبة 4 حالات على الأقل.

محرر البيانات *(Data editor)*: النافذة الرئيسية في برنامج SPSS حيث يتم إدخال البيانات وتنفيذ العمليات الإحصائية.

عرض البيانات *(Data view)*: هناك طريقتان لعرض محتويات *محرر البيانات*. وتبين طريقة عرض البيانات جدولاً يمكن استخدامه لإدخال صفوف البيانات (انظر أيضاً *عرض المتحولات*).

درجات الحرية *(Degrees of freedom)*: عدد الكيانات التي تتمتع بحرية التغير عند تقدير بعض أنواع البارامترات الإحصائية. وبمعنى عملي، لها صلة باختبارات الدلالة لعدد من *إحصائيات الاختبار* شائعة الاستخدام (مثل *النسبة F*، *الاختبار t*، *إحصائية كاي مربع*) وتحدد الشكل الدقيق *للتوزيع الاحتمالي* من أجل إحصائيات الاختبار تلك. لمزيد من التفاصيل يمكن العودة للفصل 8 والشرح الذي يحوي مثالاً عن لاعبي الركبي.

الباقي المحذوف *(Deleted residual)*: مقياس لتأثير حالة معينة من البيانات، ويساوي الفرق بين *القيمة المتوقعة المعدّلة* لحالة ما والقيمة الأصلية لتلك الحالة.

اختبار *t* التابع *(Dependent t-test)*: اختبار يستخدم *الإحصائية t* التي تبين فيما إذا كانت قيمتا المتوسط من نفس العينة (أو المشاهدات المرتبطة) مختلفتان بشكل كبير.

المتحول التابع *(Dependent variable)*: اسم آخر *لمتحول النتيجة*، ويرتبط هذا الاسم بالمنهجية التجريبية ويدعى بهذا الاسم لأنه المتحول الذي لا يتم التلاعب به من قبل منفّذ التجربة ولذلك فإن قيمته تعتمد على المتحولات التي تم التلاعب بها.

الحيدان *(Deviance)*: الفرق بين القيمة المشاهدة لمتحول ما والقيمة المتوقعة لذلك المتحول من قِبَل نموذج إحصائي.

مقارنة الإنحراف *(Deviation contrast)*: *مقارنة منظمة* غير متعامدة تقارن المتوسط لكل مجموعة (باستثناء المجموعة الأولى أو الأخيرة وذلك بناءً على نوع المقارنة المحددة) مع *المتوسط الكلي*.

إحصائية *DFBeta*: مقياس لتأثير حالة ما على قيم b في *نموذج التراجع*. إذا قمنا بتقدير أحد بارامترات التراجع b ثم حذفنا حالة معينة، وأعدنا تقدير نفس البارامتر b فإن الفرق بين هذين التقديرين هو DFBeta للحالة المحذوفة. وبالنظر إلى قيم DFBeta يمكن تحديد الحالات ذات التأثير الكبير على بارامترات نموذج التراجع. ويعتمد حجم DFBeta على وحدات القياس لبارامتر التراجع.

إحصائية *DFFit*: مقياس لتأثير حالة ما على قيم b. وتساوي الفرق بين *القيمة المتوقعة المعدّلة* والقيمة المتوقعة الأصلية لحالة ما. إذا لم تكن هذه الحالة مؤثرة فإن DFFit يجب أن تساوي 0، ولهذا نتوقع أن تكون قيم DFFit صغيرة للحالات غير المؤثرة. على كلٍ حال تعتمد هذه الإحصائية على وحدات القياس لمتحول النتيجة، ولذلك فإن القيمة 0.5 مثلاً تكون صغيرة جداً إذا كان مجال النتيجة بين 1 و100، ولكنها كبيرة جداً إذا كان المجال بين 0 و1.

ثنائي التفرع *(Dichotomous)*: وصف لمتحول يتكون من فئتين فقط (كالمتحول gender الذي يتألف من فئتين فقط هما ذكر وأنثى).

مقارنة الفرق *(Difference contrast)*: *مقارنة منظمة* غير متعامدة تقارن المتوسط لكل مجموعة (باستثناء المجموعة الأولى) مع *المتوسط الكلي* لجميع الحالات السابقة مركبة مع بعضها البعض.

طريقة *Direct oblimin*: إحدى طرق *الدوران المائل*.

تحليل التابع المميز *DFA (Discriminant function analysis)*: يدعى أيضاً تحليل المميز Discriminant analysis. يحدد هذا التحليل *متغيرات التابع المميز* لمجموعة من المتحولات، ويستفاد منه كاختبار يلي *تحليل التباين* لمعرفة فيما إذا كانت هذه المتغيرات تسمح لمجموعات من الحالات بأن تكون مميزة.

متغير التابع المميز *(Discriminant function variate)*: تركيب خطي للمتحولات يتم إنشاؤه بحيث تسعى الفروق بين قيم المتوسط للمجموعات على المتحولات المحوَّلة نحو القيمة العظمى. ويأخذ الشكل العام: $Variate_1=b_1X_1+ b_2X_2+ ... + b_nX_n$.

العلامة المميزة *(Discriminant score)*: علامة لحالة فردية على متغير معين *للتابع المميز* نحصل عليها بتعويض علامة الحالة على المتحولات المقاسة في المعادلة التي تعرّف المتغير المقصود.

المتحولات المزيفة *(Dummy variables)*: طريقة لإعادة ترميز متحول ثنائي مكوّن من أكثر من فئتين بشكل سلسلة من المتحولات *ثنائية التفرع* تأخذ القيم 0 أو 1 فقط. هناك 7 خطوات أساسية لإنشاء هذه المتحولات: (1) حساب عدد المجموعات التي نريد إعادة ترميزها ونطرح منه العدد 1، (2) إنشاء عدد من المتحولات الجديدة (المتحولات المزيفة) يساوي العدد المحسوب في الخطوة الأولى، (3) اختيار إحدى المجموعات لتكون مجموعة مرجعية (مجموعة ستتم مقارنة بقية المجموعات معها، وتعتبر مجموعة مراقبة)، (4) منح القيمة 0 لجميع المتحولات المزيفة في المجموعة المرجعية، (5) من أجل المتحول المزيف الأول، تعيين القيمة *1* للمجموعة الأولى التي ستتم مقارنتها مع المجموعة المرجعية، والقيمة 0 لهذا المتحول في بقية المجموعات، (6) من أجل المتحول المزيف الثاني، تعيين القيمة *1* للمجموعة الثانية التي ستتم مقارنتها مع المجموعة المرجعية، والقيمة 0 لهذا المتحول في بقية المجموعات، (7) تكرار هذه العملية حتى الإنتهاء من جميع المتحولات المزيفة.

اختبار *Durbin-Watson*: يختبر الارتباطات التسلسلية بين الأخطاء في نماذج التراجع. ويختبر بشكل خاص فيما إذا كانت البواقي المتجاورة مترابطة، وهذا يفيد في تقييم فرضية *الأخطاء المستقلة*. يمكن أن تتغير إحصائية الاختبار بين 0 و 4 حيث تعني القيمة 2 أن البواقي غير مرتبطة. تدل القيم التي تكون أكبر من 2 على ارتباط عكسي بين البواقي المتجاورة بينما تدل القيم التي تكون أصغر من 2 على ارتباط طردي. ويعتمد مقدار إحصائية Durbin-Watson على عدد المتحولات التنبؤية في النموذج وعلى عدد المشاهدات. ومن أجل الدقة يجب البحث عن القيم المقبولة الدقيقة في مقالة

Durbin-Watson الأصلية. وكقاعدة صارمة يمكن اعتبار القيم الأدنى من 1 أو الأكبر من 3 سبباً أكيداً للاهتمام، أما القيم الأقرب إلى 2 فتبقى إشكالية حسب العينة والنموذج.

حجم الأثر *(Effect size)*: قياس موضوعي ومعياري لمطال أثرٍ مُرَاقب، ويتضمن Cohen's d و Glass's g ومعامل Pearson للارتباط.

طريقة *Equamax*: إحدى طرق *الدوران المتعامد*، وهي خليط من الطريقتين quartimax و varimax. ويُعرف سلوكها بأنه متقلب، وربما يكون من الأفضل تجنبها.

مخطط عمود الخطأ *(Error bar chart)*: تمثيل بياني لمتوسط مجموعة من القيم المشاهدة يتضمن مجال الثقة 95% للمتوسط. يتم تمثيل المتوسط عادة بنقطة ومستطيل يمتد إلى قيمة المتوسط. ويتم تمثيل مجال الثقة بخط يمتد من قيمة المتوسط (باتجاه الأعلى أو الأسفل أو بلا الاتجاهين) إلى خط أفقي يمثل حدود مجال الثقة، يمكن رسم أعمدة الخطأ باستخدام الخطأ المعياري أو الانحراف المعياري بدلاً من مجال الثقة 95%.

المصفوفة *E (Error SSCP)*: *مصفوفة مجموع المربعات والجداء المتصالب* للخطأ في *نموذج خطي* تنبؤي تمت ملاءمته لبيانات *متعددة المتغيرات*. وتمثل *التباين اللامنهجي*، وهي المكافئ *متعدد المتغيرات لمجموع المربعات للبواقي*.

مربع إيتا *(Eta squared)*: مقياس *حجم الأثر*، وهو نسبة مجموع المربعات للنموذج إلى مجموع المربعات الكلي، ولذلك فهو *معامل التحديد* تحت اسم آخر. ويعتبر استخدامه مضيعة للوقت، فإضافة إلى كونه منحازاً، إنه يقيس الأثر الكلي لتحليل التباين ولذلك لا يمكن تفسيره بطريقة مفيدة.

قيمة *Exp(B)*: مؤشر للتغير في *الأرجحية* الناتج عن وحدة تغير في المتحول التنبؤي في *التراجع المنطقي*. إذا كانت القيمة أكبر من *1* فإنها تدل على أنه عندما يزداد المتحول التنبؤي فإن أرجحية حدوث النتيجة تزداد. وبالعكس إذا كانت القيمة أصغر من *1* فإنها تدل على أنه عندما يزداد المتحول التنبؤي فإن أرجحية حدوث النتيجة تنخفض.

الفرضية التجريبية *(Experimental hypothesis)*: التنبؤ بأن للتلاعب التجريبي بعض الأثر، أو أن بعض المتحولات ستكون مرتبطة ببعضها البعض.

معدل الخطأ حسب التجربة *(Experimentwise error rate)*: احتمال ارتكاب *الخطأ من النوع الأول* في تجربة تتضمن مقارنة إحصائية أو أكثر وذلك عندما تكون *فرضية العدم* صحيحة في كل حالة.

الاستخراج *(Extraction)*: مصطلح يُستخدم في عملية اتخاذ القرار فيما إذا كان *عامل* ما في *التحليل العاملي* هاماً إحصائياً لدرجة استخراجه من البيانات وتفسيره. ويعتمد القرار على مطال القيمة الخاصة المرتبطة بذلك العامل. انظر أيضاً *مخطط المنحدر* و *معيار Kaiser*.

النسبة *F (F-ratio)*: إحصائية اختبار ذات *توزيع احتمالي* معروف (التوزيع *F*). وهي نسبة التغايرية الوسطية في البيانات التي يمكن أن يبررها النموذج إلى التغايرية الوسطية التي لا يمكن لذلك النموذج

تبريرها. وتُستخدم لاختبار التلاؤم الكلي للنموذج في *التراجع البسيط* و *التراجع المتعدد* ولاختبار الفروق الإجمالية بين قيم المتوسط للمجموعات في التجارب.

العامل *(Factor)*: اسم آخر *للمتحول المستقل* أو *المتحول التنبؤي* ويُستخدم عادة عند وصف التصاميم التجريبية، كما يُستخدم كمرادف *للمتحول المستتر* في التحليل العاملي.

التحليل العاملي *(Factor analysis)*: تقنية متعددة المتغيرات لتحديد فيما إذا كانت الارتباطات بين مجموعة من المتحولات المراقبة نابعة من علاقتها ببعض *المتحولات المستترة* في البيانات، والتي يأخذ كل منها شكل *نموذج خطي*.

تحميل العامل *(Factor loading)*: *معامل التراجع* لمتحول ما من أجل *النموذج الخطي* الذي يصف متحولاً *مستترا* أو *عاملاً* في *التحليل العاملي*.

مصفوفة العامل *(Factor matrix)*: مصطلح عام يدل على *مصفوفة البنية* في *التحليل العاملي* في برنامج SPSS.

علامة العامل *(Factor score)*: علامة وحيدة من كيان منفصل تمثل أداءه على *متحول مستتر* معين. ويمكن توضيحها من ناحية المبدأ كما يلي: نأخذ علامة كيان ما على كل من المتحولات التي تشكّل العامل ونضربها بقيمة *تحميل العامل* للمتحول المعتبر ونجمع هذه القيم معاً.

مصفوفة تحويل العامل *A (Factor transforming matrix)*: مصفوفة مستخدمة في *التحليل العاملي*. وتحوي الزوايا التي سيتم بها تدوير العوامل عند تنفيذ *دوران العوامل*.

التحليل العاملي للتباين *(Factorial ANOVA)*: تحليل التباين الذي يتضمن *متحولين تنبؤيين* أو *متحولين مستقلين* على الأقل.

معدل الخطأ حسب العائلة *(Familywise error rate)*: احتمال ارتكاب *الخطأ من النوع الأول* في أي عائلة من الاختبارات عندما تكون فرضية العدم صحيحة في كل حالة. ويقصد بعائلة الاختبارات مجموعة من الاختبارات المنفذة على نفس المجموعة من البيانات وتهدف لنفس المسألة التجريبية.

التوزيع التكراري *(Frequency distribution)*: مخطط يبين قيم المشاهدات على المحور الأفقي وتكرار حدوث كل قيمة في مجموعة البيانات على المحور الشاقولي (يُعرف أيضاً باسم *المخطط التكراري*).

اختبار *Friedman's ANOVA*: اختبار لابارامتري لمعرفة فيما إذا كانت ثلاث مجموعات مرتبطة أو أكثر هي مختلفة. وهو النسخة اللابارامترية من *تحليل التباين وحيد الاتجاه للقياسات المكررة*.

التعميم *(Generalization)*: قابلية نموذج إحصائي ما لإعطاء معلومات خارج إطار المشاهدات التي تم بناؤه عليها. إذا تم تعميم نموذج ما فيفترض أن التنبؤات من ذلك النموذج يمكن أن تنطبق ليس على *العينة* المستند إليها فقط، وإنما على *المجتمع* الذي أُخذت منه تلك العينة.

إحصائية *Goodman and Kruskal's λ*: تقيس التخفيض المتناسب في الخطأ الذي يتم الوصول إليه عندما تُستخدم عناصر فئة ما لأحد المتحولات في التنبؤ بعناصر الفئة للمتحول الآخر. وتعني القيمة 1 أن أحد المتحولين يتوقع المتحول الآخر بشكل تام، بينما تعني القيمة 0 أن أحد المتحولين لا يستطيع التنبؤ بالمتحول الآخر أبداً.

جودة التلاؤم أو التوافق *(Goodness-of-fit)*: دليل لمدى جودة تلاؤم نموذج ما مع البيانات المستخدمة لتوليده. وتعتمد جودة التلاؤم عادة على جودة توافق البيانات المتوقعة من قِبَل النموذج مع البيانات المجمّعة فعلياً.

المتوسط الكلي *(Grand mean)*: *المتوسط* لمجموعة كاملة من المشاهدات.

التباين الكلي *(Grand variance)*: *التباين* ضمن مجموعة كاملة من المشاهدات.

تصحيح *Greenhouse-Geisser*: تقديرٌ للابتعاد عن *الكروية*. تبلغ قيمته العظمى 1 (البيانات تحقق تماماً فرضية الكروية) وقيمته الدنيا هي قيمة *الحد الأدنى*. تدل القيم التي تكون أقل من 1 على الابتعاد عن الكروية وتُستخدم لتصحيح *درجات الحرية* المرتبطة مع *نسب* F الموافقة وذلك بضربها بقيمة التقدير. يقول البعض أن تصحيح Greenhouse-Geisser صارم جداً وينصحون باستخدام تصحيح Huynh-Feldt بدلاً منه.

المتوسط التوافقي *(Harmonic mean)*: نسخة مثقّلة من *المتوسط* تأخذ بعين الاعتبار العلاقة بين التباين وحجم العينة. ويتم حسابه من العلاقة التالية:

$$H = \frac{1}{\frac{1}{n}\sum_{i=1}^{n}\frac{1}{x_i}}$$

قيم القبعة *(Hat values)*: اسم آخر لمصطلح *الفعالية*.

مصفوفة *HE*: مصفوفة مكافئة وظيفياً لحاصل قسمة *المصفوفة* SSCP *الفرضية* على *مصفوفة* SSCP *للخطأ* في *التحليل متعدد المتغيرات للتباين*. وتمثل من حيث المبدأ نسبة *التباين المنهجي* إلى *التباين اللامنهجي*، لذلك فهي المكافئ متعدد المتغيرات للنسبة F.

مقارنة *Helmert*: *مقارنة منظمة* غير متعامدة تقارن المتوسط لكل مجموعة (باستثناء المجموعة الأخيرة) مع المتوسط الكلي لجميع الحالات اللاحقة مركبة مع بعضها البعض.

عدم تجانس التباين *(Heteroscedasticity)*: عكس *تجانس التباين*. ويحدث عندما تكون البواقي لكل مستوى من مستويات *المتحول التنبؤي* (أو المتحولات التنبؤية) غير متساوية التباين. بمعنى آخر، إن انتشار البواقي عند كل نقطة على طول المتحول التنبؤي هو مختلف.

التراجع الهرمي *(Hierarchical regression)*: إحدى طرق *التراجع المتعدد*، ويحدد الباحث فيها ترتيب إدخال المتحولات التنبؤية إلى نموذج التراجع اعتماداً على أبحاث سابقة، حيث يتم إدخال المتحولات المعروفة كمتحولات تنبؤية في البداية، وبعد ذلك يتم إدخال المتحولات الجديدة.

المخطط التكراري (Histogram): انظر *التوزيع التكراري*.

تجانس مصفوفات التباين المشترك (Homogeneity of covariance matrices): فرضية لبعض الاختبارات *متعددة المتغيرات* مثل *التحليل متعدد المتغيرات للتباين*. وهي توسيع لفرضية *تجانس التباين* في التحليل وحيد المتغير. وتفترض تساوي *التباين* لكل *متحول تابع* عبر المجموعات، وكذلك التساوي الخشن للعلاقات (*التباينات المشتركة*) بين هذه المتحولات التابعة. ويتم اختبارها بمقارنة *مصفوفات التباين-التباين المشترك* للمجموعات المختلفة في التحليل.

تجانس انحدارات التراجع (Homogeneity of regression slopes): من فرضيات *تحليل التباين المشترك*. وهي الفرضية التي تنص على أن العلاقة بين *المتغير المشترك* و *متحول النتيجة* هي ثابتة عبر مستويات المعالجة المختلفة. ولذلك ومن أجل ثلاث حالات المعالجة، إذا كان هناك علاقة طردية بين المتغير المشترك والنتيجة في مجموعة ما فإننا نفترض أن علاقة طردية مماثلة في الحجم بين المتغير المشترك والنتيجة موجودة في المجموعتين الأخريين.

تجانس التباين (Homogeneity of variance): فرضية تنص على أن *التباين* لمتحول ما هو مستقر (أو متشابه نسبياً) عند جميع المستويات للمتحول الآخر.

تجانس التباين (Homoscedasticity): فرضية في تحليل *التراجع* تنص على أن البواقي عند كل مستوى من مستويات *المتحول التنبؤي* (أو المتحولات التنبؤية) متشابهة التباين. بمعنى آخر، إن انتشار البواقي عند كل نقطة على طول أي متحول تنبؤي يجب أن يكون ثابتاً تقريباً.

معامل Hosmer and Lemeshow's R^2_L: نسخة من *معامل التحديد في التراجع المنطقي*. وهي نسبة *القيمة* 2LL- للنموذج إلى القيمة 2LL- الأصلية. وبمعنى آخر، هي نسبة ما يبرره النموذج إلى المقدار الذي كان تبريره مطلوباً في البداية.

أثر Hotelling-Lawley T^2: إحصائية اختبار في *التحليل متعدد المتغيرات للتباين*. وهو مجموع القيم الخاصة لكل *متغير للتابع المميز* للبيانات، ويكافئ *النسبة* F في *تحليل التباين* من ناحية المبدأ، أي أنه مجموع نسبة التباين المنهجي إلى التباين اللامنهجي (SS_M/SS_R) لكل من المتغيرات.

تصحيح Huynh-Feldt: تقدير للابتعاد عن *الكروية*. تبلغ قيمته العظمى 1 (البيانات تحقق تماماً فرضية الكروية). تدل القيم الأصغر من هذه القيمة على ابتعاد عن الكروية، ويستخدم لتصحيح *درجات الحرية* المرتبطة مع *نسب* F الموافقة وذلك بضربها بقيمة التقدير. وهي أقل صرامة من تقدير Greenhouse-Geisser، ولكن البعض يقول إنها متسامحة جداً.

الفرضية (Hypothesis): تنبؤ عن حالة العالم (انظر *الفرضية التجريبية* و *فرضية العدم*).

المصفوفة H (Hypothesis SSCP): *مصفوفة مجموع المربعات والجداء المتصالب* الافتراضي، وهي مصفوفة مجموع المربعات والجداء المتصالب في *نموذج خطي* تنبؤي تمت ملاءمته لبيانات *متعددة المتغيرات*. وتمثل *التباين منهجي*، وهي المكافئ *متعدد المتغيرات لمجموع المربعات للنموذج*.

المصفوفة المحايدة *(Identity matrix)*: مصفوفة مربعة فيها العناصر القطرية تساوي *1* والعناصر غير القطرية تساوي *0*. وفيما يلي بعض الأمثلة:

$$\begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

الاستقلال *(Independence)*: فرضية تنص على أن أي نقطة من البيانات لا تؤثر على نقطة أخرى. عندما تأتي البيانات من أشخاص، فهي تعني بشكل أساسي أن سلوك أي مشترك لا يؤثر على سلوك مشترك آخر.

تحليل التباين المستقل *(Independent ANOVA)*: *تحليل التباين* المنفّذ على أي تصميم تم فيه التلاعب بجميع *المتحولات المستقلة* أو *المتحولات التنبؤية* باستخدام مشتركين مختلفين (جميع البيانات تأتي من كيانات مختلفة).

التصميم المستقل *(Independent design)*: تصميم تجريبي تَستخدم حالات المعالجة المختلفة فيه كيانات مختلفة (وهذا يعني في علم النفس استخدام أشخاص مختلفين في حالات المعالجة المختلفة) ولذلكً فإن البيانات الناتجة هي مستقلة (يدعى أيضاً *التصميم بين المجموعات* أو *التصميم بين المواضيع*).

الأخطاء المستقلة *(Independent errors)*: من أجل أي مراقبتين في *التراجع*، يجب أن تكون *البواقي* غير مرتبطة (أو مستقلة).

التصميم العاملي المستقل *(Independent factorial design)*: تصميم تجريبي يشمل متحولين تنبؤيين أو أكثر وقد تم التلاعب بها جميعاً باستخدام مشتركين مختلفين.

اختبار t المستقل *(Independent t-test)*: اختبار يستخدم *الإحصائية t* التي تبين فيما إذا كان المتوسطان المأخوذان من عينتين مستقلتين هما مختلفان بشكل كبير.

المتحول المستقل *(Independent variable)*: اسم آخر *للمتحول التنبؤي*. يرتبط هذا الاسم عادة مع المنهجية التجريبية. ويدعى بهذا الاسم لأنه المتحول الذي يتلاعب به منفذ التجربة ولذلك فإن قيمته لا تعتمد على أية متحولات أخرى.

أثر التفاعل *(Interaction effect)*: الأثر المركب لمتحولين تنبؤيين أو أكثر على *متحول النتيجة*.

مخطط التفاعل *(Interaction graph)*: مخطط يعرض قيم المتوسط لمتحولين مستقلين أو أكثر حيث يتم عرض المتوسطات لأحد المتحولات عند المستويات المختلفة للمتحول الآخر. ومن غير المعتاد الوصل بين المتوسطات بخط أو إظهارها بشكل أعمدة. وتساعد هذه المخططات في فهم *آثار التفاعل*.

المجال بين الربعيين *(Interquartile range)*: الحدود التي تقع ضمنها نسبة 50% الوسطى من مجموعة المشاهدات المرتّبة.

بيانات المجال *(Interval data)*: بيانات مقاسة على سلم تكون المجالات فيه متساوية. فعلى سبيل المثال يمكن أن يتراوح تقييم الأشخاص لهذا الكتاب بين *1* و *5*، ولكي تكون هذه البيانات بيانات المجال يجب أن يكون ازدياد التقييم الممثل بالتغير من *3* إلى *4* على هذا السلم مساوياً لازدياد التقييم الممثل بالتغير من *1* إلى *2* أو من *4* إلى *5*.

اختبار *Jockheere-Terpstra*: تختبر هذه الإحصائية النمط المرتّب لقيم *الوسط* عبر مجموعات مستقلة. وتقوم بشكل أساسي بنفس عمل *اختبار* Kruskal-Wallis (الذي يختبر الفرق بين قيم الوسط للمجموعات) ولكنه يشمل معلومات عما إذا كان ترتيب المجموعات مفيداً. إذا يجب استخدام هذا الاختبار عندما نتوقع أن تعطي المجموعات التي تتم مقارنتها ترتيباً مفيداً لقيم الوسط.

مقياس كفاية أخذ العينات *(Kaiser-Meyer-Olkin measure of sampling adequacy) KMO*: يمكن حسابه من أجل المتحولات المنفردة والمتعددة، ويمثل نسبة مربع الارتباط بين المتحولات إلى مربع *الارتباط الجزئي* بين المتحولات. ويتراوح بين 0 و 1، حيث تدل القيمة 0 على أن مجموع الارتباطات الجزئية كبير نسبياً مقارنة بمجموع الارتباطات وهذا يدل على انتشار في نمط الارتباطات (لذلك يكون *التحليل العاملي* غير مناسب)، أما القيمة 1 فتدل على أن أنماط الارتباطات مضغوطة نسبياً ولذلك فإن التحليل العاملي يُعطي *عوامل* واضحة وموثوقة. وتُعتبر القيم بين 0.5 و 0.7 متواضعة، والقيم بين 0.7 و 0.8 جيدة، والقيم بين 0.8 و 0.9 ممتازة، والقيم الأكبر من 0.9 رائعة.

معيار *Kaiser*: إحدى طرق *الاستخراج* في *التحليل العاملي* وتعتمد على فكرة الاحتفاظ *بالعوامل* التي تكون القيم الخاصة المرتبطة بها أكبر من 1. وتبدو هذه الطريقة دقيقة عندما يكون عدد المتحولات في التحليل أقل من 30 وجميع *التشاركيات* الناتجة (بعد الاستخراج) أكبر من 0.7، أو عندما يزيد حجم العينة على 250 وتكون التشاركية المتوسطة أكبر من أو تساوي 0.6.

معامل *Kendall's tau*: معامل ارتباط لابارامتري مشابه *لمعامل ارتباط* Spearman، ويفضل استخدامه عند وجود مجموعة صغيرة من البيانات مع عدد كبير من المراتب المتعادلة.

اختبار *Kendall' W*: يشبه *اختبار* Friedman's ANOVA ولكنه يُستخدم بشكل خاص للنظر إلى التوافق بين المحكّمين.

اختبار *Kolmogorov-Smirnov*: اختبار لمعرفة فيما إذا كان توزيعٌ للعلامات مختلفاً بشكل كبير عن *التوزيع الطبيعي*. وتدل القيمة الكبيرة على انحراف عن الطبيعية، ولكن هذا الاختبار معروف بتأثره بالعينات الكبيرة حيث تؤدي الانحرافات الصغيرة عن الطبيعية إلى نتائج مهمة.

اختبار *Kolmogorov-Smirnov Z*: يجب عدم الخلط بينه وبين *اختبار* Kolmogorov-Smirnov الذي يختبر فيما إذا كانت العينة مأخوذة من مجتمع ذي توزيع طبيعي. يختبر هذا الاختبار فيما إذا كانت مجموعتان قادمتين من نفس المجتمع (بغض النظر عن حالة ذلك المجتمع). ويشبه *اختبار* Mann-Whitney و *اختبار* Wilcoxon *لمجموع المراتب*. ويميل هذا الاختبار لامتلاك قدرة أفضل من اختبار Mann-Whitney عندما تكون أحجام العينات أقل من 25 في كل مجموعة.

اختبار *Kruskal-Wallis*: اختبار لابارامتري لما إذا كانت ثلاث مجموعات مستقلة على الأقل هي مختلفة. وهو النسخة اللابارامترية من *تحليل التباين وحيد الاتجاه المستقل*.

درجة التحدب *(Kurtosis)*: تقيس الدرجة التي تتراكم فيها العلامات في أطراف *توزيع تكراري* ما. التوزيع *المسطّح* هو توزيع يملك العديد من العلامات في الأطراف ولذلك فهو مسطّح تقريباً. وبالمقابل فالتوزيع *المدبب* هو رقيق نسبياً في الأطراف ولذلك فهو مدبب تقريباً.

المحول المستتر *(Latent variable)*: متحول لا يمكن قياسه مباشرة، ولكن يُفترض أنه متعلق بعدة متحولات يمكن قياسها.

المدبب *(Leptokurtic)*: انظر *درجة التحدب*.

اختبار *Levene*: يختبر الفرضية التي تنص على أن التباينات في المجموعات المختلفة هي متساوية (أي أن الفرق بين التباينات يساوي 0). وتشير النتيجة ذات الدلالة إلى أن التباينات هي مختلفة بشكل كبير، ولذلك فإن فرضية *تجانس التباين* لا تكون محققة. عندما تكون أحجام العينات كبيرة فإن الفروق الصغيرة في تباينات المجموعات يمكن أن تعطي اختبار Levene ذا دلالة ولذلك فإن *نسبة التباين* تكون مفيدة كتحقق مضاعف.

الفعالية *(Leverage)*: تقيس تأثير القيمة المشاهدة لمتحول النتيجة على القيم المتوقعة. وقيمة الفعالية هي (k+1)/n حيث k عدد *المتحولات التنبؤية* في النموذج، و n عدد المشتركين. يمكن أن تقع قيم الفعالية بين 0 (ليس للحالة أي تأثير) و 1 (للحالة تأثير كامل على التنبؤ). إذا لم تمارس أي حالة تأثيراً على النموذج فإننا نتوقع أن تكون جميع قيم الفعالية قريبة من القيمة المتوسطة. وقد نصح Hoaglin & Welsch (1978) بدراسة الحالات التي تكون أكبر من ضعف المتوسط (أي 2(k+1)/n) كما نصح Stevens (1992) باستخدام ثلاثة أضعاف المتوسط (أي 3(k+1)/n) كنقطة حدية للتعرف على الحالات ذات التأثير. تدعى أيضاً باسم *قيم القبعة*.

الاحتمالية *(Likelihood)*: احتمال الحصول على مجموعة المشاهدات عند إعطاء بارامترات النموذج الملائم لهذه المشاهدات.

النموذج الخطي *(Linear model)*: نموذج خطي مبني على خط مستقيم.

التراجع المنطقي *(Logistic regression)*: نسخة من *التراجع المتعدد* تكون فيه النتيجة متحولاً *ثنائي التفرع*.

لوغاريتم الاحتمالية *(Log-Likelihood)*: مقياس للخطأ أو التغاير غير المبرر في النماذج الفئوية. ويعتمد على جمع الاحتمالات المرتبطة مع قيم النتيجة المتوقعة والفعلية، ويشبه *مجموع المربعات الباقي* في *التراجع المتعدد* من حيث أنه مؤشر على مقدار المعلومات غير المبررة بعد ملاءمة النماذج الإحصائية، وذلك لأنه كلما كانت قيمة لوغاريتم الاحتمالية أكبر كانت المشاهدات غير المبررة أكثر.

التحليل الخطي اللوغاريتمي *(Loglinear analysis)*: إجرائية مستخدمة كتوسيع *لاختبار كاي مربع* لتحليل الأوضاع التي تحوي أكثر من *متحولين فئويين* وعلينا البحث عن العلاقات بين هذه المتحولات. يتم بشكل أساسي ملاءمة *نموذج خطي* للبيانات التي تتنبأ بالتكرارات المتوقعة (أي عدد الحالات المتوقعة في فئة معينة). وهو بذلك يشبه *تحليل التباين* ولكن من أجل بيانات فئوية بشكل كامل.

الحد السفلي *(Lower bound)*: الاسم المعطى للقيمة الدنيا الممكنة *لتقدير* Greenhouse-Geisser *للكروية*. ونعطى قيمته بالعلاقة 1/(k-1) حيث k عدد الحالات التجريبية للمعالجة.

مسافة *Mahalanobis (Mahalanobis distance)*: تقيس تأثير حالة ما بفحص المسافة للحالات عن *المتوسط* للمتحول التنبؤي (أو المتوسطات للمتحولات التنبؤية). وعلينا البحث عن الحالات ذات القيم الكبرى. وليس من السهل تحديد نقطة حدية للقلق، مع أن Barnett & Lewis (1998) أنتجا جدولاً للقيم الحرجة يعتمد على عدد المتحولات التنبؤية وحجم العينة. ومن الواضح من هذا العمل أنه حتى من أجل العينات الكبيرة (N=100) و 5 متحولات تنبؤية فإن القيم التي تكون أكبر من 25 هي سبب للقلق. أما في العينات الصغيرة (N=100) وعدد أقل من المتحولات التنبؤية (3 مثلاً) فإن القيم التي تكون أكبر من 15 هي إشكالية، وفي العينات الصغيرة جداً (N=30) ومتحولَين تنبؤيين فإن يجب فحص القيم التي تكون أكبر من 11.

الأثر الرئيسي *(Main effect)*: الأثر الفريد أو الوحيد *لمتحول تنبؤي* (أو *متحول مستقل*) على *متحول النتيجة*. ويُستخدم هذا المصطلح عادة ضمن إطار *تحليل التباين*.

اختبار *Mann-Whitney*: اختبار *لابارامتري* يبحث عن الفروق بين عينتين مستقلتين. إنه يختبر فيما إذا كان للمجتمعات التي سحب العينتين منها نفس الموقع. وهو *اختبار* Wilcoxon *لمجموع المراتب* من ناحية الوظيفة. وكلاهما مكافئان لابارامتريان *لاختبار* t *المستقل*.

المصفوفة *(Matrix)*: مجموعة من الأرقام مرتبة في صفوف وأعمدة. تدعى القيم ضمن المصفوفة بالمكونات أو العناصر.

اختبار *Mauchly*: اختبار لفرضية *الكروية*. إذا كان لهذا الاختبار دلالة إحصائية فإن فرضية الكروية تكون غير محققة ويجب تطبيق تصحيح مناسب على *درجات الحرية* للنسبة F في *تحليل التباين للقياسات المكررة*. ويعمل الاختبار على مقارنة *مصفوفة التباين-التباين المشترك* للبيانات مع *مصفوفة محايدة*، فإذا كانت مصفوفة التباين-التباين المشترك هي عبارة عن جداء عدد سلمي بمصفوفة محايدة فإن فرضية الكروية محققة.

تقدير الاحتمالية العظمى *(Maximum-likelihood estimation)*: طريقة لتقدير البارامترات الإحصائية باختبار البارامترات التي ترجح حدوث البيانات. تخيل أنه من أجل مجموعة من البارامترات قمنا بحساب احتمال الحصول على البيانات المشاهدة: إذا كان هذا الاحتمال مرتفعاً فإن هذه البارامترات تعطي تلاؤماً جيداً للبيانات، أما إذا كان الاحتمال منخفضاً فإن هذه البارامترات تعطي تلاؤماً سيئاً للبيانات. وتختار هذه الطريقة البارامترات التي ترفع الاحتمال إلى القيمة العظمى.

اختبار *McNemar*: يختبر الفروق بين مجموعتين مرتبطتين (انظر *اختبار* Wilcoxon *للمرتبة ذات الإشارة* و *اختبار الإشارة*) عند وجود *بيانات اسمية*. ويُستخدم عادة عند البحث عن التغيرات في علامات الأشخاص ويقارن نسبة الأشخاص الذين تغيرت استجاباتهم باتجاه معين (كازدياد العلامات مثلاً) مع نسبة الأشخاص الذين تغيرت استجاباتهم بالاتجاه المعاكس (انخفاض العلامات). ولذلك يجب استخدام هذا الاختبار عند وجود متحولين مرتبطين.

المتوسط *(Mean)*: نموذج إحصائي بسيط للمركز في توزيع من العلامات. وهو تقدير افتراضي للعلامة النموذجية.

متوسط المربعات *(Mean squares)*: مقياس للتغايرية المتوسطة. ومن أجل كل *مجموع للمربعات* (الذي يقيس التغايرية الكلية) يمكن إنشاء متوسط المربعات بتقسيم مجموع المربعات على عدد العناصر المستخدمة في حساب هذا المجموع (أو تابع له).

الوسط *(Median)*: العلامة الوسطى لمجموعة من المشاهدات المرتبة. عند وجود عدد زوجي من المشاهدات فإن الوسط هو قيمة المتوسط للعلامتين اللتين تقعان على جانبي ما سيكون القيمة الوسطى.

اختبار الوسط *(Median test)*: اختبار لابارامتري لمعرفة فيما إذا كانت العينات مسحوبة من مجتمع له نفس *الوسط*. لذلك فهو يقوم بنفس عمل *اختبار* Kruskal-Wallis. ويعمل على أساس إنتاج جدول الأحداث المحتملة المقسم من أجل كل مجموعة إلى عدد العلامات التي تقع أعلى وأدنى من الوسط المشاهد لمجموعة البيانات كاملة. إذا كانت المجموعات من نفس المجتمع فعلينا أن نتوقع أن تكون التكرارات ذاتها في جميع الحالات (حوالي 50% أعلى وحوالي 50% أدنى).

تحليل التباين المختلط *(Mixed ANOVA)*: *تحليل التباين* المستخدم في حالة *التصميم المختلط*.

التصميم المختلط *(Mixed design)*: تصميم تجريبي يشمل اثنين من المتحولات التنبؤية على الأقل وقد تم التلاعب بأحد هذه المتحولات على الأقل باستخدام مشتركين مختلفين (أو كيانات مختلفة) وتم التلاعب بأحد هذه المتحولات على الأقل باستخدام نفس المشتركين (أو الكيانات). يُعرف أيضاً بتصميم الأرض المقسومة Split-plot لأن Fischer طوّر طريقة *تحليل التباين* لتحليل بيانات زراعية تتضمن قطعاً من الأراضي تحوي محاصيل زراعية.

المنوال *(Mode)*: العلامة الأكثر تكراراً في مجموعة من البيانات.

مجموع المربعات للنموذج *(Model sum of squares)*: مقياس للمقدار الكلي من التغايرية الذي يساهم به النموذج. وهو الفرق بين *المجموع الكلي للمربعات* و *مجموع المربعات الباقي*.

طريقة مونت كارلو *(Monte Carlo method)*: مصطلح ينطبق على العملية التي تستخدم نماذج البيانات لحل المسائل الإحصائية.

اختبار *Moses Extreme Reactions*: اختبار لابارامتري يقارن التغايرية للعلامات في مجموعتين، ولذلك فهو يشبه *اختبار* Levene اللابارمتري لحد ما.

الارتباط الخطي المتعدد *(Multicollinearity)*: حالة يكون فيها متحولان على الأقل مرتبطان خطياً إلى حدٍ كبير جداً.

متعدد المنوال *(Multimodal)*: وصف لتوزيع المشاهدات التي تحوي أكثر من *منوالين* اثنين.

مضاعف *(Multiple R) R*: معامل *الارتباط المتعدد*. وهو معامل الارتباط بين القيم المشاهدة في نتيجة ما وقيم النتيجة المتوقعة من قِبَل نموذج *التراجع المتعدد*.

التراجع المتعدد *(Multiple regression)*: توسيع لمفهوم *التراجع البسيط* حيث يتم التنبؤ بنتيجة ما عن طريق تركيب خطي من اثنين أو أكثر من المتحولات التنبؤية. ويكون شكل النموذج هو $Y_i=(b_0+ b_1X_1+ b_2X_2+ ...+ b_nX_n)+\varepsilon_i$ حيث تدل Y على *متحول النتيجة*، و X *المتحول التنبؤي*. ولكل متحول تنبؤي معامل تراجع b_i مرتبط به، و b_0 هي قيمة النتيجة عندما تكون جميع المتحولات التنبؤية مساوية للصفر.

متعدد المتغيرات *(Multivariate)*: مصطلح يدل على عمليات التحليل التي تحوي اثنين من *متحولات النتيجة* على الأقل (مثل *التحليل متعدد المتغيرات للتباين* و *تحليل المكونات الرئيسية* وغيرها).

التحليل متعدد المتغيرات للتباين *(Multivariate analysis of variance) MANOVA*: عائلة الاختبارات التي توسّع *تحليل التباين* الأساسي للأوضاع التي يتم فيها قياس اثنين من *متحولات النتيجة* على الأقل.

الطبيعية متعددة المتغيرات *(Multivariate normality)*: توسيع لمفهوم *التوزيع الطبيعي* إلى عدة متحولات. إنه *توزيع احتمالي* لمجموعة من المتحولات $v'=[v_1, v_2, ..., v_n]$ معطى بالعلاقة:

$$f(v_1, v_2, \ldots, v_n) = 2\pi^{-\frac{n}{2}} \cdot |\Sigma|^{-\frac{1}{n}} \cdot \exp\left[-\frac{1}{2}(v-\mu)'\Sigma^{-1}(v-\mu)\right]$$

حيث μ شعاع قيم المتوسط للمتحولات، و Σ *مصفوفة التباين–التباين المشترك*.

معامل *Nagelkerke's R^2_N*: نسخة من *معامل التحديد* من أجل *التراجع المنطقي*. وهو شكل معدّل من *معامل* Cox and Snell's R^2_{CS} الذي يتغلب على مشكلة عدم مقدرة هذه الإحصائية الوصول إلى قيمتها العظمى.

سلبي الميلان (Negative skew): انظر *الميلان*.

البيانات الاسمية (Nominal data): الأرقام تمثل الأسماء فقط، كالأرقام على قمصان الرياضيين، فاللاعب الذي يحمل قميصه الرقم 1 ليس بالضرورة أسوأ من اللاعب صاحب الرقم 2.

الاختبارات اللابارامترية (Non-parametric tests): عائلة من الاجرائيات الإحصائية التي لا تعتمد على الفرضيات الصارمة للاختبارات البارامترية. وبشكل خاص فهي لا تفترض أن البيانات تأتي من توزيع طبيعي.

التوزيع الطبيعي (Normal distribution): *توزيع احتمالي* لمتحول عشوائي معروف بخصائص محددة. وهو متناظر تماماً (قيمة *الميلان* تساوي 0) وقيمة *درجة التحدب* هي 0.

فرضية العدم (Null hypothesis): عكس *الفرضية التجريبية* وتنص على أن التوقع خاطئ وأن الأثر المتوقع غير موجود.

المتحولات العددية (Numeric variables): التحولات التي تتضمن الأرقام.

الدوران المائل (Oblique rotation): إحدى طرق *الدوران في التحليل العاملي*، وتسمح بأن تكون *العوامل* القاعدية مرتبطة.

الأرجحية (Odds): احتمال حدوث حدث معين مقسوماً على احتمال عدم حدوثه.

نسبة الأرجحية (Odds ratio): وهي نسبة *الأرجحية* لحدوث حدث معين في مجموعة ما مقارنة بمجموعة أخرى. عندما تكون نسبة الأرجحية تساوي *1* فإن الأرجحية لنتيجة ما هي متساوية في كلتا المجموعتين.

مربع أوميغا (Omega squared): مقياس *لحجم الأثر* أقل انحيازاً من *إيتا مربع* مرتبط *بتحليل التباين*. وهو تابع *لمجموع المربعات للنموذج* و *لمجموع المربعات الباقي*، ويقيس الأثر الكلي في تحليل التباين ولذلك لا يمكن تفسيره بطريقة مفيدة. أما في بقية المجالات فهو جيد.

الاختبار وحيد الطرف (One-tailed test): اختبار *لفرضية موجّهة* حيث يتم تحديد اتجاه العلاقة سلفاً (انظر *الاختبار ثنائي الطرف*).

البيانات الترابية (Ordinal data): هي البيانات التي تدلنا على حدوث الأحداث وعلى ترتيب حدوثها أيضاً، ولكنها لا تعطي أي شيء عن الفروق بين القيم. فعلى سبيل المثال تعتبر الميداليات الذهبية والفضية والبرونزية ترابية، فهي تدل على أن الحائز على الميدالية الذهبية هو أفضل من الحائز على الميدالية الفضية، ولكنها لا تدل على مقدار الأفضلية.

المتعامد (Orthogonal): عمودي (أي أنه يصنع زاوية قائمة) على شيء ما، ويساوي *الاستقلال* في الإحصاء لأن المعنى الضمني *للنماذج الخطية* المتعامدة في الفضاء الهندسي هو أنها مستقلة بشكل كامل (لا يتأثر أحدها بالآخر).

الدوران المتعامد (Orthogonal rotation): إحدى طرق *الدوران* في *التحليل العاملي*، وتحافظ على استقلال *العوامل* القاعدية (غير مرتبطة).

متحول النتيجة (Outcome variable): المتحول الذي نحاول التنبؤ بقيمه من خلال واحد أو أكثر من *المتحولات التنبؤية*.

القيمة المنعزلة (Outlier): نقطة من البيانات المشاهدة مختلفة جداً عن بقية النقاط. وتؤثر هذه النقاط على الإحصائيات مثل *المتوسط*.

المقارنات الزوجية (Pairwise comparisons): المقارنات لزوج من قيم *المتوسط*.

الاختبار البارامتري (Parametric test): اختبار يتطلب أن تكون البيانات من أحد التوزيعات التي قام الإحصائيون بتوصيفها في كتالوج ضخم. ويُستخدم هذا المصطلح عادة من أجل الاختبارات البارامترية المعتمدة على *التوزيع الطبيعي* والذي يتطلب تحقيق الفرضيات الأساسية الأربع ليكون الاختبار دقيقاً: التوزيع الطبيعي للبيانات (انظر *التوزيع الطبيعي*)، *تجانس التباين*، *بيانات المجال* أو *بيانات النسبة*، و *الإستقلال*.

الارتباط الجزئي (Partial correlation): مقياس للعلاقة بين متحولين عند التحكم بأثرِ واحدٍ أو أكثر من المتحولات الإضافية عليهما.

مصفوفة النمط (Pattern matrix): مصفوفة في *التحليل العاملي* تحوي *معاملات التراجع* لكل متحول على كل *عامل* في البيانات (انظر *مصفوفة البنية*).

معامل Pearson للارتباط (Pearson's correlation coefficient): اسمه الكامل معامل Pearson للارتباط العزومي لحواصل الضرب، وهو مقياس *معياري* لقوة العلاقة بين متحولين. ويمكن أن يأخذ أي قيمة من 1- (عندما يتغير أحد المتحولين فإن المتحول الثاني يتغير بنفس المقدار ولكن بالاتجاه المعاكس) مروراً بالقيمة 0 (عندما يتغير أحد المتحولين فإن المتحول الثاني لا يتغير) وصولاً إلى القيمة 1+ (عندما يتغير أحد المتحولين فإن المتحول الثاني يتغير بنفس المقدار وبنفس بالاتجاه).

الارتباط الخطي التام (Perfect collinearity): ويحدث عندما يكون أحد *المتحولات التنبؤية* على الأقل في *نموذج التراجع* تركيباً خطياً لبقية المتحولات (وأبسط مثال هو حالة متحولين تنبؤيين مرتبطين بشكل تام، أي أن معامل الارتباط يساوي 1).

اختبار Phi: مقياس لقوة العلاقة بين اثنين من *المتحولات الفئوية*. ويُستخدم من أجل جداول الأحداث المحتملة ذات الأبعاد 2×2 (حالة متحولين فئويين لكل منهما فئتان فقط). وهي شكل مختلف من *اختبار كاي مربع*: $\phi=\sqrt{(\chi^2/n)}$ حيث n العدد الكلي للمشاهدات.

أثر Pillai-Bartlett (V): *إحصائية اختبار* في *التحليل متعدد المتغيرات للتباين*، وتساوي مجموع نسب التباين المبرر في *متغيرات التابع المميز* للبيانات. وهكذا فهي تشبه النسبة SS_M/SS_T.

المقارنات المنظمة (Planned comparisons or Planned contrasts): مجموعة من المقارنات بين قيم المتوسط للمجموعات التي تم بناؤها قبل جمع أي بيانات. وهي مقارنات مقادة نظرياً وتعتمد على فكرة تجزئة *التباين* الناتج عن الأثر الكلي لفروق المجموعات إلى أجزاء متدرجة بالصغر. ولهذه المقارنات قدرة أكبر من اختبارات post hoc.

المسطّح (Platykurtic): انظر *درجة التحدب*.

الارتباط ثاني التسلسل النقطي (Point-biserial correlation): مقياس معياري لقوة العلاقة بين متحولين عندما يكون أحدهما *ثنائي التفرع*. ويُستخدم هذا المقياس عندما تكون ثنائية التفرع منفصلة أو صحيحة (أي عدم وجود استمرار خفي بين الفئات). وكمثال عن ذلك يمكن أن نذكر الحَمْل، فالمرأة يمكن أن تكون حاملاً أو غير حامل.

المقارنة ذات كثير الحدود (Polynomial contrast): مقارنة تختبر المناحي في البيانات. وتبحث في شكلها الأولي جداً عن المنحى الخطي (أي أن قيم *المتوسط* للمجموعات تزداد بشكل متناسب).

المجتمع (Population): يُستخدم هذا المصطلح في الإحصاء للإشارة إلى تجمع من الوحدات (كالبشر أو النباتات أو المدن أو المنتحرين أو غيرهم) حيث نريد تعميم النتائج أو النموذج الإحصائي.

إيجابي الميلان (Positive skew): انظر *الميلان*.

اختبارات post hoc: مجموعة من المقارنات بين قيم المتوسط للمجموعات التي لم يتم التفكير بها قبل جمع البيانات. وتتضمن هذه الاختبارات عادة مقارنة قيم المتوسط لكل التراكيب المحتملة المكونة من اثنتين من الحالات التجريبية. ولتعويض عدد الاختبارات المنفّذة فإن كل اختبار يستخدم معياراً صارماً للدلالة. ولذلك تكون هذه الاختبارات أقل قدرة من *المقارنات المنظمة*. وتُستخدم عادة في الأعمال الاستكشافية التي لا تتوفر فيها فرضيات مؤكدة يمكن اعتمادها لإجراء مقارنات منظمة.

القدرة (Power): قابلية اختبار ما على اكتشاف أثر ذي حجم معين (وتعتبر القيمة 0.8 جيدة).

أثر الممارسة (Practice effect): إمكانية أن يتأثر أداء مشترك ما في مهمة (إيجابياً أو سلبياً) إذا كرر المهمة، وذلك بسبب معرفته بالحالة التجريبية و/أو القياسات المستخدمة.

المتحول التنبؤي (Predictor): متحول مستخدم لمحاولة التنبؤ بقيم متحول آخر يدعى *متحول النتيجة*.

تحليل المكونات الرئيسية PCA (Principal component analysis): تقنية *متعددة المتغيرات* لتحديد المكونات الخطية لمجموعة من المتحولات.

التوزيع الاحتمالي (Probability distribution): منحني يصف *التوزيع التكراري* المثالي لمتحول معين ويسمح بالتحقق من الاحتمال الذي ستحدث به قيم محددة من ذلك المتحول. ومن أجل *المتحولات الفئوية* يكون هو الصيغة التي تعطي الاحتمال الذي تحدث به كل فئة.

طريقة Promax: إحدى طرق *الدوران المائل* ويتم حسابها بشكل أسرع من *طريقة* Direct oblimin ولذلك فهي مفيدة في المجموعات الكبيرة من البيانات.

المنحى التربيعي (Quadratic trend): إذا وصلنا قيم المتوسط في الحالات التجريبية المرتّبة بخط فإن المنحى التربيعي يظهر بشكل تغير واحد في اتجاه ذلك الخط (أي أن الخط ينحني في مكان واحد فقط) ولهذا يكون شكل الخط مثل الحرف *U*. ويجب أن تتوفر ثلاث حالات مرتبة على الأقل للحصول على المنحى التربيعي.

المنحى الرباعي (Quartic trend): إذا وصلنا قيم المتوسط في الحالات التجريبية المرتّبة بخط فإن المنحى الرباعي يظهر بشكل ثلاثة تغيرات في اتجاه ذلك الخط. ويجب أن تتوفر خمس حالات مرتبة على الأقل للحصول على المنحى الرباعي.

طريقة Quartimax: إحدى طرق *الدوران المتعامد* وتحاول توسيع انتشار قيم *التحميل للعامل* من أجل متحول ما عبر جميع *العوامل*. وينتج عن ذلك الكثير من المتحولات المحمّلة على عامل واحد.

التباين العشوائي (Random variance): التباين الخاص بمتحول معين ولكنه غير موثوق.

العشوائية (Randomization): عملية تنفيذ الأعمال بطريقة لامنهجية أو عشوائية. وضمن إطار البحث التجريبي فإن هذا المصطلح ينطبق على التعيين العشوائي للمشتركين في حالات المعالجة المختلفة.

بيانات النسبة (Ratio data): هي *بيانات المجال* ولكن مع خاصية إضافية هي أن للنسب معنى مفيد. فعلى سبيل المثال يمكن للأشخاص تقييم هذا الكتاب ضمن مجال يتراوح بين 1 و 5. ولكي تكون هذه البيانات بيانات نسبة فلا يكفي أن تملك خصائص بيانات المجال ولكن يجب أن يكون التقييم بالعلامة 4 على سبيل المثال يمثل شخصاً استمتع بمقدار ضعفي استمتاع شخص آخر أعطى التقييم 2. وبشكل مشابه فإن الشخص الذي أعطى العلامة 1 يكون استمتاعه مساوياً لنصف استمتاع الشخص الذي أعطى التقييم 2.

معامل التراجع (Regression coefficient): انظر *المعامل* b_i و *المعامل* β_i.

نموذج التراجع (Regression model): انظر *التراجع البسيط* و *التراجع المتعدد*.

التصميم المرتبط (Related design): اسم آخر *لتصميم القياسات المكررة*.

التصميم العاملي المرتبط (Related factorial design): تصميم تجريبي يشمل اثنين من *المتحولات التنبؤية* (أو *المتحولات المستقلة*) على الأقل وقد تم التلاعب بها جميعاً باستخدام نفس المشتركين (أو الكيانات المختبرة).

الوثوقية (Reliability): قابلية مقياس ما على إنتاج نتائج منسجمة عند قياس نفس الكيانات وتحت نفس الشروط.

المقارنة المكررة *(Repeated contrast)*: *مقارنة منظمة* غير متعامدة تقارن المتوسط في كل حالة تجريبية (باستثناء الحالة الأولى) مع المتوسط للحالة السابقة.

تحليل التباين للقياسات المكررة *(Repeated-measures ANOVA)*: *تحليل التباين* المنفّذ على أي تصميم تم فيه قياس جميع *المتحولات المستقلة* باستخدام نفس المشتركين في جميع الحالات التجريبية.

تصميم القياسات المكررة *(Repeated-measures design)*: تصميم تجريبي تُستخدم فيه حالات المعالجة المختلفة نفس المشتركين ولذلك فإن البيانات الناتجة هي مرتبطة (يدعى أيضاً *بالتصميم المرتبط* أو *التصميم ضمن المواضيع*).

الباقي *(Residual)*: الفرق بين القيمة التي يتوقعها نموذج ما والقيمة المشاهدة في البيانات التي يستند إليها النموذج. عند حساب الباقي لكل مشاهدة في مجموعة البيانات فإن المجموعة الناتجة تدعى *البواقي*.

البواقي *(Residuals)*: انظر *الباقي*.

مجموع المربعات الباقي *(Residual sum of squares)*: مقياس للتغايرية التي لا يمكن تبريرها بالنموذج الملائم للبيانات. ويساوي مربع *الحيدان* الكلي بين المشاهدات وقيم هذه المشاهدات المتوقعة من قِبَل النموذج المستخدم لملاءمة البيانات.

مقارنة *Helmert* المعكوسة *(Reverse Helmert contrast)*: اسم آخر *لمقارنة الفرق*.

إحصائية *Rao* للعلامة الفعّالة *(Rao's efficient score statistic)*: إحصائية تقيس الشيء الذي تقيسه *إحصائية Wald* ولكن حسابها أسهل.

الدوران *(Rotation)*: عملية مستخدمة في *التحليل العاملي* لتحسين تفسير *العوامل*. وهي محاولة في الأساس لإجراء تحويل للعوامل الناتجة عن التحليل بحيث ترفع قيم *تحميل العوامل* الكبيرة إلى الحد الأقصى، وتخفض قيم تحميل العوامل الصغيرة إلى الحد الأدنى. وهناك طريقتان لتنفيذها: *الدوران المائل* و *الدوران المتعامد*.

جذر *Roy* الأكبر *(Roy's Largest root)*: *إحصائية اختبار في التحليل متعدد المتغيرات للتباين*. وهي القيمة الخاصة لأول متغير *للتابع المميز* لمجموعة من المشاهدات. ولذلك فهي تشبه *أثر* Hotelling-Lawley ولكن من أجل المتغير الأول فقط. ويمثل نسبة التباين المبرر إلى التباين غير المبرر (SS_M/SS_R) من أجل *التابع المميز* الأول.

العينة *(Sample)*: مجموعة صغيرة (ولكن ممثِّلة) من *المجتمع* تُستخدم لتحديد الحقائق عن ذلك المجتمع (كيف يتصرف المجتمع المعني في ظروف معينة).

توزيع أخذ العينات *(Sampling distribution)*: *التوزيع الاحتمالي* لإحصائية ما. إذا أخذنا *عينة* ما من مجتمع ما وحسبنا إحصائية معينة (مثل *المتوسط*) فإن قيمة هذه الإحصائية ستعتمد نوعاً ما على

العينة المأخوذة. وهكذا فإن الإحصائية ستتغير بشكل طفيف جداً من عينة إلى أخرى. وعلى فرض أننا أخذنا عدداً كبيراً من العينات من المجتمع وحسبنا الإحصائية المطلوبة فإنه يمكننا إنشاء توزيع تكراري للقيم التي حصلنا عليها. والتوزيع الناتج هو ما يمثله توزيع أخذ العينات، أي أنه التوزيع للقيم الممكنة لإحصائية ما والتي نتوقع الحصول عليها من مجتمع معين.

النموذج المشبّع *(Saturated model)*: نموذج يلائم البيانات بشكل تام، ولذلك لا يوجد خطأ أبداً. ويحوي جميع *الآثار الرئيسية* الممكنة وحدود *التفاعل* بين المتحولات.

المخطط المبعثر *(Scatter plot)*: مخطط يرسم قيم أحد المتحولات مقابل القيمة الموافقة لمتحول آخر (ويمكن تضمين القيمة الموافقة لمتحول ثالث على مخطط مبعثر ثلاثي الأبعاد).

مخطط المنحدر *(Scree plot)*: مخطط يرسم كل *عامل في التحليل العاملي* على المحور الأفقي مقابل القيمة الخاصة المرتبطة به على المحور الشاقولي. فيعرض الأهمية النسبية لكل عامل. وللمخطط شكل مميز (هناك انحدار حاد في المنحني تليه مرحلة تلاشي) وتُستخدم نقطة الانعطاف لهذا المنحني كوسيلة *لاستخراج العوامل*. ومن أجل عينة تحوي أكثر من 200 مشترك فإن هذا المخطط يوفر معياراً موثوقاً لاستخراج العوامل.

الارتباط شبه الجزئي *(Semi-partial correlation or Part correlation)*: مقياس للعلاقة بين متحولين عند التحكم بأثر واحد أو أكثر من المتحولات الإضافية على أحد هذين المتحولين. إذا دعونا المتحولين x و y فإن هذا المقياس يعطي قياساً للتباين في y الذي يشاركه به x فقط.

التقلص *(Shrinkage)*: فقدان *القدرة* التنبؤية لنموذج التراجع إذا كان هذا النموذج مشتقاً من المجتمع الذي أخذنا منه العينة بدلاً من العينة ذاتها.

تصحيح *Sidak*: شكل أقل صرامة من *تصحيح Bonferroni*.

اختبار الإشارة *(Sign test)*: يختبر فيما إذا كانت عينتان مرتبطتان مختلفتين. ويقوم بنفس عمل *اختبار* Wilcoxon *للمرتبة ذات الإشارة*. يتم حساب الفروق بين الحالات التجريبية وتحليل إشارة الفرق (سالبة أو موجبة) لمعرفة اتجاه الفرق. ويكون مطال الفرق مهملاً (بخلاف *اختبار* Wilcoxon حيث تدلنا المرتبة عن المطال النسبي للتغير)، ولهذا السبب فإنه يفتقد *القدرة*. على كل حال يمكن حسابه بسهولة وتحليل البيانات بسرعة دون استخدام الحاسب.

المقارنة البسيطة *(Simple contrast)*: *مقارنة منظمة* غير متعامدة تقارن *المتوسط* في كل حالة مع المتوسط للحالة الأولى أو الأخيرة بناءً على طريقة تحديدها.

تحليل الآثار البسيطة *(Simple effects analysis)*: ينظر هذا التحليل إلى الأثر لأحد *المتحولات المستقلة* (*المتحول التنبؤي* الفئوي) عند المستويات المنفصلة لمتحول مستقل آخر.

التراجع البسيط *(Simple regression)*: *نموذج خطي* يتم فيه التنبؤ بمتحول النتيجة باستخدام متحول تنبؤي وحيد. ويأخذ النموذج الشكل التالي: $Y_i=(b_0+ b_1X_1)+\varepsilon_i$ حيث تدل Y على *متحول*

النتيجة، و X *المتحول التنبؤي*، و b_1 معامل التراجع المتعلق بالمتحول التنبؤي، و b_0 هي قيمة النتيجة عندما تكون قيمة المتحول التنبؤي مساوية للصفر.

الميلان *(Skew)*: مقياس للتناظر في *التوزيع التكراري*. وتبلغ قيمته 0 في توزيع متناظر. عندما تتجمع العلامات المتكررة في النهاية الدنيا للتوزيع فإن الذيل يدل على اتجاه العلامات الأعلى أو الأكثر إيجابية وتكون قيمته موجبة. وبالعكس عندما تتجمع العلامات المتكررة في النهاية العليا للتوزيع فإن الذيل يدل على اتجاه العلامات الأدنى أو الأكثر سلبية وتكون قيمته سالبة.

معامل *Spearman* للارتباط *(Spearman's correlation coefficient)*: مقياس معياري لقوة العلاقة بين متحولين لا يعتمد على فرضيات *الاختبار البارامتري*. وهو *معيار* Pearson *للارتباط* عند تنفيذه على البيانات التي تم تحويلها إلى علامات مرتبة.

الكروية *(Sphericity)*: شكل أقل صرامة من *التناظر المركب* يفترض أن التباينات للفروق بين البيانات المأخوذة من نفس المشتركين (أو الكيانات المختبرة) متساوية. ونجد هذه الفرضية عادة في *تحليل البيانات للقياسات المكررة*، ولكنها تطبق عند وجود أكثر من نقطتين من البيانات لنفس المشترك (انظر *تصحيح* Greenhouse-Geisser و *تصحيح* Huynh-Feldt).

وثوقية النصف المشطور *(Split-half reliability)*: مقياس *للوثوقية* نحصل عليه بتقسيم العناصر في مقياس ما إلى نصفين (بطريقة عشوائية) والحصول على علامة من كل نصف من المقياس. ويتم تصحيح *الارتباط* بين العلامتين ليأخذ بعين الاعتبار حقيقة أن الارتباطات مبنية على نصف العناصر فقط ثم يُستخدم لقياس الوثوقية. وهناك طريقتان لتنفيذ ذلك، فقد طوّر Spearman (1910) و Brown (1910) صيغة لا تأخذ *الإنحراف المعياري* للعناصر بعين الاعتبار:

$$r_{sh} = \frac{2r_{12}}{1 + r_{12}}$$

حيث r_{12} الارتباط بين نصفي المقياس. أما Flanagan (1937) و Rulon (1939) فقد اقترحا صيغة تأخذ بعين الاعتبار تباين العنصر:

$$r_{sh} = \frac{4r_{12} \times s_1 \times s_2}{s_T^2}$$

حيث s_1 و s_2 الإنحراف المعياري لكل من نصفي المقياس، s^2_T التباين للاختبار الكلي.

المصفوفة المربعة *(Square matrix)*: مصفوفة فيها عدد الصفوف يساوي عدد الأعمدة.

الانحراف المعياري *(Standard deviation)*: تقدير للتغايرية المتوسطة (الانتشار) لمجموعة من البيانات مقاس بنفس وحدات القياس للبيانات الأصلية، ويساوي الجذر التربيعي *للتباين*.

الخطأ المعياري *(Standard error)*: *الانحراف المعياري* في *توزيع أخذ العينات* لإحصائية ما. فمن أجل إحصائية ما (كالمتوسط مثلاً) يدلنا الخطأ المعياري على مقدار التغايرية الموجودة في الإحصائية

عبر *العينات* من نفس *المجتمع*. ولذلك تدل القيم الكبيرة على أن الإحصائية من عينة ما لا تعكس بدقة المجتمع الذي تم أخذ العينة منه.

الخطأ المعياري للفروق *(Standard error of differences)*: إذا كان علينا أن نأخذ عدة أزواج من العينات من مجتمع ما ونحسب متوسطاتها فإننا نحسب الفروق بين هذه المتوسطات أيضاً. إذا رسمنا الفروق بين متوسطات العينات *كتوزيع تكراري* فيكون لدينا *توزيع أخذ العينات* للفروق. *الانحراف المعياري* لهذا التوزيع هو الخطأ المعياري للفروق. ولذلك فهو مقياس لتغايرية الفروق بين متوسطات العينات.

التوحيد القياسي *(Standardization)*: عملية تحويل متحول ما إلى وحدة معيارية للقياس. ووحدة القياس المستخدمة عادة هي *الانحراف المعياري* (انظر *العلامات المعيارية* z أيضاً). يسمح التوحيد القياسي بمقارنة البيانات عند استخدام وحدات مختلفة للقياس (نستطيع مقارنة الكتل المقدرة بالكيلوغرام مع الأطوال المقاسة بالمتر).

معياري *(Standardized)*: انظر *التوحيد القياسي*.

قيمة *DFBeta* المعيارية *(Standardized DFBeta)*: نسخة معيارية من DFBeta. إن استخدام هذه القيم المعيارية أسهل من DFBeta لأنه يمكن تطبيق نقاط قطع عامة. وقد اقترح Stevens (1992) النظر إلى الحالات التي تكون قيمتها المطلقة أكبر من 2.

قيمة *DFFit* المعيارية *(Standardized DFFit)*: نسخة معيارية من DFFit.

البواقي المعيارية *(Standardized residuals)*: *البواقي* لنموذج ما مقدرة بوحدات *الانحراف المعياري*. تعتبر البواقي المعيارية التي تكون قيمتها المطلقة أكبر من 3.29 (وعادة نستخدم القيمة 3) سبباً للقلق وذلك لأنه في عينة متوسطة فإن قيمة مرتفعة بهذا الشكل لا يرجح أن تحدث بمحض الصدفة. وإذا كانت نسبة المشاهدات التي تتعدى البواقي المعيارية فيها القيمة 2.58 (وعادة نستخدم القيمة 2.5) أكبر من 1% فمن الواضح أن مستوى الخطأ ضمن النموذج غير مقبول (النموذج يلائم بيانات العينة بشكل سيء). وإذا كانت نسبة المشاهدات التي تتعدى القيمة المطلقة للبواقي المعيارية فيها القيمة 1.96 (وعادة نستخدم القيمة 2) أكبر من 5% فمن الواضح أن النموذج يمثل البيانات الفعلية بشكل ضعيف.

التراجع الخطوي *(Stepwise regression)*: إحدى طرق *التراجع المتعدد* يتم فيها إدخال المتحولات إلى النموذج بناءً على معيار إحصائي (*الارتباط شبه الجزئي* مع *متحول النتيجة*). بعد إدخال متحول جديد في النموذج يتم تقييم جميع المتحولات في النموذج لمعرفة المتحولات المطلوب حذفها.

المتحولات النصية *(String variables)*: متحولات تتضمن كلمات (سلاسل من الأحرف). يمكن أن تتضمن هذه المتحولات إجابات على استبيان ما.

مصفوفة البنية (Structure matrix): مصفوفة في *التحليل العاملي* تتضمن *معاملات الارتباط* لكل متحول على كل *عامل* في البيانات. عند استخدام *الدوران المتعامد* تكون هذه المصفوفة هي نفس *مصفوفة النمط*، ولكن عند استخدام *الدوران المائل* فإن هاتين المصفوفتين مختلفتان.

Studentized deleted residual: مقياس لتأثير حالة معينة من البيانات. وهو النسخة المعيارية من *الباقي المحذوف*.

Studentized residuals: شكل آخر من *البواقي المعيارية*، وهو حاصل قسمة *البواقي غير المعيارية* على تقدير *الانحراف المعيار* الذي يتغير من نقطة إلى أخرى. ولهذه البواقي نفس الخصائص للبواقي المعيارية ولكنها تعطي تقديراً أدق لتباين الخطأ لحالة معينة.

مجموع الأخطاء المربعة (Sum of squared errors): اسم آخر *لمجموع المربعات*.

مجموع المربعات SS (Sum of squares): تقدير للتغايرية الكلية (الانتشار) لمجموعة من البيانات. يتم أولاً حساب *الحيدان* لكل علامة ثم حساب مربع هذه القيمة. ومجموع المربعات هو مجموع هذه الحيدانات المربعة.

مصفوفة مجموع المربعات والجداء المتصالب SSCP (Sum of squares and cross-product matrix): *مصفوفة مربعة* العناصر القطرية فيها تمثل *مجموع المربعات* لمتحول معين، والعناصر غير القطرية تمثل *الجداءات المتصالبة* بين زوج من المتحولات. وهذه المصفوفة هي نفس *مصفوفة التباين–التباين المشترك* من حيث المبدأ ولكنها تعبر بالقيم الكلية عن التغايرية والعلاقات بين المتحولات، بينما تعبر مصفوفة التباين–التباين المشترك عن القيم المتوسطة.

الآثار المخمدة (Suppressor effects): وتنتج عندما يكون لمتحول تنبؤي ما أثر هام فقط عند المحافظة على متحول آخر ثابتاً.

القواعد (Syntax): تعليمات مسبقة التعريف مكتوبة لتوجيه برنامج SPSS لتنفيذ ما تريده.

محرر القواعد (Syntax editor): نافذة لكتابة *القواعد* وتنفيذها في برنامج SPSS.

التغاير المنهجي (Systematic variation): التغاير العائد لأثر حقيقي ما (يمكن أن يكون الأثر الناتج عن قيام منفذ التجربة بإجراء ما على جميع المشتركين في *عينة* ما ولكن ليس على بقية العينات، أو التغاير الطبيعي بين المجموعات من المتحولات). ويمكن اعتباره التغاير الذي يمكن أن يبرره النموذج المستخدم لملاءمة البيانات.

الإحصائية t (t-statistic): *إحصائية اختبار* ذات *توزيع احتمالي* معروف (التوزيع *t*). وتُستخدم في إطار التراجع لاختبار فيما إذا كان *معامل التراجع b* مختلفاً بشكل كبير عن الصفر، أما في العمل التجريبي فإنها تُستخدم لاختبار فيما إذا كانت الفروق بين متوسطين مختلفة بشكل كبير عن الصفر (انظر *اختبار t المستقل* و *اختبار t التابع*).

وثوقية الاختبار-إعادة الاختبار *(Test-retest reliability)*: قدرة مقياس ما على إنتاج نتائج منسجمة عند اختبار نفس الكيانات في نقطتين مختلفتين زمنياً.

إحصائية الاختبار *(Test statistic)*: إحصائية نعرف فيها تكرار حدوث القيم المختلفة. وتُستخدم القيم المشاهدة لهذه الإحصائية لاختبار *الفرضيات* عادة.

التسامح *(Tolerance)*: تقيس إحصائيات التسامح *الارتباط الخطي المتعدد*، وهي ببساطة مقلوب *معامل تضخم التباين (1/VIF)*. تدل القيم الأدنى من 0.1 على مشاكل خطيرة، مع أن Menard (1995) قد اقترح أن القيم الأدنى من 0.2 تشكل سبباً للقلق.

المصفوفة T *(Total SSCP)*: *مصفوفة مجموع المربعات والجداء المتصالب* لمجموعة كاملة من المشاهدات، وهي المكافئ *متعدد المتغيرات لمجموع المربعات الكلي*.

مجموع المربعات الكلي *(Total sum of squares)*: مقياس للتغايرية الكلية ضمن مجموعة من المشاهدات. وهو مربع *الحيدان* بين كل مشاهدة والمتوسط الكلي لجميع المشاهدات.

التحويل *(Transformation)*: عملية تطبيق تابع رياضي على جميع المشاهدات في مجموعة البيانات وذلك لتصحيح بعض شذوذ التوزيع مثل *الميلان* أو *التحدب*.

الاختبار ثنائي الطرف *(Two-tailed test)*: اختبار لفرضية غير موجَّهة، ويُستخدم عند عدم تحديد اتجاه العلاقة (انظر *الاختبار وحيد الطرف*).

الخطأ من النوع الأول *(Type I error)*: ويحدث عندما نعتقد بوجود أثر حقيقي في *المجتمع*، بينما لا يوجد أثر حقيقي فعلياً.

الخطأ من النوع الثاني *(Type II error)*: ويحدث عندما نعتقد بعدم وجود أثر حقيقي في *المجتمع*، بينما يوجد أثر حقيقي فعلياً.

التباين الفريد *(Unique variance)*: تباين خاص بمتحول معين (لا يشاركه به أي متحول آخر). ونميل لاستخدام مصطلح التباين الفريد للإشارة إلى التباين الذي يمكن أن ننسبه بشكل موثوق إلى قياس واحد فقط، وإلا فإننا ندعوه *التباين العشوائي*.

وحيد المتغير *(Univariate)*: ويعني متحولاً واحداً، ويُستخدم عادة للإشارة إلى الأوضاع التي يتم فيها قياس *متحول نتيجة* واحد (مثل *تحليل التباين* و *اختبار t* و *اختبار Matt-Whitney* وغيرها).

البواقي غير المعيارية *(Unstandardized residuals)*: *البواقي* لنموذج ما مقدرة بالوحدات المستخدمة لقياس *متحول النتيجة* الأصلي.

التغاير اللامنهجي *(Unsystematic variation)*: التغاير الذي لا يعود للأثر الذي نهتم بدراسته (لذلك يمكن أن يكون عائداً للفروق الطبيعية بين الأشخاص في العينات المختلفة، كالفروق في الذكاء والاندفاع وغيرها). ويمكن اعتباره التغاير الذي لا يمكن تبريره مهما كان النموذج المستخدم لملاءمة البيانات.

عرض المتحولات *(Variable view)*: هناك طريقتان لعرض محتويات *محرر البيانات*. وتسمح طريقة عرض المتحولات بتحديد خصائص المتحولات التي نريد إدخال البيانات فيها (انظر أيضاً *عرض البيانات*).

التباين *(Variance)*: تقدير للتغايرية المتوسطة (الانتشار) لمجموعة من البيانات. ويساوي مجموع *المربعات* مقسوماً على عدد أقل بواحد من عدد القيم المعتمد لحساب مجموع المربعات.

مصفوفة التباين-التباين المشترك *(Variance-Covariance matrix)*: *مصفوفة مربعة* تمثل المتحولات المقاسة. يمثل القطر الرئيسي التباينات ضمن كل متحول، بينما تمثل العناصر غير القطرية *التباينات المشتركة* بين كل زوج من المتحولات.

معامل تضخم التباين *VIF (Variance Inflation Factor)*: مقياس *للارتباط الخطي المتعدد*. يدل VIF فيما إذا كان *لمتحول تنبؤي* ما علاقة خطية قوية مع المتحولات التنبؤية الأخرى. وقد اقترح Myers (1990) أن القيمة 10 هي قيمة جيدة كمعيار لحد القلق. واقترح Bowerman and O'Connell (1990) انه إذا كان VIF أكبر من 1 فإن الارتباط الخطي المتعدد قد يؤثر على *نموذج التراجع*.

نسبة التباين *(Variance ratio)*: نسبة التباين للمجموعة ذات التباين الأكبر إلى التباين للمجموعة ذات التباين الأصغر. إذا كانت هذه النسبة أصغر من 2 فيمكننا افتراض *تجانس التباين* بكل أمان.

قانون جمع التباين *(Variance sum law)*: وينص على أن *التباين* للفرق بين *متحولين مستقلين* يساوي مجموع تباينات هذين المتحولين.

طريقة *Varimax*: إحدى طرق *الدوران المتعامد*. وتحاول توسيع انتشار قيم *تحميل العامل* ضمن *العوامل*. ولذلك فهي تحاول تحميل عدد أقل من المتحولات بشكل أعلى على كل عامل مما يعطي تجمعات من العوامل أسهل تفسيراً.

العارض *(Viewer)*: نافذة في برنامج SPSS يتم فيها عرض الخرج لأي تحليل.

إحصائية *Wald*: *إحصائية اختبار* ذات *توزيع احتمالي* معروف (*توزيع كاي مربع*) وتُستخدم لاختبار فيما إذا كان المعامل b *لمتحول تنبؤي* في نموذج *التراجع المنطقي* مختلفاً بشكل كبير عن الصفر. وتشبه *إحصائية* t في *نموذج التراجع* حيث يكون حاصل قسمة المعامل b على الخطأ المعياري له. تكون إحصائية Wald غير دقيقة عندما يكون معامل التراجع b كبيراً، لأن الخطأ المعياري يتضخم مما يجعل إحصائية Wald مقدرة بأقل من قيمتها.

اختبار *Wald-Wolfowitz*: شكل آخر من *اختبار* Mann-Whitney. يتم ترتيب العلامات حسب المرتبة كما في اختبار Mann-Whitney ولكن بدلاً من تحليل المراتب فإن هذا الاختبار يبحث عن سلاسل العلامات من نفس المجموعة ضمن الترتيب المرتب. إذا لم يكن هناك فرق بين المجموعات فإن المراتب من المجموعتين يجب أن تكون متداخلة الانتشار بشكل عشوائي. أما إذا كانت المجموعتان مختلفتين فإننا يجب أن يجد مراتب أكثر من إحدى المجموعتين عند الطرف الأدنى،

ومراتب أكثر من المجموعة الأخرى عند الطرف الأعلى. وبالبحث عن تجمعات العلامات بهذه الطريقة يمكن حساب الاختبار إذا كانت المجموعات المختلفة.

الأثقال *(Weights)*: عدد نستخدمه لضرب متحول ما. والثقل المعيّن لمتحول ما يحدد التأثير الذي يملكه ذلك المتحول ضمن معادلة رياضية، فالقيمة الكبيرة تعطي المتحول تأثيراً كبيراً.

نسبة *Welch F*: نسخة من *النسبة F* مصممة لتكون دقيقة عندما تكون فرضية *تجانس التباين* غير محققة.

اختبار *Wilcoxon* للمرتبة ذات الإشارة *(Wilcoxon signed-rank test)*: *اختبار لابارامتري* يبحث عن الفروق بين عينتين مرتبطتين. وهو المكافئ اللابارامتري *لاختبار t المرتبط*.

اختبار *Wilcoxon* لمجموع المراتب *(Wilcoxon rank-sum test)*: *اختبار لابارامتري* يبحث عن الفروق بين عينتين مستقلتين. أي أنه يختبر فيما إذا كان للمجتمعان اللذان تم سحب العينتين منهما نفس الموقع. ومن حيث الوظيفة فإنه يشبه *اختبار* Mann-Whitney، والاختباران هما المكافئان اللابارامتريان *لاختبار t المستقل*.

إحصائية *Wilk's lambda* (Λ): *إحصائية اختبار في التحليل متعدد المتغيرات للتباين*. وهي جداء التباين غير المبرر على كل من *متغيرات التابع المميز* ولذلك فهي تمثل نسبة تباين الخطأ إلى التباين الكلي (SS_R/SS_T) لكل متغير.

التصميم ضمن المواضيع *(Within-Subjects design)*: اسم آخر *لتصميم القياسات المكررة*.

تصحيح *Yates* للاستمرارية *(Yates's continuity correction)*: تعديل *لاختبار كاي مربع* عند وجود متحولين فئويين لكل منهما فئتان فقط (جدول الأحداث المحتملة 2x2). في العينات الكبيرة يؤدي التعديل إلى فرق صغير ومشكوك فيه على أية حال.

العلامة المعيارية *z* *(z-score)*: قيمةُ مشاهدة ما مقدرة بوحدات الانحراف المعياري. ويتم حسابها بطرح قيمة *المتوسط* لكل المشاهدات من قيمة المشاهدة وتقسيم الناتج على *الانحراف المعياري* لجميع المشاهدات. وبتحويل توزيع ما للمشاهدات إلى العلامات z نحصل على توزيع جديد له متوسط 0 وانحراف معياري 1.

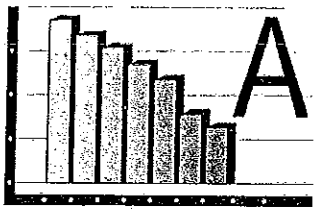

الملحق A

A.1 جدول التوزيع الطبيعي المعياري

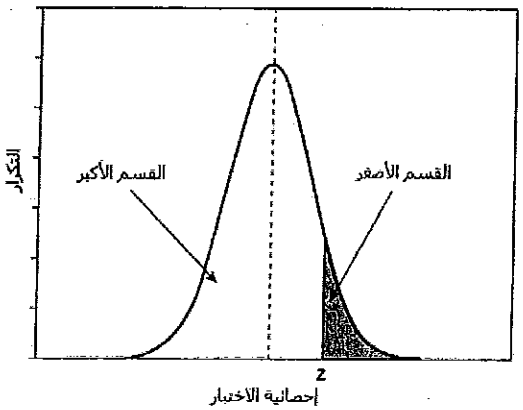

z	القسم الأكبر	القسم الأصغر	y
.00	.50000	.50000	.3989
.01	.50399	.49601	.3989
.02	.50798	.49202	.3989
.03	.51197	.48803	.3988
.04	.51595	.48405	.3986
.05	.51994	.48006	.3984
.06	.52392	.47608	.3982
.07	.52790	.47210	.3980
.08	.53188	.46812	.3977
.09	.53586	.46414	.3973
.10	.53983	.46017	.3970
.11	.54380	.45620	.3965
.12	.54776	.45224	.3961
.13	.55172	.44828	.3956
.14	.55567	.44433	.3951
.15	.55962	.44038	.3945
.16	.56356	.43644	.3939
.17	.56749	.43251	.3932
.18	.57142	.42858	.3925
.19	.57535	.42465	.3918
.20	.57926	.42074	.3910
.21	.58317	.41683	.3902
.22	.58706	.41294	.3894
.23	.59095	.40905	.3885
.24	.59483	.40517	.3876
.25	.59871	.40129	.3867
.26	.60257	.39743	.3857
.27	.60642	.39358	.3847
.28	.61026	.38974	.3836
.29	.61409	.38591	.3825
.30	.61791	.38209	.3814
.31	.62172	.37828	.3802
.32	.62552	.37448	.3790
.33	.62930	.37070	.3778
.34	.63307	.36693	.3765
.35	.63683	.36317	.3752

(Continued)

(Continued)

z	القسم الأكبر	القسم الأصغر	y
.36	.64058	.35942	.3739
.37	.64431	.35569	.3725
.38	.64803	.35197	.3712
.39	.65173	.34827	.3697
.40	.65542	.34458	.3683
.41	.65910	.34090	.3668
.42	.66276	.33724	.3653
.43	.66640	.33360	.3637
.44	.67003	.32997	.3621
.45	.67364	.32636	.3605
.46	.67724	.32276	.3589
.47	.68082	.31918	.3572
.48	.68439	.31561	.3555
.49	.68793	.31207	.3538
.50	.69146	.30854	.3521
.51	.69497	.30503	.3503
.52	.69847	.30153	.3485
.53	.70194	.29806	.3467
.54	.70540	.29460	.3448
.55	.70884	.29116	.3429
.56	.71226	.28774	.3410
.57	.71566	.28434	.3391
.58	.71904	.28096	.3372
.59	.72240	.27760	.3352
.60	.72575	.27425	.3332
.61	.72907	.27093	.3312
.62	.73237	.26763	.3292
.63	.73565	.26435	.3271
.64	.73891	.26109	.3251
.65	.74215	.25785	.3230
.66	.74537	.25463	.3209
.67	.74857	.25143	.3187
.68	.75175	.24825	.3166
.69	.75490	.24510	.3144
.70	.75804	.24196	.3123
.71	.76115	.23885	.3101
.72	.76424	.23576	.3079
.73	.76730	.23270	.3056
.74	.77035	.22965	.3034
.75	.77337	.22663	.3011
.76	.77637	.22363	.2989
.77	.77935	.22065	.2966
.78	.78230	.21770	.2943
.79	.78524	.21476	.2920
.80	.78814	.21186	.2897
.81	.79103	.20897	.2874
.82	.79389	.20611	.2850
.83	.79673	.20327	.2827
.84	.79955	.20045	.2803
.85	.80234	.19766	.2780
.86	.80511	.19489	.2756
.87	.80785	.19215	.2732
.88	.81057	.18943	.2709
.89	.81327	.18673	.2685
.90	.81594	.18406	.2661
.91	.81859	.18141	.2637
.92	.82121	.17879	.2613
.93	.82381	.17619	.2589
.94	.82639	.17361	.2565
.95	.82894	.17106	.2541
.96	.83147	.16853	.2516
.97	.83398	.16602	.2492
.98	.83646	.16354	.2468
.99	.83891	.16109	.2444
1.00	.84134	.15866	.2420
1.01	.84375	.15625	.2396
1.02	.84614	.15386	.2371
1.03	.84849	.15151	.2347
1.04	.85083	.14917	.2323
1.05	.85314	.14686	.2299
1.06	.85543	.14457	.2275
1.07	.85769	.14231	.2251
1.08	.85993	.14007	.2227
1.09	.86214	.13786	.2203
1.10	.86433	.13567	.2179
1.11	.86650	.13350	.2155
1.12	.86864	.13136	.2131
1.13	.87076	.12924	.2107
1.14	.87286	.12714	.2083
1.15	.87493	.12507	.2059
1.16	.87698	.12302	.2036
1.17	.87900	.12100	.2012
1.18	.88100	.11900	.1989
1.19	.88298	.11702	.1965
1.20	.88493	.11507	.1942
1.21	.88686	.11314	.1919
1.22	.88877	.11123	.1895
1.23	.89065	.10935	.1872
1.24	.89251	.10749	.1849
1.25	.89435	.10565	.1826

(Continued)

z	القسم الأكبر	القسم الأصغر	y
1.26	.89617	.10383	.1804
1.27	.89796	.10204	.1781
1.28	.89973	.10027	.1758
1.29	.90147	.09853	.1736
1.30	.90320	.09680	.1714
1.31	.90490	.09510	.1691
1.32	.90658	.09342	.1669
1.33	.90824	.09176	.1647
1.34	.90988	.09012	.1626
1.35	.91149	.08851	.1604
1.36	.91309	.08691	.1582
1.37	.91466	.08534	.1561
1.38	.91621	.08379	.1539
1.39	.91774	.08226	.1518
1.40	.91924	.08076	.1497
1.41	.92073	.07927	1476
1.42	.92220	.07780	.1456
1.43	.92364	.07636	.1435
1.44	.92507	.07493	.1415
1.45	.92647	.07353	.1394
1.46	.92785	.07215	.1374
1.47	.92922	.07078	.1354
1.48	.93056	.06944	.1334
1.49	.93189	.06811	.1315
1.50	.93319	.06681	.1295
1.51	.93448	.06552	.1276
1.52	.93574	.06426	.1257
1.53	.93699	.06301	.1238
1.54	.93822	.06178	.1219
1.55	.93943	.06057	.1200
1.56	.94062	.05938	.1182
1.57	.94179	.05821	.1163
1.58	.94295	.05705	.1145
1.59	.94408	.05592	.1127
1.60	.94520	.05480	.1109
1.61	.94630	.05370	.1092
1.62	.94738	.05262	.1074
1.63	.94845	.05155	.1057
1.64	.94950	.05050	.1040
1.65	.95053	.04947	.1023
1.66	.95154	.04846	.1006
1.67	.95254	.04746	.0989
1.68	.95352	.04648	.0973
1.69	.95449	.04551	.0957
1.70	.95543	.04457	.0940
1.71	.95637	.04363	.0925
1.72	.95728	.04272	.0909
1.73	.95818	.04182	.0893
1.74	.95907	.04093	.0878
1.75	.95994	.04006	.0863
1.76	.96080	.03920	.0848
1.77	.96164	.03836	.0833
1.78	.96246	.03754	.0818
1.79	.96327	.03673	0804
1.80	.96407	.03593	.0790
1.81	.96485	.03515	.0775
1.82	.96562	.03438	.0761
1.83	.96638	.03362	.0748
1.84	.96712	.03288	.0734
1.85	.96784	.03216	.0721
1.86	.96856	.03144	.0707
1.87	.96926	.03074	.0694
1.88	.96995	.03005	.0681
1.89	.97062	.02938	.0669
1.90	.97128	.02872	.0656
1.91	.97193	.02807	.0644
1.92	.97257	.02743	.0632
1.93	.97320	.02680	.0620
1.94	.97381	.02619	.0608
1.95	.97441	.02559	.0596
1.96	.97500	.02500	.0584
1.97	.97558	.02442	.0573
1.98	.97615	.02385	.0562
1.99	.97670	.02330	.0551
2.00	.97725	.02275	.0540
2.01	.97778	.02222	.0529
2.02	.97831	.02169	.0519
2.03	.97882	.02118	.0508
2.04	.97932	.02068	.0498
2.05	.97982	.02018	.0488
2.06	.98030	.01970	.0478
2.07	.98077	.01923	.0468
2.08	.98124	.01876	.0459
2.09	.98169	.01831	.0449
2.10	.98214	.01786	.0440
2.11	.98257	.01743	.0431
2.12	.98300	.01700	.0422
2.13	.98341	.01659	.0413
2.14	.98382	.01618	.0404
2.15	.98422	.01578	.0396

(Continued)

(Continued)

z	القسم الأكبر	القسم الأصغر	٢
2.16	.98461	.01539	.0387
2.17	.98500	.01500	.0379
2.18	.98537	.01463	.0371
2.19	.98574	.01426	.0363
2.20	.98610	.01390	.0355
2.21	.98645	.01355	.0347
2.22	.98679	.01321	.0339
2.23	.98713	.01287	.0332
2.24	.98745	.01255	.0325
2.25	.98778	.01222	.0317
2.26	.98809	.01191	.0310
2.27	.98840	.01160	.0303
2.28	.98870	.01130	.0297
2.29	.98899	.01101	.0290
2.30	.98928	.01072	.0283
2.31	.98956	.01044	.0277
2.32	.98983	.01017	.0270
2.33	.99010	.00990	.0264
2.34	.99036	.00964	.0258
2.35	.99061	.00939	.0252
2.36	.99086	.00914	.0246
2.37	.99111	.00889	.0241
2.38	.99134	.00866	.0235
2.39	.99158	.00842	.0229
2.40	.99180	.00820	.0224
2.41	.99202	.00798	.0219
2.42	.99224	.00776	.0213
2.43	.99245	.00755	.0208
2.44	.99266	.00734	.0203
2.45	.99286	.00714	.0198
2.46	.99305	.00695	.0194
2.47	.99324	.00676	.0189
2.48	.99343	.00657	.0184
2.49	.99361	.00639	.0180
2.50	.99379	.00621	.0175
2.51	.99396	.00604	.0171
2.52	.99413	.00587	.0167
2.53	.99430	.00570	.0163
2.54	.99446	.00554	.0158
2.55	.99461	.00539	.0154
2.56	.99477	.00523	.0151
2.57	.99492	.00508	.0147
2.58	.99506	.00494	.0143
2.59	.99520	.00480	.0139
2.60	.99534	.00466	.0136
2.61	.99547	.00453	.0132
2.62	.99560	.00440	.0129
2.63	.99573	.00427	.0126
2.64	.99585	.00415	.0122
2.65	.99598	.00402	.0119
2.66	.99609	.00391	.0116
2.67	.99621	.00379	.0113
2.68	.99632	.00368	.0110
2.69	.99643	.00357	.0107
2.70	.99653	.00347	.0104
2.71	.99664	.00336	.0101
2.72	.99674	.00326	.0099
2.73	.99683	.00317	.0096
2.74	.99693	.00307	.0093
2.75	.99702	.00298	.0091
2.76	.99711	.00289	.0088
2.77	.99720	.00280	.0086
2.78	.99728	.00272	.0084
2.79	.99736	.00264	.0081
2.80	.99744	.00256	.0079
2.81	.99752	.00248	.0077
2.82	.99760	.00240	.0075
2.83	.99767	.00233	.0073
2.84	.99774	.00226	.0071
2.85	.99781	.00219	.0069
2.86	.99788	.00212	.0067
2.87	.99795	.00205	.0065
2.88	.99801	.00199	.0063
2.89	.99807	.00193	.0061
2.90	.99813	.00187	.0060
2.91	.99819	.00181	.0058
2.92	.99825	.00175	.0056
2.93	.99831	.00169	.0055
2.94	.99836	.00164	.0053
2.95	.99841	.00159	.0051
2.96	.99846	.00154	.0050
2.97	.99851	.00149	.0048
2.98	.99856	.00144	.0047
2.99	.99861	.00139	.0046
3.00	.99865	.00135	.0044
⋮	⋮	⋮	⋮
3.25	.99942	.00058	.0020
⋮	⋮	⋮	⋮
3.50	.99977	.00023	.0009
⋮	⋮	⋮	⋮
4.00	.99997	.00003	.0001

Values calculated by author using SPSS 11.

A.2 القيم الحرجة للتوزيع t

	اختبار ثنائي الطرف		اختبار وحيد الطرف	
df	*0.05*	*0.01*	*0.05*	*0.01*
1	12.71	63.66	6.31	31.82
2	4.30	9.92	2.92	6.96
3	3.18	5.84	2.35	4.54
4	2.78	4.60	2.13	3.75
5	2.57	4.03	2.02	3.36
6	2.45	3.71	1.94	3.14
7	2.36	3.50	1.89	3.00
8	2.31	3.36	1.86	2.90
9	2.26	3.25	1.83	2.82
10	2.23	3.17	1.81	2.76
11	2.20	3.11	1.80	2.72
12	2.18	3.05	1.78	2.68
13	2.16	3.01	1.77	2.65
14	2.14	2.98	1.76	2.62
15	2.13	2.95	1.75	2.60
16	2.12	2.92	1.75	2.58
17	2.11	2.90	1.74	2.57
18	2.10	2.88	1.73	2.55
19	2.09	2.86	1.73	2.54
20	2.09	2.85	1.72	2.53
21	2.08	2.83	1.72	2.52
22	2.07	2.82	1.72	2.51
23	2.07	2.81	1.71	2.50
24	2.06	2.80	1.71	2.49
25	2.06	2.79	1.71	2.49
26	2.06	2.78	1.71	2.48
27	2.05	2.77	1.70	2.47
28	2.05	2.76	1.70	2.47
29	2.05	2.76	1.70	2.46
30	2.04	2.75	1.70	2.46
35	2.03	2.72	1.69	2.44
40	2.02	2.70	1.68	2.42
45	2.01	2.69	1.68	2.41
50	2.01	2.68	1.68	2.40
60	2.00	2.66	1.67	2.39
70	1.99	2.65	1.67	2.38
80	1.99	2.64	1.66	2.37
90	1.99	2.63	1.66	2.37
100	1.98	2.63	1.66	2.36
∞ (*z*)	1.96	2.58	1.64	2.33

All values computed by the author using *SPSS* 11.

A.3 القيم الحرجة للتوزيع F

درجات الحرية (المقام)	p	درجات الحرية (البسط) 1	2	3	4	5	6	7	8	9	10
1	.05	161.45	199.50	215.71	224.58	230.16	233.99	236.77	238.88	240.54	241.88
	.01	4052.18	4999.50	5403.35	5624.58	5763.65	5858.99	5928.36	5981.07	6022.47	6055.85
2	.05	18.51	19.00	19.16	19.25	19.30	19.33	19.35	19.37	19.38	19.40
	.01	98.50	99.00	99.17	99.25	99.30	99.33	99.36	99.37	99.39	99.40
3	.05	10.13	9.55	9.28	9.12	9.01	8.94	8.89	8.85	8.81	8.79
	.01	34.12	30.82	29.46	28.71	28.24	27.91	27.67	27.49	27.35	27.23
4	.05	7.71	6.94	6.59	6.39	6.26	6.16	6.09	6.04	6.00	5.96
	.01	21.20	18.00	16.69	15.98	15.52	15.21	14.98	14.80	14.66	14.55
5	.05	6.61	5.79	5.41	5.19	5.05	4.95	4.88	4.82	4.77	4.74
	.01	16.26	13.27	12.06	11.39	10.97	10.67	10.46	10.29	10.16	10.05
6	.05	5.99	5.14	4.76	4.53	4.39	4.28	4.21	4.15	4.10	4.06
	.01	13.75	10.92	9.78	9.15	8.75	8.47	8.26	8.10	7.98	7.87
7	.05	5.59	4.74	4.35	4.12	3.97	3.87	3.79	3.73	3.68	3.64
	.01	12.25	9.55	8.45	7.85	7.46	7.19	6.99	6.84	6.72	6.62
8	.05	5.32	4.46	4.07	3.84	3.69	3.58	3.50	3.44	3.39	3.35
	.01	11.26	8.65	7.59	7.01	6.63	6.37	6.18	6.03	5.91	5.81
9	.05	5.12	4.26	3.86	3.63	3.48	3.37	3.29	3.23	3.18	3.14
	.01	10.56	8.02	6.99	6.42	6.06	5.80	5.61	5.47	5.35	5.26
10	.05	4.96	4.10	3.71	3.48	3.33	3.22	3.14	3.07	3.02	2.98
	.01	10.04	7.56	6.55	5.99	5.64	5.39	5.20	5.06	4.94	4.85
11	.05	4.84	3.98	3.59	3.36	3.20	3.09	3.01	2.95	2.90	2.85
	.01	9.65	7.21	6.22	5.67	5.32	5.07	4.89	4.74	4.63	4.54
12	.05	4.75	3.89	3.49	3.26	3.11	3.00	2.91	2.85	2.80	2.75
	.01	9.33	6.93	5.95	5.41	5.06	4.82	4.64	4.50	4.39	4.30
13	.05	4.67	3.81	3.41	3.18	3.03	2.92	2.83	2.77	2.71	2.67
	.01	9.07	6.70	5.74	5.21	4.86	4.62	4.44	4.30	4.19	4.10
14	.05	4.60	3.74	3.34	3.11	2.96	2.85	2.76	2.70	2.65	2.60
	.01	8.86	6.51	5.56	5.04	4.69	4.46	4.28	4.14	4.03	3.94
15	.05	4.54	3.68	3.29	3.06	2.90	2.79	2.71	2.64	2.59	2.54
	.01	8.68	6.36	5.42	4.89	4.56	4.32	4.14	4.00	3.89	3.80
16	.05	4.49	3.63	3.24	3.01	2.85	2.74	2.66	2.59	2.54	2.49
	.01	8.53	6.23	5.29	4.77	4.44	4.20	4.03	3.89	3.78	3.69
17	.05	4.45	3.59	3.20	2.96	2.81	2.70	2.61	2.55	2.49	2.45
	.01	8.40	6.11	5.18	4.67	4.34	4.10	3.93	3.79	3.68	3.59
18	.05	4.41	3.55	3.16	2.93	2.77	2.66	2.58	2.51	2.46	2.41
	.01	8.29	6.01	5.09	4.58	4.25	4.01	3.84	3.71	3.60	3.51

(Continued)

درجات الحرية (المقام)	p	درجات الحرية (البسط) 1	2	3	4	5	6	7	8	9	10
19	.05	4.38	3.52	3.13	2.90	2.74	2.63	2.54	2.48	2.42	2.38
	.01	8.18	5.93	5.01	4.50	4.17	3.94	3.77	3.63	3.52	3.43
20	.05	4.35	3.49	3.10	2.87	2.71	2.60	2.51	2.45	2.39	2.35
	.01	8.10	5.85	4.94	4.43	4.10	3.87	3.70	3.56	3.46	3.37
22	.05	4.30	3.44	3.05	2.82	2.66	2.55	2.46	2.40	2.34	2.30
	.01	7.95	5.72	4.82	4.31	3.99	3.76	3.59	3.45	3.35	3.26
24	.05	4.26	3.40	3.01	2.78	2.62	2.51	2.42	2.36	2.30	2.25
	.01	7.82	5.61	4.72	4.22	3.90	3.67	3.50	3.36	3.26	3.17
26	.05	4.23	3.37	2.98	2.74	2.59	2.47	2.39	2.32	2.27	2.22
	.01	7.72	5.53	4.64	4.14	3.82	3.59	3.42	3.29	3.18	3.09
28	.05	4.20	3.34	2.95	2.71	2.56	2.45	2.36	2.29	2.24	2.19
	.01	7.64	5.45	4.57	4.07	3.75	3.53	3.36	3.23	3.12	3.03
30	.05	4.17	3.32	2.92	2.69	2.53	2.42	2.33	2.27	2.21	2.16
	.01	7.56	5.39	4.51	4.02	3.70	3.47	3.30	3.17	3.07	2.98
35	.05	4.12	3.27	2.87	2.64	2.49	2.37	2.29	2.22	2.16	2.11
	.01	7.42	5.27	4.40	3.91	3.59	3.37	3.20	3.07	2.96	2.88
40	.05	4.08	3.23	2.84	2.61	2.45	2.34	2.25	2.18	2.12	2.08
	.01	7.31	5.18	4.31	3.83	3.51	3.29	3.12	2.99	2.89	2.80
45	.05	4.06	3.20	2.81	2.58	2.42	2.31	2.22	2.15	2.10	2.05
	.01	7.23	5.11	4.25	3.77	3.45	3.23	3.07	2.94	2.83	2.74
50	.05	4.03	3.18	2.79	2.56	2.40	2.29	2.20	2.13	2.07	2.03
	.01	7.17	5.06	4.20	3.72	3.41	3.19	3.02	2.89	2.78	2.70
60	.05	4.00	3.15	2.76	2.53	2.37	2.25	2.17	2.10	2.04	1.99
	.01	7.08	4.98	4.13	3.65	3.34	3.12	2.95	2.82	2.72	2.63
80	.05	3.96	3.11	2.72	2.49	2.33	2.21	2.13	2.06	2.00	1.95
	.01	6.96	4.88	4.04	3.56	3.26	3.04	2.87	2.74	2.64	2.55
100	.05	3.94	3.09	2.70	2.46	2.31	2.19	2.10	2.03	1.97	1.93
	.01	6.90	4.82	3.98	3.51	3.21	2.99	2.82	2.69	2.59	2.50
150	.05	3.90	3.06	2.66	2.43	2.27	2.16	2.07	2.00	1.94	1.89
	.01	6.81	4.75	3.91	3.45	3.14	2.92	2.76	2.63	2.53	2.44
300	.05	3.87	3.03	2.63	2.40	2.24	2.13	2.04	1.97	1.91	1.86
	.01	6.72	4.68	3.85	3.38	3.08	2.86	2.70	2.57	2.47	2.38
500	.05	3.86	3.01	2.62	2.39	2.23	2.12	2.03	1.96	1.90	1.85
	.01	6.69	4.65	3.82	3.36	3.05	2.84	2.68	2.55	2.44	2.36
1000	.05	3.85	3.00	2.61	2.38	2.22	2.11	2.02	1.95	1.89	1.84
	.01	6.66	4.63	3.80	3.34	3.04	2.82	2.66	2.53	2.43	2.34

(Continued)

(Continued)

درجات الحرية (المقام)	p	درجات الحرية (البسط) 15	20	25	30	40	50	1000
1	.05	245.95	248.01	249.26	250.10	251.14	251.77	254.19
	.01	6157.31	6208.74	6239.83	6260.65	6286.79	6302.52	6362.70
2	.05	19.43	19.45	19.46	19.46	19.47	19.48	19.49
	.01	99.43	99.45	99.46	99.47	99.47	99.48	99.50
3	.05	8.70	8.66	8.63	8.62	8.59	8.58	8.53
	.01	26.87	26.69	26.58	26.50	26.41	26.35	26.14
4	.05	5.86	5.80	5.77	5.75	5.72	5.70	5.63
	.01	14.20	14.02	13.91	13.84	13.75	13.69	13.47
5	05	4.62	4.56	4.52	4.50	4.46	4.44	4.37
	.01	9.72	9.55	9.45	9.38	9.29	9.24	9.03
6	.05	3.94	3.87	3.83	3.81	3.77	3.75	3.67
	.01	7.56	7.40	7.30	7.23	7.14	7.09	6.89
7	.05	3.51	3.44	3.40	3.38	3.34	3.32	3.23
	.01	6.31	6.16	6.06	5.99	5.91	5.86	5.66
8	.05	3.22	3.15	3.11	3.08	3.04	3.02	2.93
	.01	5.52	5.36	5.26	5.20	5.12	5.07	4.87
9	.05	3.01	2.94	2.89	2.86	2.83	2.80	2.71
	.01	4.96	4.81	4.71	4.65	4.57	4.52	4.32
10	.05	2.85	2.77	2.73	2.70	2.66	2.64	2.54
	.01	4.56	4.41	4.31	4.25	4.17	4.12	3.92
11	.05	2.72	2.65	2.60	2.57	2.53	2.51	2.41
	.01	4.25	4.10	4.01	3.94	3.86	3.81	3.61
12	.05	2.62	2.54	2.50	2.47	2.43	2.40	2.30
	.01	4.01	3.86	3.76	3.70	3.62	3.57	3.37
13	.05	2.53	2.46	2.41	2.38	2.34	2.31	2.21
	.01	3.82	3.66	3.57	3.51	3.43	3.38	3.18
14	.05	2.46	2.39	2.34	2.31	2.27	2.24	2.14
	.01	3.66	3.51	3.41	3.35	3.27	3.22	3.02
15	.05	2.40	2.33	2.28	2.25	2.20	2.18	2.07
	.01	3.52	3.37	3.28	3.21	3.13	3.08	2.88
16	.05	2.35	2.28	2.23	2.19	2.15	2.12	2.02
	.01	3.41	3.26	3.16	3.10	3.02	2.97	2.76
17	.05	2.31	2.23	2.18	2.15	2.10	2.08	1.97
	.01	3.31	3.16	3.07	3.00	2.92	2.87	2.66
18	.05	2.27	2.19	2.14	2.11	2.06	2.04	1.92
	.01	3.23	3.08	2.98	2.92	2.84	2.78	2.58

(Continued)

درجات الحرية (المقام)	p	درجات الحرية (البسط) 15	20	25	30	40	50	1000
19	0.05	2.23	2.16	2.11	2.07	2.03	2.00	1.88
	0.01	3.15	3.00	2.91	2.84	2.76	2.71	2.50
20	0.05	2.20	2.12	2.07	2.04	1.99	1.97	1.85
	0.01	3.09	2.94	2.84	2.78	2.69	2.64	2.43
22	0.05	2.15	2.07	2.02	1.98	1.94	1.91	1.79
	0.01	2.98	2.83	2.73	2.67	2.58	2.53	2.32
24	0.05	2.11	2.03	1.97	1.94	1.89	1.86	1.74
	0.01	2.89	2.74	2.64	2.58	2.49	2.44	2.22
26	0.05	2.07	1.99	1.94	1.90	1.85	1.82	1.70
	0.01	2.81	2.66	2.57	2.50	2.42	2.36	2.14
28	0.05	2.04	1.96	1.91	1.87	1.82	1.79	1.66
	0.01	2.75	2.60	2.51	2.44	2.35	2.30	2.08
30	0.05	2.01	1.93	1.88	1.84	1.79	1.76	1.63
	0.01	2.70	2.55	2.45	2.39	2.30	2.25	2.02
35	0.05	1.96	1.88	1.82	1.79	1.74	1.70	1.57
	0.01	2.60	2.44	2.35	2.28	2.19	2.14	1.90
40	0.05	1.92	1.84	1.78	1.74	1.69	1.66	1.52
	0.01	2.52	2.37	2.27	2.20	2.11	2.06	1.82
45	0.05	1.89	1.81	1.75	1.71	1.66	1.63	1.48
	0.01	2.46	2.31	2.21	2.14	2.05	2.00	1.75
50	0.05	1.87	1.78	1.73	1.69	1.63	1.60	1.45
	0.01	2.42	2.27	2.17	2.10	2.01	1.95	1.70
60	0.05	1.84	1.75	1.69	1.65	1.59	1.56	1.40
	0.01	2.35	2.20	2.10	2.03	1.94	1.88	1.62
80	0.05	1.79	1.70	1.64	1.60	1.54	1.51	1.34
	0.01	2.27	2.12	2.01	1.94	1.85	1.79	1.51
100	0.05	1.77	1.68	1.62	1.57	1.52	1.48	1.30
	0.01	2.22	2.07	1.97	1.89	1.80	1.74	1.45
150	0.05	1.73	1.64	1.58	1.54	1.48	1.44	1.24
	0.01	2.16	2.00	1.90	1.83	1.73	1.66	1.35
300	0.05	1.70	1.61	1.54	1.50	1.43	1.39	1.17
	.01	2.10	1.94	1.84	1.76	1.66	1.59	1.25
500	.05	1.69	1.59	1.53	1.48	1.42	1.38	1.14
	.01	2.07	1.92	1.81	1.74	1.63	1.57	1.20
1000	.05	1.68	1.58	1.52	1.47	1.41	1.36	1.11
	.01	2.06	1.90	1.79	1.72	1.61	1.54	1.16

All values computed by the author using SPSS 11.

A.4 القيم الحرجة لتوزيع كاي مربع

df	p .05	.01
1	3.84	6.63
2	5.99	9.21
3	7.81	11.34
4	9.49	13.28
5	11.07	15.09
6	12.59	16.81
7	14.07	18.48
8	15.51	20.09
9	16.92	21.67
10	18.31	23.21
11	19.68	24.72
12	21.03	26.22
13	22.36	27.69
14	23.68	29.14
15	25.00	30.58
16	26.30	32.00
17	27.59	33.41
18	28.87	34.81
19	30.14	36.19
20	31.41	37.57
21	32.67	38.93
22	33.92	40.29
23	35.17	41.64
24	36.42	42.98

df	p .05	.01
25	37.65	44.31
26	38.89	45.64
27	40.11	46.96
28	41.34	48.28
29	42.56	49.59
30	43.77	50.89
35	49.80	57.34
40	55.76	63.69
45	61.66	69.96
50	67.50	76.15
60	79.08	88.38
70	90.53	100.43
80	101.88	112.33
90	113.15	124.12
100	124.34	135.81
200	233.99	249.45
300	341.40	359.91
400	447.63	468.72
500	553.13	576.49
600	658.09	683.52
700	762.66	789.97
800	866.91	895.98
900	970.90	1001.63
1000	1074.68	1106.97

A.5 اختبار Welch F: النسبة F عندما لا تتحقق فرضية تجانس التباين

شرحنا في المربع 3.8 النسبة F العائدة لـــ Brown-Forsythe التي تصحح خروقات فرضية تجانس التباين. وقد اكتشفنا أن:

$$F_{BF} = \frac{SS_M}{SS_{R_{BF}}} = \frac{SS_M}{\sum s_k^2\left(1-\frac{n_k}{N}\right)}$$

لذلك، ومن أجل بيانات Viagra تكون SS_M=20.135 (وهي قيمة لم تتغير) وتصبح المعادلة بالشكل:

$$F_{BF} = \frac{SS_M}{s^2_{group1}\left(1-\frac{n_{group1}}{N}\right)+s^2_{group2}\left(1-\frac{n_{group2}}{N}\right)+s^2_{group3}\left(1-\frac{n_{group3}}{N}\right)}$$
$$= \frac{20.135}{1.70\left(1-\frac{5}{15}\right)+1.70\left(1-\frac{5}{15}\right)+2.50\left(1-\frac{5}{15}\right)}$$
$$= 5.119$$

ويبقى مجموع المربعات للنموذج على حاله،، بينما يعطى مجموع المربعات للخطأ بالمعادلة التالية:

$$\frac{1}{df_R} = \sum \frac{\left(\frac{s_k^2\left(1-\frac{n_k}{N}\right)}{SS_{R_{BF}}}\right)^2}{(n_k-1)}$$
$$= \frac{\left(\frac{1.133}{3.933}\right)^2}{5-1}+\frac{\left(\frac{1.133}{3.933}\right)^2}{5-1}+\frac{\left(\frac{1.667}{3.933}\right)^2}{5-1}$$
$$= 0.0864$$
$$df_R = \frac{1}{0.0864} = 11.57$$

أما النسبة Welch F فهي أقل تعقيداً نوعاً ما. علينا أولاً أن نحسب الثقل الذي يعتمد على حجم العينة n_k والتباين s^2. فمن أجل مجموعة معينة:

$$w_k = \frac{n_k}{s_k^2}$$

ونحتاج أيضاً للمتوسط الكلي المعتمد على المتوسط المثقّل لكل مجموعة. لذلك نأخذ المتوسط لكل مجموعة ونضربه بالثقل وذلك من أجل جميع المجموعات ثم نجمع هذه الجداءات معاً ونقسم الناتج على مجموع الأثقال:

$$\bar{X}^{Welch}_{grand} = \frac{\sum w_k.\bar{X}_k}{\sum w_k}$$

وأسهل طريقة لتنفيذ ذلك هي استخدام الجدول المبين فيما يلي:

المجموعة	التباين s^2	حجم العينة n_k	الثقل w_k	المتوسط $\bar{x}_k$	الجداء $w_k \cdot \bar{x}_k$
الدواء التمويهي	1.70	5	2.941	2.2	6.4702
الجرعة المنخفضة	1.70	5	2.941	3.2	9.4112
الجرعة المرتفعة	2.50	5	2.000	5.0	10.000
المجموع			**7.882**		**25.8814**

لذلك نحصل على:

$$\bar{x}_{grand}^{Welch} = \frac{25.8814}{7.882} = 3.284$$

لنعد إلى المعادلة (5.8) حيث نجد مجموع المربعات للنموذج:

$$SS_M = \Sigma n_k.(\bar{x}_k - \bar{x}_{grand})^2$$

يتم تعديل هذا المجموع عند حساب النسبة Welch F ليتضمن التثقيل والمتوسط الكلي المثقّل:

$$SS_M^{Welch} = \Sigma w_k.(\bar{x}_k - \bar{x}_{grand}^{Welch})^2$$

ولإيجاد متوسط المربعات نقسم مجموع المربعات الذي حصلنا عليه على عدد درجات الحرية:

$$MS_M^{Welch} = \frac{\Sigma w_k.(\bar{x}_k - \bar{x}_{grand}^{Welch})^2}{k \quad 1}$$

$$= \frac{2.941(2.2 - 3.284)^2 + 2.941(3.2 - 3.284)^2 + 2.000(5.0 - 3.284)^2}{3 - 1}$$

$$= 4.683$$

علينا الآن إيجاد حد يدعى lambda وهو يعتمد أيضاً على الأثقال:

$$\Lambda = \frac{3\Sigma\frac{\left(1 - \frac{w_k}{\Sigma w_k}\right)}{n_k - 1}}{k^2 - 1}$$

$$= \frac{3\left(\frac{\left(1 - \frac{2.941}{7.882}\right)^2}{5-1} + \frac{\left(1 - \frac{2.941}{7.882}\right)^2}{5-1} + \frac{\left(1 - \frac{2.000}{7.882}\right)^2}{5-1}\right)}{3^2 - 1}$$

$$= 0.126$$

تعطى بعد ذلك النسبة F بالعلاقة التالية:

$$F_W = \frac{MS_M^{Welch}}{1 + \frac{2\Lambda(k-2)}{3}}$$
$$= \frac{4.683}{1 + \frac{2 \times 0.126 \times (3-2)}{3}}$$
$$= 4.32$$

وكما في حالة النسبة F العائدة لـ Brown-Forsythe فإن عدد درجات الحرية للنموذج يبقى ذاته (k-1=2) أما عدد درجات الحرية للباقي فيصبح $df_R=1/\Lambda=1/0.126=7.94$.

A.6 حساب الآثار البسيطة

الأثر الأساسي البسيط (ويدعى عادة الأثر البسيط Simple effect) هو أثر أحد المتحولات على مستويات متحول آخر. وقد رأينا في الفصل 10 مثالاً عن قياس جاذبية الشريك الذي يمكن أن يختاره الشخص (ذكر أو أنثى) بعد تناول مشروب خالي من الكحول أو تناول قدحين من البيرة أو تناول 4 أقداح من البيرة. ولذلك لدينا متحولان مستقلان: الكحول (بدون كحول، قدحين، 4 أقداح) والجنس (ذكر أو أنثى). ويمكن أن نقوم بتحليل الآثار البسيطة وذلك بأن ننظر إلى أثر الجنس (أي مقارنة علامات الذكور مع الإناث) عند المستويات الثلاثة للمتحول الآخر (الكحول). ولنتعرف إلى طريقة تنفيذ ذلك. نقوم بتجزئة مجموع المربعات للنموذج الذي رأينا طريقة حسابه في الفصل 10:

$$SS_M = \Sigma n_k \left(\overline{X}_k - \overline{X}_{grand}\right)^2$$

فمن أجل الآثار البسيطة، نقوم بحساب مجموع مربعات للنموذج من أجل أثر الجنس عند كل مستوى للكحول. لذلك سنبدأ بحالة المشروب الخالي من الكحول ونحسب مجموع المربعات للنموذج. وهكذا فإن المتوسط الكلي هو المتوسط عند عدم تناول الكحول، ومتوسطات المجموعات هي المتوسط لمجموعة الذكور (عند عدم تناول الكحول) والإناث (عند عدم تناول الكحول). ولذلك نقوم بتجميع البيانات وفق كمية الكحول المستهلكة. وضمن كل مجموعة من هذه المجموعات الثلاث نحسب المتوسط الكلي وكذلك المتوسط لعلامات الذكور والإناث بشكل منفصل. وكل ما نحتاجه هي قيم المتوسط التي قمنا بحسابها. وهكذا يمكن النظر إلى البيانات كما في الشكل 1.

خالي من الكحول	
الذكور	الإناث
50	65
55	70
80	60
65	60
70	60
75	55
75	60
65	55
66.875	**60.625**

المتوسط =63.7500

قدحين من البيرة	
الذكور	الإناث
45	70
60	65
85	60
65	70
70	65
70	60
80	60
60	50
66.875	**62.500**

المتوسط =64.6875

4 أقداح من البيرة	
الذكور	الإناث
30	55
30	65
30	70
55	55
35	55
20	60
45	50
40	50
35.625	**57.500**

المتوسط =46.5625

الشكل 1 ترتيب البيانات من أجل البحث عن الأثر البسيط للجنس عند المستويات المختلفة للكحول

يمكننا بعد ذلك أن نطبق نفس المعادلة لمجموع المربعات للنموذج والتي استخدمناها من أجل مجموع المربعات الكلي للنموذج ولكن سنستخدم المتوسط الكلي للمجموعة بدون كحول (63.75) والمتوسطات لعلامات الذكور (66.875) والإناث (60.625) ضمن تلك المجموعة:

$$SS_{Gender\ (No\ Alcohol)} = \Sigma n_k (\bar{x}_k - \bar{x}_{grand})^2$$
$$= 8 \times (60.625 - 63.750)^2 + 8 \times (66.875 - 63.750)^2$$
$$= 156.25$$

يتم حساب عدد درجات الحرية لهذا الأثر بنفس الطريقة المعتمدة لمجموع المربعات للنموذج أي أنه أقل بواحد من عدد الحالات التي تتم مقارنتها (k-1)، وفي هذه الحالة يكون df=2-1=1.

الخطوة التالية هي تنفيذ نفس العمل من أجل بيانات حالة قدحين من البيرة. نستخدم الآن المتوسط الكلي لمجموعة قدحين من البيرة (64.6875) والمتوسطات لعلامات الذكور (66.875) والإناث (62.500) ضمن تلك المجموعة:

$$SS_{Gender\ (2\ Pints)} = \Sigma n_k (\bar{x}_k - \bar{x}_{grand})^2$$
$$= 8 \times (62.500 - 64.6875)^2 + 8 \times (66.875 - 64.6875)^2$$
$$= 76.56$$

وعدد درجات الحرية لهذا الأثر هو نفس عدد درجات الحرية للأثر البسيط السابق df=1.

الخطوة التالية هي تنفيذ نفس العمل من أجل بيانات حالة 4 أقداح من البيرة. نستخدم الآن المتوسط الكلي لمجموعة 4 أقداح من البيرة (46.5625) والمتوسطات لعلامات الذكور (57.500) والإناث (35.625) ضمن تلك المجموعة:

$$SS_{Gender\ (4\ Pints)} = \Sigma n_k (\bar{x}_k - \bar{x}_{grand})^2$$
$$= 8 \times (57.500 - 46.5625)^2 + 8 \times (35.625 - 46.5625)^2$$
$$= 1914.06$$

ومرة أخرى عدد درجات الحرية هو df=1 (لأننا نقارن مجموعتين أي أن k=2). وكما في حالة تحليل التباين (ANOVA) فإننا نحول مجموع المربعات إلى متوسط المربعات وذلك بتقسيمه على عدد درجات الحرية. على كل حال، وبما أن عدد درجات الحرية يساوي 1 في جميع الحالات فإن متوسط المربعات يساوي مجموع المربعات.

المرحلة الأخيرة هي حساب النسبة F لكل من الآثار البسيطة. والنسبة F هي حاصل قسمة متوسط المربعات للنموذج على متوسط المربعات البواقي. قد نتساءل: لماذا متوسط المربعات الباقي؟ عند حساب الآثار البسيطة فإننا نستخدم متوسط المربعات الباقي من أجل ANOVA الأصلي (أي متوسط المربعات الباقي للنموذج الكلي) وبذلك فإننا نقوم بتجزئة مجموع المربعات للنموذج للمحافظة على التحكم بمعدل الخطأ من النوع الأول. ومن أجل البيانات الحالية، فإن مجموع المربعات الباقي يساوي 83.036 (انظر الفقرة 6.2.10) لذلك نحصل على:

$$F_{\text{Gender (No Alcohol)}} = \frac{MS_{\text{Gender (No Alcohol)}}}{MS_R} = \frac{156.25}{83.036} = 1.88$$

$$F_{\text{Gender (2 Pints)}} = \frac{MS_{\text{Gender (2 Pints)}}}{MS_R} = \frac{76.56}{83.036} = 0.92$$

$$F_{\text{Gender (4 Pints)}} = \frac{MS_{\text{Gender (4 Pints)}}}{MS_R} = \frac{1914.06}{83.036} = 23.05$$

يمكننا تقييم F بالطريقة المعتادة (وهي ذات درجات حرية 1 و 42 في هذا المثال). على كل حال، من أجل حالة قدحين من البيرة نحن متأكدون من عدم وجود أثر مهم للجنس لأن النسبة F أصغر من 1.

A.7 اختبار Jonckheere للمنحنى

يعتمد اختبار Jonckheere على فكرة بسيطة ولكنها ذكية، وهي أخذ علامة من حالة تجريبية ما وحساب عدد العلامات التي تكون أصغر من تلك العلامة في الحالات التجريبية التالية. لذلك فإن أول خطوة هي ترتيب المجموعات بالطريقة التي تتوقع أن يتغير الوسط فيها. إذا أخذنا مثال الصويا من الفصل 13 فإننا نتوقع أن يكون عدد الحيوانات المنوية أعلى في المجموعة التي لم تتناول أي وجبة صويا، ثم يتناقص هذا العدد وفق الترتيب التالي: المجموعة التي تتناول وجبة واحدة من الصويا أسبوعياً، ثم المجموعة التي تتناول 4 وجبات أسبوعياً ثم المجموعة التي تتناول 7 وجبات أسبوعياً. وهكذا نبدأ مع حالة 0 وجبة أسبوعياً ونأخذ العلامة الأولى ونطرح السؤال التالي: كم يبلغ عدد العلامات التي هي أكبر من هذه العلامة في الحالة التجريبية التالية؟

إذا قمت بترتيب العلامات تصاعدياً في كل حالة تجريبية فإن تنفيذ ذلك العمل يصبح سهلاً جداً. يعرض الجدول 1 طريقة مناسبة لترتيب البيانات. لاحظ أنه تم ترتيب عدد الحيوانات المنوية تصاعدياً، وترتيب المجموعات بالطريقة التي نتوقع فيها انخفاض الوسط. وهكذا نبدأ مع العلامة الأولى في المجموعة 0 وجبة صويا (وهي العلامة 0.35) وننظر إلى العلامات في المجموعة التجريبية التالية (1 وجبة أسبوعياً) ونحسب عدد العلامات التي هي أكبر من 0.35 فنجد أن العدد هو 19 من أصل 20 ولذلك نضع القيمة 19 في العمود المناسب و ننتقل إلى العلامة التالية (وهي 0.58) ونقوم بنفس العمل. عند الانتهاء من هذا العمل لجميع العلامات في الحالة 0 وجبة نعود مرة أخرى إلى العلامة الأولى (0.35) ولكن في هذه المرة نحسب عدد العلامات التي هي أكبر من 0.35 في الحالة التجريبية التالية (4 وجبات أسبوعياً) فنجد أن العدد هو 18 ولذلك نضع القيمة 18 في العمود المناسب وننتقل إلى العلامة التالية (0.58) ونقوم بنفس العمل. وعند الانتهاء من مقارنة العلامات في المجموعة 4 وجبات ننتقل إلى المجموعة 7 وجبات ونكرر نفس العمل بحيث نقارن المجموعة الأولى (0 وجبة) مع جميع المجموعات التالية.

بعد ذلك ننتقل إلى المجموعة التالية (1 وجبة أسبوعياً). ومرة أخرى نبدأ مع العلامة الأولى (0.33) وننظر إلى العلامات في المجموعة التجريبية التالية (4 وجبات أسبوعياً) ونحسب عدد العلامات التي هي أكبر من 0.33 فنجد أن العدد هو 20 لذلك نضع القيمة 20 في العمود المناسب وننتقل إلى العلامة التالية (0.36). نكرر ذلك العمل لجميع العلامات في المجموعة 1 وجبة أسبوعياً، وعند الانتهاء نعود مرة أخرى إلى العلامة الأولى (0.33) في المجموعة 1 وجبة أسبوعياً ونكرر نفس العمل مع علامات المجموعة التجريبية التالية (7 وجبات أسبوعياً). وعند الانتهاء ننتقل إلى المجموعة التالية (4 وجبات أسبوعياً). ونكرر العمل حتى ننتهي من مقارنة كل مجموعة مع المجموعات التالية. بعد ذلك نقوم بجمع الأعداد في كل عمود ونسمي المجموع U_{ij}.

بدون وجبات صوبا				وجبة واحدة			4 وجبات		7 وجبات
عدد الحيوانات المنوية(مليون)	عدد العلامات الأكبر في			عدد الحيوانات المنوية	عدد العلامات الأكبر في		عدد الحيوانات المنوية	عدد العلامات الأكبر في	عدد الحيوانات المنوية
	وجبة واحدة	4 وجبات	7 وجبات		4 وجبات	7 وجبات		7 وجبات	
0.35	19	20	18	0.33	20	18	0.40	18	0.31
0.58	18	19	16	0.36	20	18	0.60	16	0.32
0.88	15	18	13	0.63	18	16	0.96	13	0.56
0.92	15	18	13	0.64	18	16	1.20	12	0.57
1.22	15	16	12	0.77	18	15	1.31	11	0.71
1.51	15	14	7	1.53	14	7	1.35	9	0.81
1.52	15	14	7	1.62	14	7	1.68	7	0.87
1.57	14	14	7	1.71	13	7	1.83	7	1.18
2.43	11	11	6	1.94	12	7	2.10	6	1.25
2.79	9	11	4	2.48	11	6	2.93	3	1.33
3.40	9	6	1	2.71	11	5	2.96	3	1.34
4.52	8	5	0	4.12	6	0	3.00	3	1.49
4.72	8	5	0	5.65	5	0	3.09	2	1.50
6.90	6	3	0	6.76	3	0	3.36	1	2.09
7.58	4	3	0	7.08	3	0	4.34	0	2.70
7.78	4	3	0	7.26	3	0	5.81	0	2.75
9.62	2	3	0	7.92	3	0	5.94	0	2.83
10.05	2	3	0	8.04	3	0	10.16	0	3.07
10.32	2	2	0	12.10	1	0	10.98	0	3.28
21.08	0	0	0	18.47	0	0	18.21	0	4.11
المجموع U_{ij}	**191**	**188**	**104**		**196**	**122**		**111**	

الجدول 1 ترتيب البيانات لتوضيح اختبار Jonckheere من أجل مثال الصوبا من الفصل 13

إن إحصائية الاختبار J هي ببساطة مجموع هذه الأعداد:

$$J = \sum_{I<j}^{k} U_{ij}$$

ومن أجل هذا المثال فإن J تساوي:

$$J=191+188+104+196+122+111=912$$

ومن أجل العينات الصغيرة توجد جداول خاصة تحوي القيم الحرجة للإحصائية J. على كل حال، عندما تكون العينة كبيرة (وفي هذا المثال تكون العينة كبيرة عندما يكون عدد العناصر فيها أكبر

من 8) فإن توزيع أخذ العينات للإحصائية J يصبح طبيعياً مع قيمة متوسطة وانحراف معياري يعرّفان بالعلاقات:

$$\bar{J} = \frac{N^2 - \sum n_k^2}{4}$$

$$\sigma_j = \sqrt{\frac{1}{72}\left[N^2(2N+3) - \sum n_k^2(2n_k+3)\right]}$$

حيث N حجم العينة الكلي (وفي هذا المثال N=80) و n_k حجم العينة للمجموعة k (وفي هذا المثال لدينا 4 مجموعات متساوية الحجم أي أن n_k=20). نحسب القيمة المتوسطة بالشكل:

$$\bar{J} = \frac{80^2 - \left(20^2 + 20^2 + 20^2 + 20^2\right)}{4}$$

$$= 1200$$

كما يمكن حساب الانحراف المعياري بالشكل:

$$\sigma_j = \sqrt{\frac{1}{72}\left[80^2(2\times 80+3) - \left[20^2(2\times 20+3) + 20^2(2\times 20+3) + 20^2(2\times 20+3) + 20^2(2\times 20+3)\right]\right]}$$

$$= 116.33$$

يمكننا أن نستخدم القيمة المتوسطة والانحراف المعياري لتحويل J إلى علامة معيارية z (أنظر الفصل 1) وذلك باستخدام الصيغة القياسية التالية:

$$z = \frac{x - \bar{x}}{s} = \frac{J - \bar{J}}{\sigma_j} = \frac{912 - 1200}{116.33} = -2.476$$

يمكن تقييم العلامة المعيارية z باستخدام القيم الحرجة في الملحق A1. إن هذا الاختبار أحادي الطرف دائماً لأنه يجب أن نضع منحى متوقعاً لكي نستخدم هذا الاختبار. لذلك نبحث عن قيم z التي تكون أكبر من 1.65 (بالقيمة المطلقة) لكي يكون ذا دلالة. تدلنا إشارة الاختبار عما إذا كان الوسط يزداد عبر المجموعات (قيم z الموجبة) أو يتناقص عبر المجموعات (قيم z السالبة) كما في هذا المثال.

هل هناك أهمية لترتيب المجموعات؟

لقد عرضنا في الحالة السابقة كيفية استخدام اختبار Jonckheere عند ترتيب المجموعات وفق تناقص الوسط (لقد توقعنا أن يكون عدد الحيوانات المنوية أعظمياً في المجموعة التي لم تتناول أي وجبة صويا ثم يتناقص وفق الترتيب التالي: وجبة واحدة أسبوعياً ثم 4 وجبات أسبوعياً ثم 7 وجبات أسبوعياً، ولذلك قمنا بترتيب المجموعات بالشكل: 0 وجبة صويا- وجبة واحدة- 4 وجبات- 7 وجبات). وتطلب بعض الكتب ترتيب المجموعات بشكل تصاعدي (أي أننا نبدأ بالمجموعة التي نتوقع أن تكون قيمة الوسط فيها هي الأدنى). ومن أجل بيانات مثال الصويا فهذا يعني ترتيب المجموعات بشكل معاكس لما فعلناه سابقاً، أي أننا نبدأ مع المجموعة التي تتناول 7 وجبات من الصويا أسبوعياً ثم المجموعة 4 وجبات ثم المجموعة 1 وجبة وأخيراً المجموعة 0 وجبة.

والهدف من هذه الفقرة هو توضيح ما يحدث إذا قمنا بترتيب المجموعات بشكل معاكس.

العملية مشابهة لما فعلناه سابقاً ولكننا سنبدأ بالمجموعة التي تتناول 7 وجبات أسبوعياً، حيث نأخذ العلامة الأولى ونطرح السؤال التالي: كم يبلغ عدد العلامات التي هي أكبر من هذه العلامة في الحالة التجريبية التالية؟ إذا قمت بترتيب العلامات تصاعدياً في كل حالة تجريبية فإن تنفيذ ذلك العمل يصبح سهلاً جداً. يعرض الجدول 2 طريقة مناسبة لترتيب البيانات. لاحظ أنه تم ترتيب عدد الحيوانات المنوية تصاعدياً، وترتيب المجموعات بالطريقة التي نتوقع فيها ازدياد الوسط.وهكذا نبدأ مع العلامة الأولى في المجموعة 7وجبات أسبوعياً (وهي العلامة 0.31) وننظر إلى العلامات في المجموعة التجريبية التالية (4 وجبات أسبوعياً) ونحسب عدد العلامات التي هي أكبر من 0.31 فنجد أن العدد هو 20، ولذلك نضع القيمة 20 في العمود المناسب و ننتقل إلى العلامة التالية (وهي 0.32) ونقوم بنفس العمل. عند الانتهاء من هذا العمل لجميع العلامات في الحالة 7 وجبات نعود مرة أخرى إلى العلامة الأولى (0.31) ولكن في هذه المرة نحسب عدد العلامات التي هي أكبر من 0.35 في الحالة التجريبية التالية (1 وجبة أسبوعياً) فنجد أن العدد هو 20 ولذلك نضع القيمة 20 في العمود المناسب وننتقل إلى العلامة التالية (0.32) ونقوم بنفس العمل. وعند الانتهاء من مقارنة العلامات في المجموعة 1 وجبة ننتقل إلى المجموعة 0 وجبة ونكرر نفس العمل بحيث نقارن المجموعة الأولى (7 وجبات) مع جميع المجموعات التالية.

ننتقل بعد ذلك إلى المجموعة التالية (4 وجبات أسبوعياً). ومرة أخرى نبدأ مع العلامة الأولى (0.40) وننظر إلى العلامات في المجموعة التجريبية التالية (1 وجبة أسبوعياً) ونحسب عدد العلامات التي هي أكبر من 0.40 فنجد أن العدد هو 18 لذلك نضع القيمة 18 في العمود المناسب وننتقل إلى العلامة التالية (0.60). نكرر ذلك العمل لجميع العلامات في المجموعة 4 وجبات، وعند الانتهاء نعود مرة أخرى إلى العلامة الأولى (0.40) في المجموعة 4 وجبات ونكرر نفس العمل مع علامات المجموعة التجريبية التالية (0 وجبة أسبوعياً). وعند الانتهاء ننتقل إلى المجموعة التالية (1 وجبة أسبوعياً). ونكرر العمل حتى ننتهي من مقارنة كل مجموعة مع المجموعات التالية. بعد ذلك نقوم بجمع الأعداد في كل عمود ونسمي المجموع U_{ij}.

0 وجبة	وجبة واحدة فقط		4 وجبات			7 وجبات صويا			
عدد الحيوانات المنوية	عدد العلامات الأكبر في	عدد الحيوانات المنوية	عدد العلامات الأكبر في		عدد الحيوانات المنوية	عدد العلامات الأكبر في			عدد الحيوانات المنوية
	0 وجبة		0 وجبة	وجبة فقط		0 وجبة	وجبة فقط	4 وجبات	
0.35	20	0.33	19	18	0.40	20	20	20	0.31
0.58	19	0.36	18	18	0.60	20	20	20	0.32
0.88	18	0.63	16	15	0.96	19	18	19	0.56
0.92	18	0.64	16	15	1.20	19	18	19	0.57
1.22	18	0.77	15	15	1.31	18	16	18	0.71
1.51	13	1.53	15	15	1.35	18	15	18	0.81
1.52	12	1.62	12	13	1.68	18	15	18	0.87
1.57	12	1.71	12	12	1.83	16	15	17	1.18
2.43	12	1.94	12	11	2.10	15	15	16	1.25
2.79	11	2.48	10	9	2.93	15	15	15	1.33
3.40	11	2.71	10	9	2.96	15	15	15	1.34
4.52	9	4.12	10	9	3.00	15	15	14	1.49
4.72	7	5.65	10	9	3.09	15	15	14	1.50
6.90	7	6.76	10	9	3.36	12	11	12	2.09
7.58	6	7.08	9	8	4.34	11	10	11	2.70
7.78	6	7.26	7	7	5.81	11	9	11	2.75
9.62	4	7.92	7	7	5.94	10	9	11	2.83
10.05	4	8.04	2	2	10.16	10	9	8	3.07
10.32	1	12.10	1	2	10.98	10	9	7	3.28
21.08	1	18.47	1	1	18.21	9	9	6	4.11
	209		**212**	**204**		**296**	**278**	**289**	**المجموع U_{ij}**

الجدول 2 ترتيب البيانات لتوضيح اختبار Jonckheere من أجل مثال الصويا من الفصل 13

إن إحصائية الاختبار J هي ببساطة مجموع هذه الأعداد:

$$J = \sum_{i<j}^{k} U_{ij}$$

ومن أجل هذا المثال فإن J تساوي:

$$J=289+278+296+204+212+209=1488$$

وكما ذكرنا سابقاً فإنه من أجل العينات الصغيرة هناك جداول خاصة تحوي القيم الحرجة للإحصائية J. على كل حال، عندما تكون العينة كبيرة (وفي هذا المثال تكون العينة كبيرة عندما

يكون عدد العناصر فيها أكبر من 8) فإن توزيع أخذ العينات للإحصائية J يصبح طبيعياً مع قيمة متوسطة وانحراف معياري يعرّفان بالعلاقات:

$$\bar{J} = \frac{N^2 - \sum n_k^2}{4}$$

$$\sigma_j = \sqrt{\frac{1}{72}\left[N^2(2N+3) - \sum n_k^2(2n_k+3)\right]}$$

حيث N حجم العينة الكلي (وفي هذا المثال N=80) و n_k حجم العينة k (وفي هذا المثال لدينا 4 مجموعات متساوية الحجم أي أن n_k=20). نحسب القيمة المتوسطة بالشكل:

$$\bar{J} = \frac{80^2 - \left(20^2 + 20^2 + 20^2 + 20^2\right)}{4}$$

$$= 1200$$

كما يمكن حساب الانحراف المعياري بالشكل:

$$\sigma_j = \sqrt{\frac{1}{72}\left[80^2(2\times 80+3) - \left[20^2(2\times 20+3) + 20^2(2\times 20+3) + 20^2(2\times 20+3) + 20^2(2\times 20+3)\right]\right]}$$

$$= 116.33$$

يمكننا أن نستخدم القيمة المتوسطة والانحراف المعياري لتحويل J إلى علامة معيارية z (أنظر الفصل 1) وذلك باستخدام الصيغة القياسية التالية:

$$z = \frac{x - \bar{x}}{s} = \frac{J - \bar{J}}{\sigma_j} = \frac{1488 - 1200}{116.33} = 2.476$$

لاحظ أن العلامة المعيارية z هي نفس القيمة التي حصلنا عليها عندما رتبنا المجموعات بشكل تنازلي باستثناء أن قيمتها موجبة! وهذا يثبت ما كتبناه سابقاً: إن إشارة الاختبار تدلنا على ازدياد الوسط عبر المجموعات عندما تكون قيمة z موجبة، أو انخفاض الوسط عبر المجموعات عندما تكون قيمة z سالبة. لقد قمنا في المرة الأولى بترتيب المجموعات بشكل تنازلي ولذلك حصلنا على قيمة z سالبة، وفي المرة الثانية قمنا بترتيب المجموعات بشكل تصاعدي ولذلك حصلنا على قيمة z موجبة.

A.8 ملحق الفصل 14

حساب المصفوفة E^{-1}

إذا كانت المصفوفة E مصفوفة مربعة أبعادها 2×2 وعناصرها معطاة بالشكل:

$$E = \begin{pmatrix} 51 & 13 \\ 13 & 122 \end{pmatrix}$$

فإنه يمكن حساب محدد المصفوفة من العلاقة التالية:

$$|E| = (51 \times 122) - (13 \times 13) = 6053$$

وتكون مصفوفة المتممات للمصفوفة E هي:

$$\text{matrix of minors for } E = \begin{pmatrix} 122 & 13 \\ 13 & 51 \end{pmatrix}$$

ونموذج الإشارات لهذه المصفوفة:

$$\begin{pmatrix} + & - \\ - & + \end{pmatrix}$$

وبذلك تكون مصفوفة العوامل المشتركة هي:

$$\begin{pmatrix} +122 & -13 \\ -13 & +51 \end{pmatrix}$$

ونحصل على مقلوب المصفوفة E (أي E^{-1}) بتقسيم عناصر مصفوفة العوامل المشتركة على محدد المصفوفة:

$$E^{-1} = \begin{pmatrix} \frac{122}{6053} & \frac{-13}{6053} \\ \frac{-13}{6053} & \frac{51}{6053} \end{pmatrix} = \begin{pmatrix} 0.0202 & -0.0021 \\ -0.0021 & 0.0084 \end{pmatrix}$$

حساب المصفوفة HE^{-1}

$$\begin{aligned} HE^{-1} &= \begin{pmatrix} 10.47 & -7.53 \\ -7.53 & 19.47 \end{pmatrix} \begin{pmatrix} 0.0202 & -0.0021 \\ -0.0021 & 0.0084 \end{pmatrix} \\ &= \begin{pmatrix} (10.47 \times 0.0202) + (-7.53 \times -0.0021) & (10.47 \times -0.0021) + (-7.53 \times 0.0084) \\ (-7.53 \times 0.0202) + (19.47 \times -0.0021) & (-7.53 \times -0.0021) + (19.47 \times 0.0084) \end{pmatrix} \\ &= \begin{pmatrix} 0.2273 & -0.0852 \\ -0.1930 & 0.1794 \end{pmatrix} \end{aligned}$$

حساب القيم الخاصة

تعتبر القيم الخاصة أو الجذور لأي مصفوفة مربعة هي حلول معادلة المميز التالية:

$$|A - \lambda I| = 0$$

حيث A هي المصفوفة المربعة المعنية، و I هي المصفوفة المحايدة بنفس أبعاد المصفوفة A. ويكون عدد القيم الخاصة مساوياً لعدد أسطر المصفوفة المربعة (أو عدد أعمدتها). وفي هذا المثال نبحث عن القيم الخاصة للمصفوفة HE^{-1}. نشكّل المعادلة المطلوبة:

$$\begin{aligned}
\left|HE^{-1} - \lambda I\right| &= \left|\begin{pmatrix} 0.2273 & -0.0852 \\ -0.1930 & 0.1794 \end{pmatrix} - \begin{pmatrix} \lambda & 0 \\ 0 & \lambda \end{pmatrix}\right| \\
&= \left|\begin{pmatrix} 0.2273-\lambda & -0.0852 \\ -0.1930 & 0.1794-\lambda \end{pmatrix}\right| \\
&= (0.2273-\lambda)(0.1794-\lambda) - (-0.1930 \times -0.0852) \\
&= \lambda^2 - 0.2273\lambda - 0.1794\lambda + 0.0407 - 0.0164 \\
&= \lambda^2 - 0.4067\lambda + 0.0243
\end{aligned}$$

وهكذا يمكن التعبير عن المعادلة $|HE^{-1} - \lambda I| = 0$ بالشكل التالي:

$$\lambda^2 - 0.4067\lambda + 0.0243 = 0$$

ويمكن حل هذه المعادلة من الدرجة الثانية $a\lambda^2 + b\lambda + c = 0$ بأي من الطرق المعروفة (حيث a=1 و b=-0.4067 و c=0.0243):

$$\begin{aligned}
\lambda_i &= \frac{-b \pm \sqrt{(b^2 - 4ac)}}{2a} \\
&= \frac{0.4067 \pm \sqrt{((-0.4067)^2 - 4 \times 1 \times 0.0243)}}{2 \times 1} \\
&= \frac{0.4067 \pm 0.2612}{2}
\end{aligned}$$

والقيم الخاصة هي: λ_1=0.334 و λ_2=0.073.

A.9 حساب معاملات علامات العامل

$$B = R^{-1} \cdot A$$

$$B = \begin{pmatrix} 4.76 & -7.46 & 3.91 & -2.35 & 2.42 & -0.49 \\ -7.46 & 18.49 & -12.42 & 5.45 & -5.54 & 1.22 \\ 3.91 & -12.42 & 10.07 & -3.65 & 3.79 & -0.96 \\ -2.35 & 5.45 & -3.65 & 2.97 & -2.16 & 0.02 \\ 2.42 & -5.54 & 3.79 & -2.16 & 2.98 & -0.56 \\ -0.49 & 1.22 & -0.96 & 0.02 & -0.56 & 1.27 \end{pmatrix} \begin{pmatrix} 0.87 & 0.01 \\ 0.96 & -0.03 \\ 0.92 & 0.04 \\ 0.00 & 0.82 \\ -0.10 & 0.75 \\ 0.09 & 0.70 \end{pmatrix}$$

العمود الأول من المصفوفة B

للحصول على العنصر الأول من العمود الأول للمصفوفة B (أي العنصر B_{11}) علينا أن نضرب كل عنصر من العمود الأول للمصفوفة A بالعنصر الموافق له في المكان من السطر الأول للمصفوفة R^{-1}، ثم نجمع هذه الجداءات معاً. وللحصول على العنصر الثاني من العمود الأول للمصفوفة B (أي العنصر B_{21}) علينا أن نضرب كل عنصر من العمود الأول للمصفوفة A بالعنصر الموافق له في المكان من السطر الثاني للمصفوفة R^{-1}، ثم نجمع هذه الجداءات معاً ... وهلم جرا:

$$B_{11} = (4.75924 \times 0.87407) + (-7.46190 \times 0.95768) + (3.90949 \times 0.92138) + (-2.35093 \times -0.00237) + (2.42104 \times -0.09575) + (-0.48607 \times 0.096)$$
$$= 0.343$$

$$B_{21} = (-7.4619 \times 0.87407) + (18.48556 \times 0.95768) + (-12.41679 \times 0.92138) + (5.445 \times -0.00237) + (-5.54427 \times -0.09575) + (1.22155 \times 0.096)$$
$$= 0.376$$

$$B_{31} = (3.90949 \times 0.87407) + (-12.41679 \times 0.95768) + (10.07382 \times 0.92138) + (-3.64853 \times -0.00237) + (3.78869 \times -0.09575) + (-0.95731 \times 0.096)$$
$$= 0.362$$

$$B_{41} = (-2.35093 \times 0.87407) + (5.445 \times 0.95768) + (-3.64853 \times 0.92138) + (2.96922 \times -0.00237) + (-2.16094 \times -0.09575) + (0.02255 \times 0.096)$$
$$= 0.000$$

$$B_{51} = (2.42104 \times 0.87407) + (-5.54427 \times 0.95768) + (3.78869 \times 0.92138) + (-2.16094 \times -0.00237) + (2.97983 \times -0.09575) + (-0.56017 \times 0.096)$$
$$= 0.037$$

$$B_{61} = (-0.48607 \times 0.87407) + (1.22155 \times 0.95768) + (-0.95731 \times 0.92138) + (0.02255 \times -0.00237) + (-0.56017 \times -0.09575) + (1.27072 \times 0.096)$$
$$= 0.039$$

العمود الثاني من المصفوفة B

للحصول على العنصر الأول من العمود الثاني للمصفوفة B (أي العنصر B_{12}) علينا أن نضرب كل عنصر من العمود الثاني للمصفوفة A بالعنصر الموافق له في المكان من السطر الأول للمصفوفة R^{-1}، ثم نجمع هذه الجداءات معاً. وللحصول على العنصر الثاني من العمود الثاني للمصفوفة B (أي العنصر B_{22}) علينا أن نضرب كل عنصر من العمود الثاني للمصفوفة A بالعنصر الموافق له في المكان من السطر الثاني للمصفوفة R^{-1}، ثم نجمع هذه الجداءات معاً ... وهلم جرا:

$$B_{12} = (4.75924 \times 0.00842) + (-7.46190 \times -0.03653) + (3.90949 \times 0.03178) + (-2.35093 \times 0.81556) + (2.42104 \times 0.75435) + (-0.48607 \times 0.69936) = 0.006$$

$$B_{22} = (-7.4619 \times 0.00842) + (18.48556 \times -0.03653) + (-12.41679 \times 0.03178) + (5.445 \times 0.81556) + (-5.54427 \times 0.75435) + (1.22155 \times 0.69936) = -0.020$$

$$B_{32} = (3.90949 \times 0.00842) + (-12.41679 \times -0.03653) + (10.07382 \times 0.03178) + (-3.64853 \times 0.81556) + (3.78869 \times 0.75435) + (-0.95731 \times 0.69936) = 0.020$$

$$B_{42} = (-2.35093 \times 0.00842) + (5.445 \times 0.03653) + (-3.64853 \times 0.03178) + (2.96922 \times 0.81556) + (-2.16094 \times 0.75435) + (0.02255 \times 0.69936) = 0.473$$

$$B_{52} = (2.42104 \times 0.00842) + (-5.54427 \times -0.03653) + (3.78869 \times 0.03178) + (-2.16094 \times 0.81556) + (2.97983 \times 0.75435) + (-0.56017 \times 0.69936) = 0.437$$

$$B_{62} = (-0.48607 \times 0.00842) + (1.22155 \times -0.03653) + (-0.95731 \times 0.03178) + (0.02255 \times 0.81556) + (-0.56017 \times 0.75435) + (1.27072 \times 0.69936) = 0.405$$

وهكذا تكون المصفوفة B بالشكل:

$$B = \begin{pmatrix} 0.343 & 0.006 \\ 0.376 & -0.020 \\ 0.362 & 0.020 \\ 0.000 & 0.473 \\ -0.037 & 0.437 \\ 0.039 & 0.405 \end{pmatrix}$$

A.10 تعريف المقارنات باستخدام القواعد

لماذا نضطر لاستخدام القواعد؟

استخدمنا في الفصول 10 و11 و12 من الكتاب المقارنات الجاهزة في برنامج SPSS لمقارنة المجموعات المختلفة بعد تنفيذ تحليل التباين (ANOVA). وهذه المقارنات الخاصة (التي تم وصفها في الجدول 6.8 في الفصل 8) تغطي معظم الحالات، ولكن في التصاميم الأكثر تعقيداً هناك حالات لا يمكن فيها استخدام المقارنات الجاهزة في برنامج SPSS. وفي حالة التصاميم العاملية ليس هناك طريقة لتعريف رموز المقارنات عبر مربعات الحوار المألوفة. وعلى كل حال يسمح برنامج SPSS بتنفيذ هذه المقارنات إذا قمنا بتعريفها باستخدام القواعد (Syntax).

مثال

تخيل أن أحد الأطباء النفسيين أراد معرفة الآثار لعقار جديد مضاد للاكتئاب يدعى Cheerup. فأخذ 50 شخصاً يعانون من الاكتئاب ووزعهم بشكل عشوائي على 5 مجموعات. المجموعة الأولى هي مجموعة قائمة الانتظار التي تعمل كمجموعة مراقبة (وهي مجموعة لم تتم معالجتها خلال الدراسة)، وتناولت المجموعة الثانية أقراصاً تمويهية (تم إخبار هذه المجموعة بأنها تأخذ علاجاً مضاداً للاكتئاب بينما هي تتناول أقراصاً تحوي السكر بدون أي عناصر فعّالة)، وتناولت المجموعة الثالثة عقاراً مضاداً للاكتئاب SSRI معروفاً يدعى Seroxat، وتناولت المجموعة الرابعة عقاراً مضاداً للاكتئاب SNRI يدعى Effexor، أما المجموعة الأخيرة فقد تناولت العقار الجديد Cheerup. وقد تم قياس مستويات الاكتئاب قبل العلاج وبعد شهرين من العلاج، وذلك على مقياس يتراوح بين 0 (سعيد جداً) و20 (كئيب جداً).

إن التصميم في هذه الدراسة هو تصميم مختلط ثنائي الاتجاه. هناك متحولان مستقلان هما نوع المعالجة (بدون علاج، علاج تمويهي، Seroxat، Effexor، Sheerup) والزمن (قبل المعالجة وبعد المعالجة). وقد تم قياس المتحول الأول (نوع المعالجة) باستخدام مشتركين مختلفين (ولذلك فهو متحول بين المجموعات) أما المتحول الثاني (الزمن) فقد تم قياسه باستخدام نفس المشتركين (ولذلك فهو متحول قياسات مكررة). وهكذا فإن المطلوب هو استخدام 2×5 تحليل للتباين ثنائي الاتجاه.

والآن، نرغب بإجراء بعض المقارنات. تخيل أننا وضعنا الفرضيات التالية:

1. إن أي علاج هو أفضل من عدم العلاج.
2. العلاج بالعقارات هو أفضل من العلاج بالدواء التمويهي.
3. العقار الجديد Cheerup هو أفضل من العقاقير من الطراز القديم.
4. العقاقير من الطراز القديم لا تختلف في فعاليتها عن بعضها البعض.

وعلينا ترميز هذه الفرضيات المختلفة كما فعلنا في الفصل 8. تتضمن المقارنة الأولى مقارنة حالة عدم العلاج مع جميع المجموعات الأخرى. ولذلك فإن الخطوة الأولى هي فصل المتحولات إلى جزئين وتعيين ثقل موجب لجزء منها وثقل سالب للجزء الآخر.

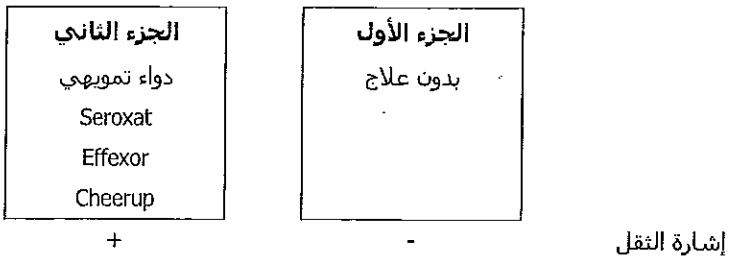

بعد إنجاز هذه الخطوة، علينا تعيين قيمة عددية للمجموعات في كل جزء. وكما ذكرنا في الفصل 8 فإن أسهل طريقة لتنفيذ ذلك هي تعيين قيمة مساوية لعدد المجموعات في الجزء المقابل. ولذلك فإن قيمة الثقل لأي مجموعة في الجزء الأول ستكون مساوية لعدد المجموعات في الجزء الثاني (وهو 4). وبشكل مشابه فإن قيمة الثقل لأي مجموعة في الجزء الثاني ستكون مساوية لعدد المجموعات في الجزء الأول (وهو 1). ولذلك فإننا نحصل على الرموز التالية:

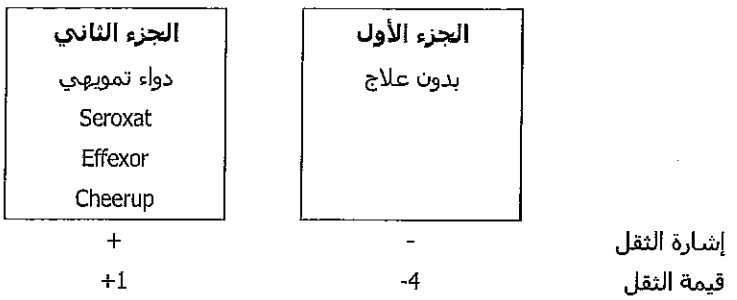

تتطلب المقارنة الثانية مقارنة مجموعة الدواء التمويهي مع جميع المجموعات التي تناولت عقاراً مضاداً للاكتئاب. ومرة أخرى نقوم بفصل المجموعات وفقاً لذلك، وتعيين إشارة سالبة إلى أحد الجزئين وإشارة موجبة إلى الجزء الآخر، ثم تعيين الثقل على أساس عدد المجموعات في الجزء المقابل. علينا أن نتذكر أن نعطي مجموعة عدم العلاج الثقل 0 لأنها غير متضمنة في المقارنة الحالية.

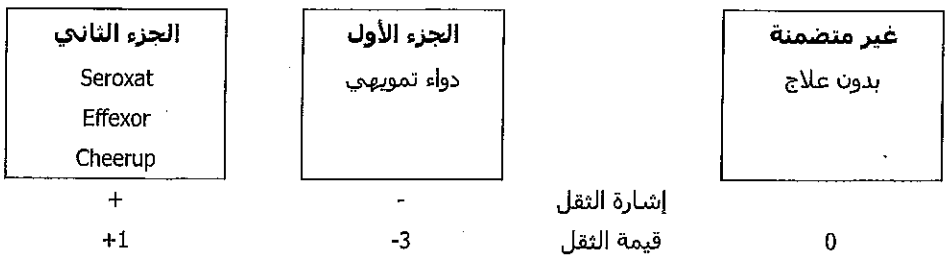

تتطلب المقارنة الثالثة مقارنة العقار الجديد (Cheerup) مع العقاقير القديمة (Seroxat وEffexor). ومرة أخرى نقوم بفصل المجموعات وفقاً لذلك، وتعيين إشارة سالبة إلى أحد الجزئين وإشارة موجبة إلى الجزء الآخر، ثم تعيين الثقل على أساس عدد المجموعات في الجزء المقابل. علينا أن نتذكر أيضاً أن نعطي مجموعتي عدم العلاج والدواء التمويهي الثقل 0 لأنهما لا تدخلان في المقارنة الحالية.

الجزء الثاني	الجزء الأول		غير متضمنة
Seroxat Effexor	Cheerup		بدون علاج دواء تمويهي
+	-	إشارة الثقل	
+1	-2	قيمة الثقل	0

وتتطلب المقارنة الأخيرة مقارنة العقارين من الطراز القديم. ومرة أخرى نقوم بفصل المجموعات وفقاً لذلك، وتعيين إشارة سالبة إلى أحد الجزئين وإشارة موجبة إلى الجزء الآخر، ثم تعيين الثقل على أساس عدد المجموعات في الجزء المقابل. علينا أن نتذكر أيضاً أن نعطي مجموعات عدم العلاج والدواء التمويهي والعقار الجديد (Cheerup) الثقل 0 لأنها لا تدخل في المقارنة الحالية.

الجزء الثاني	الجزء الأول		غير متضمنة
Seroxat	Effexor		بدون علاج دواء تمويهي Cheerup
+	-	إشارة الثقل	
+1	-1	قيمة الثقل	0

يمكننا تلخيص هذه المقارنات في الجدول التالي:

	بدون علاج	دواء تمويهي	Seroxat	Effexor	Cheerup
المقارنة الأولى	-4	1	1	1	1
المقارنة الثانية	0	-3	1	1	1
المقارنة الثالثة	0	0	1	1	-2
المقارنة الرابعة	0	0	1	-1	0

نحتاج لهذه القيم في برنامج SPSS من أجل تنفيذ المقارنات المطلوبة.

إدخال المقارنات باستخدام القواعد

لإدخال هذه المقارنات باستخدام القواعد علينا فتح نافذة القواعد (Syntax) أولاً، ويمكنك العودة للفصل 2 لمعرفة ذلك. بعد ذلك ينبغي علينا كتابة التعليمات التالية:

```
MANOVA
before after BY treat(0 4)
```

وتقوم هذه التعليمات ببدء عملية ANOVA في برنامج SPSS. ويقوم السطر الثاني بتحديد المتحولات في محرر البيانات، وهما المتحولان before وafter (متحولات القياس المكررة)، وما يأتي بعد الكلمة BY هو متحول القياسات بين المجموعات ولذلك ينبغي أن يليه قوسان يحصران القيمة الدنيا والقيمة العظمى لمتحول الترميز. لقد سمينا المتحول بين المجموعات treat، وقمنا بترميز المجموعات بالشكل التالي: 0=بدون علاج، و1=الدواء التمويهي، و2=Seroxat و3=Effexor و4=Cheerup. ولذلك فإن القيمة الدنيا لمتحول الترميز هي 0 والقيمة العظمى هي 4. وهكذا فإن هذين السطرين يطلبان من برنامج SPSS بدء إجرائية ANOVA ويخبرانه بوجود متحولين للقياسات المكررة هما before وafter وبوجود متحول بين المجموعات يدعى treat تتراوح قيمته بين 0 و4.

```
/WSFACTORS time(2)
```

تسمح التعليمة /WSFACTORS بتحديد متحولات القياسات المكررة. يعلم برنامج SPSS بوجود اثنين من المتحولات هما before وafter ولكنه لا يعرف كيفية التعامل مع هذين المتحولين. وتطلب هذه التعليمة من برنامج SPSS أن يقوم بإنشاء متحول قياسات مكررة يدعى time وله مستويان (العدد بين القوسين). يبحث برنامج SPSS بعد ذلك عن المتحولات المعرّفة سابقاً ويعين المتحول الأول (وهو before) إلى المستوى الأول من متحول القياسات المكررة time، ويعين المتحول الثاني (وهو after) إلى المستوى الثاني من المتحول time.

نستخدم التعليمة التالية لتحديد المقارنات للمتحول الأول:

```
/CONTRAST(time)=Special(1 1 , 1 -1)
```

تُستخدم التعليمة /CONTRAST لتحديد أي مقارنة، ويليها عادة اسم المتحول الذي نريد تطبيق المقارنة عليه بين القوسين. لدينا متحولان (time وtreat) وفي هذه المقارنة الأولى نريد تحديد المقارنة للمتحول time. وللمتحول time مستويان فقط ولذلك فإن كل ما علينا عمله هو أن نطلب من برنامج SPSS مقارنة هذين المستويين (وهذا ما يقوم به البرنامج بشكل افتراضي، ولكننا نرغب بالتدريب على ذلك). نضع بعد اسم المتحول إشارة مساواة لتعريف المقارنة، لذلك يمكننا أن نضع اسم إحدى المقارنات القياسية مثل Helmert ولكننا نريد تعريف مقارنة خاصة بنا ولذلك نستخدم الكلمة Special. يجب أن تتبع الكلمة Special رموز المقارنة موضوعة بين قوسين. يتم الفصل بين الرموز للمقارنات المختلفة باستخدام الفاصلة العادية، وضمن كل مقارنة يتم الفصل بين الرموز للمجموعات المختلفة باستخدام المسافة. ويجب أن تكون المقارنة الأولى دائماً هي المقارنة التي تحدد مقارنة مرجعية لجميع المقارنات الأخرى ويتم فيها ترميز جميع المجموعات بالرمز 1. لذلك وبما أن للمتحول time مستويان فقط فإن رموز المقارنة الأولى هي 1 1، وهذا يدل برنامج SPSS على أن المقارنة الأولى هي مقارنة يحمل فيها كل من المتحولين before وafter القيمة 1. وتدل الفاصلة على

نهاية المقارنة الأولى ووجود مقارنة ثانية. وقد تم تعريف هذه المقارنة الثانية بالشكل 1- 1 وهذا يدل برنامج SPSS على أن القيمة المعطاة للمتحول before هي 1، والقيمة المعطاة للمتحول after هي 1-. لاحظ أن الرموز المكتوبة داخل القوسين يتم تعيينها للمتحولات حسب الترتيب الذي تم فيه إدخال تلك المتحولات في السطر الثاني من هذه القواعد before after BY treat (0 4).

نستخدم التعليمة التالية لتحديد المقارنات للمتحول الثاني:

/CONTRAST(treat)= Special(1 1 1 1 1, -4 1 1 1 1, 0 -3 1 1 1, 0 0 1 1 -2, 0 0 1 -1 0)

وفي هذه المرة تم وضع اسم المتحول الثاني (treat) بعد التعليمة /CONTRAST. للمتحول treat خمسة مستويات وقد أوجدنا سابقاً 4 مقارنات مختلفة نرغب بتنفيذها. وكما في الحالة السابقة فقد استخدمنا الكلمة Special بعد إشارة المساواة لتعريف مقارنات خاصة بنا ووضع يتم الرموز بين قوسين. وقد تم الفصل بين الرموز للمقارنات المختلفة باستخدام الفاصلة العادية، والفصل بين الرموز للمجموعات المختلفة ضمن المقارنة الواحدة باستخدام المسافة. وتم تعريف المقارنة الأولى كمقارنة مرجعية وتم ترميز جميع المجموعات فيها بالرمز 1. لذلك وبما أن للمتحول treat خمسة مستويات فإننا نكتب 1 1 1 1 1، وهذا يدل برنامج SPSS على أن المقارنة الأولى هي مقارنة يحمل فيها كل من المجموعات الخمس القيمة 1. وتدل الفاصلة على نهاية المقارنة الأولى ووجود مقارنة ثانية. وقد تم تعريف المقارنة الثانية بالشكل 1 1 1 1 4-، وهذا يدل برنامج SPSS على إعطاء القيمة 4- للمجموعة الأولى والقيمة 1 لبقية المجموعات. ولكن كيف سيقرر برنامج SPSS من هي المجموعة الأولى؟ إنه يستخدم متحول الترميز في محرر البيانات ويقوم بترتيب المجموعات بنفس الترتيب. لذلك وبما أننا قمنا بترميز المجموعات بالشكل التالي: 0=بدون علاج، 1=دواء تمويهي، Seroxat=2، Effexor=3، Cheerup =4، فإن المقارنة الأولى تعطي الرمز 4- للمجموعة بدون علاج، والرمز 1 لبقية المجموعات. ومرة أخرى تدل الفاصلة على نهاية المقارنة الثانية ووجود مقارنة ثالثة. وقد تم تعريف المقارنة الثالثة بالشكل 1 1 1 3- 0، وهذا يدل برنامج SPSS على إعطاء القيمة 0 للمجموعة الأولى (بدون علاج)، والقيمة 3- للمجموعة الثانية (الدواء التمويهي) والقيمة 1 لبقية المجموعات. ومرة أخرى تدل الفاصلة على نهاية المقارنة الثالثة ووجود مقارنة رابعة. وقد تم تعريف المقارنة الرابعة بالشكل 2- 1 1 0 0، وهذا يدل برنامج SPSS على إعطاء القيمة 0 لكل من المجموعتين الأولى (بدون علاج) والثانية (الدواء التمويهي) وإعطاء القيمة 1 لكل من المجموعتين الثالثة (Seroxat) والرابعة (Effexor)، وإعطاء القيمة 2- للمجموعة الخامسة (Cheerup). وتدل الفاصلة على نهاية المقارنة الرابعة ووجود مقارنة خامسة. وقد تم تعريف المقارنة الخامسة بالشكل 0 1- 1 0 0، وهذا يدل برنامج SPSS على إعطاء القيمة 0 لكل من المجموعة الأولى (بدون علاج) والثانية (الدواء التمويهي) والخامسة (Cheerup) وإعطاء القيمة 1 للمجموعة الثالثة (Seroxat) والقيمة 1- للمجموعة الرابعة (Effexor). وهكذا فإن هذا السطر قد قام بتعريف المقارنات الأربع كما أردنا تماماً.

```
/CINTERVAL JOINT(0.95) MULTIVARIATE(BONFER)
```

يقوم هذا السطر بتعريف نوع مجالات الثقة التي تريدها للمقارنات المطلوبة. وننصح باستخدام خيار Bonferroni ولكن يمكنك إيجاد أنواع أخرى في دليل القواعد لبرنامج SPSS.

```
/METHODE UNIQUE
/ERROR WITHIN+RESIDUAL
/PRINT TRANSFORM HOMOGENEITY(BARTLETT COCHRAN BOXM)
 SIGNIF(UNIV MULT AVERF HF GG)
 PARAM(ESTIM EFSIZE).
```

تحدد هذه الأسطر عدة أشياء مختلفة (قد تكون مفيدة أو غير مفيدة) كمصفوفة التحويل (TRANSFORM) غير الضرورية هنا ولكنها مفيدة عند استخدام المقارنات الجاهزة في برنامج SPSS، واختبارات التجانس ((HOMOGENEITY(BARTLETT COCHRAN BOXM) وتحليل التباين الأساسي وتصحيحات Huynh-Feldt وGreenhouse-Geisser التي لا نحتاجها في هذا المثال (SIGNIF(UNIV MULT AVERF HF GG)) وتقدير البارامترات وتقدير حجم الأثر للمقارنات التي قمنا بتعريفها ((PARAM(ESTIM EFSIZE). وهكذا فإن النص الكامل للقواعد يصبح:

```
MANOVA
before after BY treat(0 4)
/WSFACTORS time(2)
/CONTRAST(time)=Special(1 1 , 1 -1)
/CONTRAST(treat)= Special(1 1 1 1 1, -4 1 1 1 1, 0 -3 1 1 1, 0 0 1 1 -2, 0 0 1 -1 0)
/CINTERVAL JOINT(0.95) MULTIVARIATE(BONFER)
/METHODE UNIQUE
/ERROR WITHIN+RESIDUAL
/PRINT TRANSFORM HOMOGENEITY(BARTLETT COCHRAN BOXM)
 SIGNIF(UNIV MULT AVERF HF GG)
 PARAM(ESTIM EFSIZE).
```

وتأكد من وضع النقطة في نهاية السطر الأخير.

الخرج من المقارنات

بعد تنفيذ مجموعة تعليمات القواعد التي أدخلناها نحصل على الخرج، ولتفسير هذا الخرج علينا أن نتذكر المقارنات التي قمنا بتعريفها. وسنقوم بتفسير المعالم الأساسية في هذا المثال.

يحوي الجزء الأول من الخرج اختبارات التجانس (والتي يجب أن تكون بدون دلالة ولكن يجب الانتباه لاختبار Box لأنه يميل لأن يكون غير دقيق). الجزء الأول الهام هو الأثر الأساسي للمتحول treat. هناك جدول ملخص لتحليل التباين (ANOVA)، وهو شبيه بالجداول التي رأيناها في الفصول 8-11. ويدلنا على عدم وجود أثر أساسي مهم لنوع العلاج، $F(4,45)=2.01,\ p>0.05$. وهذا يدلنا على أنه إذا أهملنا الوقت الذي تم فيه قياس الاكتئاب (time) فإن مستويات الاكتئاب كانت نفسها تقريباً عبر مجموعات العلاج المختلفة. ومن الطبيعي أن تكون مستويات الاكتئاب متماثلة قبل العلاج، ولذلك فإن هذه النتيجة غير مفاجئة (لأنها تأخذ القيم المتوسطة لعلامات الاكتئاب قبل العلاج وبعده). ويوضح المخطط ذلك، فمستويات الاكتئاب هي متماثلة نسبياً عبر المجموعات.

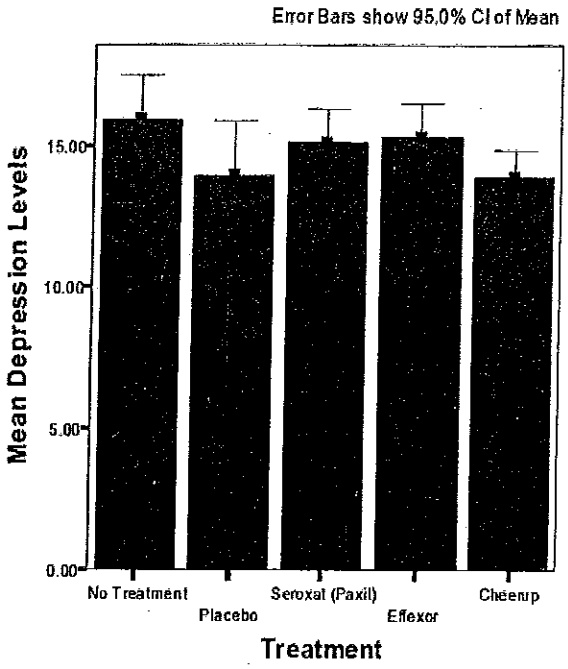

```
* * * * * * Analysis of Variance -- design 1 * * * * * *

Tests of Between-Subjects Effects.

Tests of Significance for T1 using UNIQUE sums of squares
Source of Variation          SS       DF       MS          F  Sig of F

WITHIN+RESIDUAL          359.95       45     8.00
TREAT                     64.30        4    16.08       2.01       .109

- - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - -

Estimates for T1
--- Joint univariate .9500 BONFERRONI confidence intervals

TREAT

 Parameter      Coeff.  Std. Err.      t-Value     Sig. t Lower -95% CL- Upper

         2  -7.7781746    3.99972    -1.94468      .05808  -18.18578    2.62944
         3   3.53553391   3.09817     1.14117      .25984   -4.52617   11.59723
         4   3.74766594   2.19074     1.71069      .09403   -1.95282    9.44815
         5   -.21213203   1.26482     -.16772      .86756   -3.50331    3.07904

 Parameter    ETA Sq.

         2       .07752
         3       .02813
         4       .06106
         5       .00062

- - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - - -
```

إن الأثر الأساسي متبوع ببعض المقارنات، ولكننا لن ننظر إلى هذه المقارنات لأن الأثر الأساسي عديم الدلالة. على كل حال، سنخبرك بما تمثله هذه المقارنات، فالبارامتر 2 يمثل المقارنة الأولى (بدون علاج مقابل البقية) وكما ترى فإن هذه المقارنة ذات دلالة تقريباً لأن قيمة .Sig أعلى من 0.05 بقليل. والبارامتر 3 يمثل المقارنة الثانية (الدواء التمويهي مقابل البقية) وهي عديمة الدلالة. والبارامتر 4 يمثل المقارنة الثالثة (Cheerup مقابل Effexor و Seroxat) وهي ذات دلالة تقريباً. أما البارامتر 5 فيمثل المقارنة الأخيرة (Seroxat مقابل Effexor) وهي عديمة الدلالة. على كل حال، تهمل جميع المقارنات أثر المتحول time ولذلك فهي لا تهمنا عملياً.

القسم التالي الذي يهمنا هو الآثار ضمن المواضيع، وهي تتضمن الأثر الأساسي للمتحول time والتفاعل بين time وtreat. في البداية لدينا جدول ملخص لتحليل التباين ويدلنا على وجود أثر أساسي مهم للمتحول time، $F(1,45)=43.02,\ p<0.001$. ويدلنا على أنه إذا أهملنا نوع المعالجة (treat) فإن هناك فرقاً مهماً بين مستويات الاكتئاب قبل العلاج وبعده. ومن نظرة سريعة إلى قيم المتوسط نكتشف أن مستويات الاكتئاب قبل العلاج كانت أدنى بشكل ملحوظ من مستويات الاكتئاب بعد العلاج. وتحت الجدول هناك تقدير البارامتر لأثر المتحول time. ونظراً لوجود مستويين فقط للمتحول time فإن ذلك يمثل الفرق في مستويات الاكتئاب قبل العلاج وبعده. وليست هناك مقارنات أخرى محتملة.

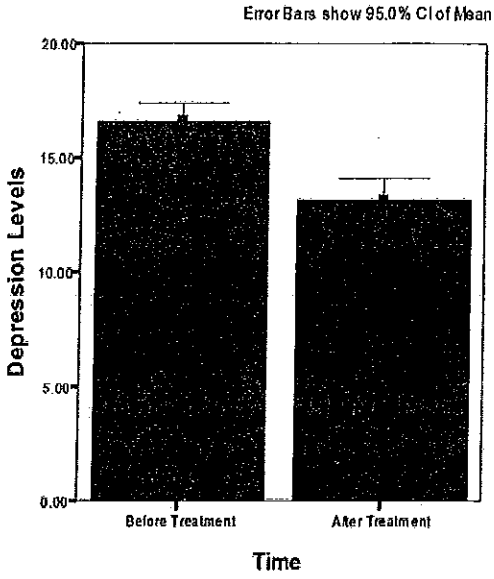

* * * * * * A n a l y s i s o f V a r i a n c e -- design 1 * * * * * *

Tests involving 'TIME' Within-Subject Effect.

Tests of Significance for T2 using UNIQUE sums of squares

Source of Variation	SS	DF	MS	F	Sig of F
WITHIN+RESIDUAL	320.35	45	7.12		
TIME	306.25	1	306.25	43.02	.000
TREAT BY TIME	125.90	4	31.47	4.42	.004

Estimates for T2
--- Joint univariate .9500 BONFERRONI confidence intervals

TIME

Parameter	Coeff.	Std. Err.	t-Value	Sig. t	Lower -95% CL-	Upper
1	2.47487373	.37733	6.55891	.00000	1.71489	3.23485

Parameter	ETA Sq.
1	.48875

TREAT BY TIME

Parameter	Coeff.	Std. Err.	t-Value	Sig. t	Lower -95% CL-	Upper
2	11.3137085	3.77330	2.99836	.00441	1.49527	21.13214
3	-.56568542	2.92278	-.19354	.84740	-8.17101	7.03964
4	-5.8689863	2.06672	-2.83976	.00675	-11.24676	-.49121
5	.919238816	1.19322	.77038	.44510	-2.18562	4.02410

Parameter	ETA Sq.
2	.16651
3	.00083
4	.15197
5	.01302

إن حد التفاعل مهم أيضاً، F(4,45)=4.42, p<0.01. وهذا يدل على أن التغير في مستوى الاكتئاب عبر الزمن مختلف في بعض أنواع المعالجة عن الأنواع الأخرى. ويمكن أن نتأكد من ذلك عبر مخطط التفاعل، كما يمكننا النظر إلى المقارنات. المقارنات الأساسية للتحليل الإجمالي هي تقديرات البارامترات لحد التفاعل (الجزء من الخرج الذي يقع تحت العنوان TREAT BY TIME) لأنها تأخذ بعين الاعتبار أثر المتحول time وtreat بآن واحد.

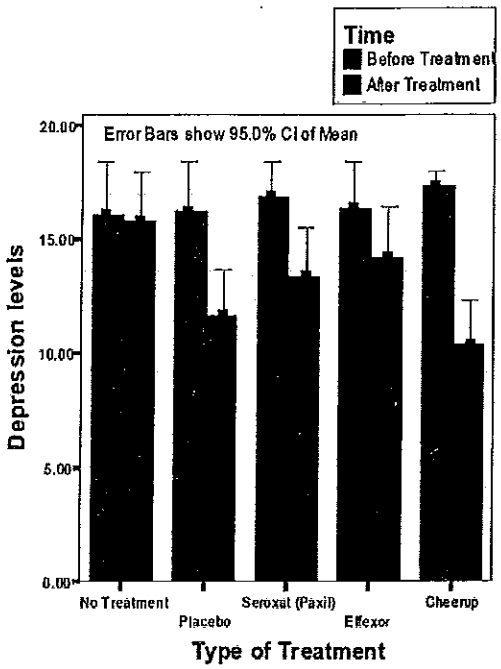

- يمثل البارامتر 2 المقارنة الأولى (بدون علاج مقابل البقية) وكما ترى فإنها ذات دلالة (p<0.05). وهذا يدلنا على أن التغير في مستويات الاكتئاب في المجموعة التي لم تتلق أي علاج كان مختلفاً بشكل كبير عن التغير المتوسط في بقية المجموعات، t=2.998, p<0.01. وكما ترى على المخطط، ليس هناك تغير في مستوى الاكتئاب في المجموعة التي لم تتلق أي علاج، بينما هناك انخفاض في مستوى الاكتئاب في بقية المجموعات. ولذلك فإن هذه المقارنة تعكس حقيقة عدم وجود تغير في المجموعة التي بقيت دون علاج، وحدوث انخفاض في مستوى الاكتئاب في بقية المجموعات.
- يمثل البارامتر 3 المقارنة الثانية (الدواء التمويهي مقابل Seroxat وEffexor وCheerup) وهذه المقارنة عديمة الدلالة t=-0.194, p=0.85. ويبين ذلك أن انخفاض مستويات الاكتئاب الملاحظ في مجموعة الدواء التمويهي مماثل للانخفاض المتوسط في مستويات الاكتئاب الملاحظ في المجموعات Seroxat وEffexor وCheerup. وبكلمات أخرى، إن الأثر المركب للعقاقير على الاكتئاب ليس أفضل من الدواء التمويهي.

- يمثل البارامتر 4 المقارنة الثالثة (Cheerup مقابل Seroxat وEffexor) وهذه المقارنة عالية الدلالة t=-2.84, p<0.01. ويبين ذلك أن انخفاض مستويات الاكتئاب الملاحظ في مجموعة Cheerup هو أكبر بكثير من الانخفاض المتوسط في مستويات الاكتئاب الملاحظ في المجموعتين Seroxat وEffexor. وبطريقة أخرى، إن للعقار Cheerup أثر أكبر من العقاقير الأخرى المضادة للاكتئاب.
- يمثل البارامتر 5 المقارنة الرابعة (Seroxat مقابل Effexor) وهي مقارنة عديمة الدلالة، t=0.77، p=0.45. وتدلنا على أن الانخفاض في مستويات الاكتئاب الملاحظ في مجموعة Seroxat مماثل للانخفاض الملاحظ في مجموعة Effexor. أي أن للعقارين Seroxat وEffexor آثاراً متماثلة في معالجة الاكتئاب.

نأمل أننا استطعنا عبر هذا المثال توضيح كيفية تعريف المقارنات باستخدام القواعد وكيفية أن النظر إلى هذه المقارنات (وخاصة من أجل حد التفاعل) يمكن أن يكون مفيداً في تقسيم أثر التفاعل.

A.11 تصميم استبيان

صفات الاستبيان الجيد

من السهل جداً تصميم استبيان ما، ولكن من المستحيل ظاهرياً تصميم استبيان جيد. إذ أن تصميم استبيان يستغرق وقتاً طويلاً دون أية ضمانات حول قابلية استخدامه من قبل أي شخص.

ويجب أن يتمتع الاستبيان الجيد بالصفات التالية:

- الصلاحية.
- الوثوقية.
- التمييز.

التمييز

قبل أن نتحدث عن الصلاحية والوثوقية علينا أن نتحدث عن التمييز، وهو عملياً مسألة اختيار العناصر. ويعني التمييز أن الأشخاص ذوي العلامات المختلفة في استبيان ما يجب أن يكونوا مختلفين في البنية التي نهتم بها. فعلى سبيل المثال، يجب أن يميز الاستبيان الذي يقيس الخوف (الرهاب) الاجتماعي بين الأشخاص ذوي الخوف الاجتماعي والأشخاص بدون الخوف الاجتماعي (أي أن الأشخاص في المجموعات المختلفة يجب أن يحققوا علامات مختلفة). هناك ثلاث نتائج طبيعية يجب أخذها بعين الاعتبار:

1. الأشخاص ذوي نفس العلامة يجب أن يكونوا متساوين عبر البنية المقاسة.
2. الأشخاص ذوي العلامات المختلفة يجب أن يكونوا مختلفين عن بعضهم البعض عبر البنية المقاسة.
3. درجة الفرق بين الأشخاص تتناسب مع الفرق بين العلامات.

لنأخذ مثالاً واقعياً بسيطاً ذي 3 عناصر يقيس الاجتماعية. تخيل أننا قدمنا هذا الاستبيان لشخصين: عاصم وزاهر. وكانت إجاباتهما كما في الشكل التالي:

عاصم		
	نعم	لا
1. أحب المشاركة في الحفلات	✓	
2. أذهب إلى المقاهي غالباً		✓
3. أستمتع فعلاً بمقابلة الناس	✓	

زاهر		
	نعم	لا
1. أحب المشاركة في الحفلات	✓	
2. أذهب إلى المقاهي غالباً	✓	
3. أستمتع فعلاً بمقابلة الناس		✓

لقد كانت إجابة عاصم "نعم" على العنصرين الأول والثالث، و"لا" على العنصر الثاني. فإذا أعطينا الإجابة "نعم" القيمة 1، والإجابة "لا" العلامة 0، فإن علامة عاصم الكلية في الاستبيان هي 2. أما إجابات زاهر فكانت "نعم" على العنصرين الأول والثاني، و"لا" على العنصر الثالث. وباستخدام

نظام منح العلامات السابق فإن علامة زاهر الكلية هي 2 أيضاً. ولذلك فإنه لدينا إجابات متماثلة رقمياً (العلامة 2 لكلا الشخصين)، وهكذا فإن هذين الشخصين متماثلين من الناحية الاجتماعية، ولكن هل هما كذلك فعلياً؟

والجواب: ليس بالضرورة. يبدو أن زاهر يحب الذهاب إلى الحفلات والمقاهي ولكنه لا يستمتع بمقابلة الناس بشكل عام، بينما يستمتع عاصم في الحفلات وبمقابلة الناس ولكنه لا يحب الذهاب إلى المقاهي. وهكذا يبدو أن زاهر يستمتع في الأوضاع الاجتماعية التي تحوي الكحول (المقاهي والحفلات) بينما يحب عاصم أن يكون اجتماعياً بشكل عام ولكنه لا يتسامح مع دخان السجائر (كما في المقاهي). ولذلك فإن هذين الشخصين مختلفان جداً. إن الأسئلة كانت متأثرة بعوامل أخرى (كالموقف من الكحول أو الأجواء المليئة بالدخان). يجب أن يكون الاستبيان الجيد مصمماً بحيث يكون الأشخاص ذوي العلامات المتساوية متماثلين من ناحية البنية التي يتم قياسها، وهذا الأمر صعب التحقيق.

وهناك نقطة أخرى هي فرق العلامات. تخيل أننا أخذنا العلامات في استبيان الخوف من العناكب (SPQ). وتخيل أننا أخذنا ثلاثة مشتركين في هذا الاستبيان وقد حصلوا على العلامات التالية:

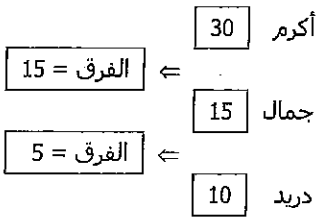

حصل أكرم على 30 علامة في هذا الاستبيان (أي أن يخاف كثيراً من العناكب) وحصل جمال على 15 علامة (ذو خوف متوسط من العناكب) وحصل عديد على 10 علامات (لا يخاف كثيراً من العناكب). هل يعني ذلك أن دريد وجمال أكثر تشابهاً في خوفهم من العناكب من جمال وأكرم؟ نظرياً يبدو ذلك صحيحاً لأن علامة جمال أكثر تشابهاً مع علامة دريد (الفرق =5) من علامة أكرم (الفرق =15). لنسأل سؤالاً آخر: هل أكرم يخاف من العناكب بمقدار 3 أضعاف خوف دريد؟ وبمقدار ضعفي خوف جمال؟ مرة أخرى، تدلنا علامته أن الإجابة هي نعم. ولكن لا يمكننا أن نضمن مسبقاً أن الفروق في العلامات ستكون قابلة للمقارنة مع بعضها البعض، ولذلك يجب أن يتم بناء الاستبيان بحيث تتناسب الفروق في العلامات مع الفروق بين الأشخاص.

الصلاحية

يجب أن تقيس العناصر في الاستبيان شيئاً ما، ويقيس الاستبيان الجيد ما هو مصمم لقياسه أصلاً (ويدعى ذلك بالصلاحية). وهكذا فالصلاحية تعني قياس ما تعتقد أنك تقيسه. ومن الصعب تقييم الصلاحية، إذ أنها تأخذ عدة أشكال:

1. **صلاحية المحتوى:** يجب أن تكون العناصر في الاستبيان مرتبطة بالبنية التي يتم قياسها. فعلى سبيل المثال، يكون الاستبيان المصمم لقياس التفكير التطفلي عديم الفائدة إذا احتوى عناصر متعلقة بالقدرة الإحصائية. وتدل صلاحية المحتوى على مدى تمثيل الأسئلة للبنية. ويتحقق ذلك عندما يتم اختيار العناصر أولاً: لا تضع عناصر مماثلة لعناصر أخرى بشكل واضح، وتأكد أن الأسئلة تغطي المجال الكامل للبنية.
2. **صلاحية المعيار:** هل يقيس الاستبيان فعلاً ما يدّعي أنه يقيسه. في عالم مثالي يمكن تقييم ذلك بربط العلامات على كل عنصر بمشاهدات العالم الحقيقي (كمقارنة العلامات على العناصر الاجتماعية مع عدد المرات التي يقوم فيها الشخص بنشاطات اجتماعية). ولكن هذا غير عملي، وهناك تقنيات بديلة مثل: (1) استخدام الاستبيان في أوضاع متنوعة لمعرفة مدى توقعه لها، (2) معرفة مدى ارتباطه بالمقاييس الأخرى المعروفة في البنية (فالأشخاص الاجتماعيون قد يسجلون علامات أعلى في مقياس الانبساط والاهتمام بما هو خارج الذات) و(3) هناك تقنيات إحصائية مثل دليل صلاحية العنصر (Item Validity Index IVI). إن اختبار صلاحية المعيار يتعدى إطار هذا الملحق، ولكن يجب الانتباه إليه والتحقق من استخدام عناصر حساسة.
3. **صلاحية العاملي:** وتتعلق هذه الصلاحية بما إذا كانت بنية العامل للاستبيان ذات معنى حدسي. ولذلك يتم تقييم صلاحية العاملي عبر التحليل العاملي. بعد الانتهاء من وضع المجموعة النهائية من عناصر الاستبيان يمكنك تنفيذ تحليل عاملي على البيانات (انظر الفصل 11). يقوم التحليل العاملي بأخذ الأسئلة المرتبطة وإعادة ترميزها في متحولات قاعدية غير مرتبطة تدعى العوامل (وكمثال يمكن إعادة ترميز المتحولات: الطول، قياس الصدر، عرض الأكتاف، الوزن في متحول قاعدي يدعى بنية الجسم). لنأخذ مثالاً آخر: لتقييم النجاح في مادة دراسية يمكن قياس الانتباه في المحاضرات، عدد الملاحظات المأخوذة في المحاضرات، عدد الأسئلة المطروحة خلال المحاضرات، ويمكن ربط جميع هذه المتحولات بسمة قاعدية يمكن أن تكون "الاندفاع للنجاح". وقد تعلمنا سابقاً كيفية تنفيذ التحليل العاملي في برنامج SPSS، وعرفنا كيف أن هذا التحليل يعطي جدولاً بالعناصر وارتباطها أو تحميلها على كل عامل. ويتكون العامل من العناصر المرتبطة بشدة معه. ويمكن معرفة صلاحية العاملي من خلال معرفة فيما إذا كانت العناصر المرتبطة مع العوامل تعطي معنى حدسياً أم لا. وبشكل أساسي إذا كانت العناصر مجمعة في مجموعات ذات معنى فإنه يمكنك الاستدلال على صلاحية العاملي.

إن الصلاحية شرط ضروري ولكنها غير كافية للاستبيان.

الوثوقية

لا يكفي أن يكون الاستبيان صالحاً بل يجب أن يكون موثوقاً أيضاً. والوثوقية هي قدرة الاستبيان على إنتاج نفس النتائج تحت نفس الشروط أو في نفس الظروف. ولكي يكون الاستبيان موثوقاً يجب أن يكون صالحاً أولاً. ومن الواضح أن أسهل طريقة لتقييم الوثوقية هي اختبار نفس المجموعة

من الأشخاص مرتين، فإذا كان الاستبيان موثوقاً فإننا نتوقع أن يحصل كل شخص على نفس العلامة في المرتين. لذلك فإن العلامات في الاستبيان يجب أن تكون مرتبطة بشكل تام (أو قريب من التام). على كل حال، إذا قمنا باختبار نفس الأشخاص مرتين فإننا نتوقع آثار الممارسة والآثار المربكة (قد يتذكر الأشخاص إجاباتهم من المرة الأولى). كما أن هذه الطريقة ليست مفيدة جداً في الاستبيانات التي تهدف لقياس شيء ما نتوقع أن يتغير مع مرور الزمن (كالاكتئاب أو القلق). يمكن التغلب على هذه المشاكل باستخدام طريقة الشكل البديل التي يتم فيها ابتكار استبيانين ومقارنتهما. ولكن هذه الطريقة مكلفة من ناحية الوقت كوسيلة لضمان الوثوقية، ولحسن الحظ هناك طرق إحصائية أسهل.

إن أبسط تقنية إحصائية هي طريقة النصف المشطور. ويتم في هذه الطريقة تقسيم عناصر الاستبيان عشوائياً إلى مجموعتين. يتم بعد ذلك حساب علامة لكل موضوع اعتماداً على نصف المقياس. إذا كان المقياس موثوقاً جداً فإننا نتوقع أن تكون علامة الشخص ذاتها في كل من نصفي المقياس، وبذلك نتأكد من أن النصفين مرتبطان بشكل مثالي. والارتباط بين النصفين هو الإحصائية التي يتم حسابها في طريقة النصف المشطور، وتدل القيم الكبيرة للارتباط على الوثوقية. المشكلة مع هذه الطريقة هي وجود عدد من الطرق التي يمكن استخدامها لتقسيم مجموعة من البيانات إلى نصفين، ولذلك فإن النتائج يمكن أن تكون ناتجة عن طريقة تقسيم البيانات. وللتغلب على هذه المشكلة يقترح Cronbach تقسيم البيانات إلى نصفين بكل الطرق الممكنة وحساب معامل الارتباط لكل عملية تقسيم. يسمى متوسط هذه القيم معيار Cronbach's alpha وهو المقياس الأكثر انتشاراً لوثوقية المقياس. وتعتبر القيمة 0.8 مقبولة لمعيارCronbach's alpha ، أما القيم الأدنى فتدل على مقياس غير موثوق.

كيف تصمم استبياناً؟

الخطوة الأولى: اختيار بنية ما

عليك أن تقرر أولاً ما الذي تريد قياسه. ثم تكوين فكرة أساسية عن البنية التي تريد اختبارها وكيفية ارتباطها بالعوامل الهامة الأخرى. فعلى سبيل المثال إذا نظرت إلى التقمص العاطفي (Empathy) فإنك تأخذ أحد أهم المكونات في طريقة Carl Rogers للعلاج، ولذلك فإن وضع سمة "الشخصية" قد يكون مفيداً إذا أردت أن تصبح طبيباً معالجاً على طريقة Rogers. وينتج عن ذلك أن وضع استبيان يتضمن قياس هذه السمة قد يكون مفيداً في عمليات الاختيار في مناهج التدريب على طريقة Rogers. وعليك إذاً وضع نوع ما من السياق لتوضيح أهمية هذه البنية، وستشكل هذه المعلومات أسس المدخل.

الخطوة الثانية: اعتماد مقياس للإجابة

يعتبر اختيار طريقة الإجابة على أسئلة الاستبيان مسألة أساسية، ويمكنك اختيار إحدى الطرق التالية:

- **مقياس نعم/لا أو نعم/لا/لا أعلم:** يجبر هذا المقياس الأشخاص على إعطاء الإجابة الأولى (نعم) أو الإجابة الثانية (لا) حتى لو كانوا يشعرون بأن إجابتهم ليست هي الأولى (نعم) أو الثانية (لا). تخيل أنك تريد قياس الأفكار التطفلية، ولديك عنصر مثل "أفكر بموضوع قتل الأطفال". من المحتمل أن تكون إجابات جميع الأشخاص هي "لا" (حتى لو كانت لديهم مثل تلك الأفكار) وذلك لأنه من الصعب قبول هذا الأمر. ولذلك فإن ما يقوم به هذا العنصر هو طرح قيمة من علامة كل شخص، وبالتالي لا يدلنا على شيء مفيد، إنه مجرد تشويش في البيانات. ويمكن أن يحدث هذا السيناريو عند استخدام مقياس يحوي الإجابة "لا أعلم" (لأن الأشخاص لا يستطيعون اتخاذ قرار فيميلون للإجابة المحايدة). ولهذا يكون من المفيد أحياناً وضع إجابة محايدة لمساعدتك على تحديد الأشياء التي لا يشعر الناس بأية مشاعر نحوها. وبدون هذه النقطة المحايدة فإنك تجبر الأشخاص على اختيار جهة معينة أو جهة معاكسة وهذا يشبه دحرجة قطعة نقود على حافتها وانتظار معرفة جهة سقوطها. فعندما تدفع 50% من الأشخاص على اختيار جهة معينة و 50% على اختيار الجهة المقابلة فإنك لا تضيف سوى التشويش إلى البيانات.
- **مقياس Likert:** وهو مقياس الإجابة القياسي "موافق- غير موافق" للفئات التراتبية. ويتوفر بعدة أشكال:
  - * **3 نقاط:** وهي موافق- لا موافق ولا غير موافق- غير موافق.
  - * **5 نقاط:** وهي موافق- نقطة الوسط- لا موافق ولا غير موافق- نقطة الوسط- غير موافق.
  - * **7 نقاط:** وهي موافق- نقطتان- لا موافق ولا غير موافق- نقطتان- غير موافق.

يجب أن تشجع الأسئلة الأشخاص على استخدام جميع نقاط المقياس. ولذلك فإن التوزيع الإحصائي للإجابات على عنصر واحد يجب أن يكون توزيعاً طبيعياً مع قيمة متوسطة تقع في منتصف المقياس (فمن أجل مقياس 5 نقاط فإن المتوسط لسؤال ما يجب أن يكون 3). كما أن مجال العلامات يجب أن يغطي جميع الإجابات الممكنة.

الخطوة الثالثة: توليد العناصر

بعد إيجاد البنية التي تريد قياسها واعتماد نوع المقياس للإجابات، تأتي المهمة التالية وهي توليد العناصر. ينبغي أن يكون العدد الأعظمي لعناصر الاستبيان 30 عنصراً (وأن لا يقل عن 20 كحد أدنى). إن أفضل طريقة لتوليد العناصر هي اعتماد أسلوب الأفكار البارعة السريعة من قبل عينة صغيرة من الأشخاص، ويشمل ذلك الطلب من الأشخاص سرد الأوجه المتعددة الممكنة للبنية. فعلى سبيل المثال، إذا أردت وضع استبيان عن قلق الامتحان فيمكنك أن تطلب من عدد من الطلاب (20 أو أكثر) من الفروع المختلفة (العلمية والأدبية) ومن مختلف السنوات الدراسية وبعض

الأصدقاء أن يضعوا لائحة تبين الأشياء المتعلقة بالامتحانات التي تثير القلق لديهم. ويكون من الأفضل لو استطعت تضمين أشخاص على أطراف البنية في هذه العينة (عدد من الأشخاص الذين يصابون بقلق كبير من الامتحان وعدد آخر ممن يحافظون على هدوئهم ولا يقلقون من الامتحانات). يسمح هذا بالحصول على عناصر تغطي الطيف الكامل للبنية التي تريد قياسها.

ستحصل بعد ذلك على مجموعة كبيرة من العناصر تسمح لك باستيحاء الأسئلة. أعد صياغة اقتراحات العينة بشكل يلائم مقياس الإجابات المعتمد ثم احذف الأسئلة المتماثلة. يجب أن تبدأ بحوالي 50 إلى 60 سؤالاً بحيث يمكنك تقليصها إلى 30 بعد حذف الأسئلة المتشابهة.

الأمور الواجب اعتبارها:

1. صياغة الأسئلة: يمكن أن تؤثر طريقة صياغة الأسئلة على الإجابات التي يعطيها الأشخاص.
2. انحياز الإجابة: وهو ميل الأشخاص لإعطاء نفس الإجابة على كل الأسئلة. حاول صياغة بعض العناصر بطريقة عكسية لتجنب انحياز الإجابة وتذكر أن تعطي هذه العناصر علامات معاكسة عند إدخال البيانات في برنامج SPSS.

الخطوة الرابعة: جمع البيانات

بعد كتابة جميع الأسئلة أعد ترتيبها بشكل عشوائي لتحصل على الاستبيان. لاختبار الاستبيان الذي قمت بإعداده، اطبع نسخاً منه ووزعه على أكبر عدد ممكن من الأشخاص (الفائدة من جعل الاستبيان قصيراً هي تقليل الوقت اللازم للإجابة عليه وإعادته). يجب أن يقوم 50-100 شخص على الأقل بالإجابة على هذا الاستبيان، ولكن كلما كان العدد أكبر كان التحليل أفضل.

الخطوة الخامسة: التحليل

أدخل البيانات في برنامج SPSS بعد تمثيل كل سؤال بعمود واحد في محرر البيانات. وتحويل مقياس الإجابات إلى أرقام (فمن أجل مقياس 5 نقاط: 1=موافق تماماً، 2=موافق، 3=لا موافق ولا غير موافق، 4=غير موافق، 5=غير موافق أبداً). وتذكر أن العناصر المصاغة بطريقة عكسية يجب أن تحصل على طريقة معاكسة في منح العلامات أيضاً.

وما نحاول عمله في هذا التحليل هو أولاً حذف العناصر غير المفيدة في الاستبيان. لذلك سنقوم بتخفيض عدد العناصر إلى أقل من 30 وذلك قبل تنفيذ التحليل العاملي. ويمكننا إنجاز ذلك بالنظر إلى الإحصائيات الوصفية والارتباطات بين الأسئلة.

الإحصائيات الوصفية

إن أول ما يجب أن ننظر إليه هو التوزيع الإحصائي لعلامات العنصر، وهذا يسمح لنا بالتخلص من العناصر الفائضة مباشرة.

لذلك وعند تنفيذ استبيان ما فإن أول ما ننظر إليه هو الإحصائيات الوصفية لعناصر الاستبيان. ويتم ذلك بسهولة في برنامج SPSS، حيث نبحث عن:

1. **المجال:** أي عنصر ذي مجال محدود (لم يتم استخدام جميع نقاط المقياس).
2. **الميلان:** ذكرنا سابقاً أن كل سؤال يجب أن يُظهر للعيان مجموعة من الإجابات الموزعة بشكل طبيعي عبر المواضيع (يجب أن يظهر متوسط العنصر في مركز المقياس وأن لا يكون هناك أي ميلان). ولفحص العناصر التي تعطي بيانات ذات ميلان فإننا نبحث عن قيم الميلان (Skewness) والخطأ المعياري للميلان (SE Skew) في الخرج الذي يعطيه برنامج SPSS. يمكننا تقسيم الميلان على الخطأ المعياري الخاص به لتشكيل العلامات المعيارية z (انظر الفصل 3). إذا كانت القيمة المطلقة للعلامة المعيارية z أكبر من 1.96 فإن الميلان كبير. احذف العناصر ذات الميلان الكبير.
3. **الانحراف المعياري:** إضافة إلى المجال وميلان التوزيع فإن العناصر ذات الانحراف المعياري الكبير أو الصغير قد تسبب المشاكل لذلك علينا الانتباه من القيم الكبيرة والصغيرة للانحراف المعياري.

إنها الخطوات الأولى فقط. إذا تم خرق أي من هذه القواعد فإن العناصر تصبح غير قابلة للمقارنة (من ناحية التحليل العاملي) مما يجعل الاستبيان عديم الفائدة.

الارتباطات

يجب أن تكون جميع العناصر مترابطة فيما بينها لمستوى معين إذا كانت تقيس بعض السمات لشيء واحد. إذا كانت بعض العناصر غير مرتبطة عند مستوى 0.05 أو 0.01 من الدلالة فإن عليك استثناء هذه العناصر (انظر الفصل 15 المتعلق بالتحليل العاملي).

التحليل العاملي

عند حذف أي عناصر مسببة لمشاكل متعلقة بالتوزيع أو أنها غير مرتبطة ببعضها البعض فإن عليك تنفيذ التحليل العاملي على العناصر الباقية ومحاولة تفسير بنية العوامل الناتجة. ويمكنك العودة للفصل 15 الذي يحوي تفاصيل عملية التحليل العاملي.

وما عليك عمله هو فحص بنية العوامل واتخاذ القرارات حول:

1. العوامل التي تريد الإبقاء عليها.
2. العناصر ذات التحميل على تلك العوامل.
3. ما تمثله هذه العوامل.
4. إذا كانت بعض العناصر بدون تحميل مرتفع على أي من العوامل، فإن عليك حذف هذه العناصر من الإصدارات القادمة من الاستبيان (يجب التذكير بأن هذه العناصر غير مفيدة وبأنك لا تملك الوقت حالياً لمراجعة الاستبيان وإعادة اختباره).

الخطوة السادسة: تقييم الاستبيان

بعد إلقاء نظرة على بنية العوامل عليك التحقق من وثوقية العناصر والاستبيان بشكل إجمالي. عليك تنفيذ تحليل الوثوقية للاستبيان. وهناك معياران يجب النظر إليهما: (1) دليل وثوقية العنصر (Item Reliability Index IRI) وهو الارتباط بين العلامة للعنصر والعلامة للاختبار ككل مضروبة بالانحراف المعياري لذلك العنصر (وفي برنامج SPSS يدعى الارتباط المصحح للعنصر بالكل). يقوم برنامج SPSS بحساب الارتباط المصحح للعنصر بالكل، ونريد أن تكون هذه القيم ذات دلالة لجميع العناصر. ومع أننا لا نحصل على قيم الدلالة فإنه ينبغي البحث عن قيم الارتباط التي تكون أكبر من 0.3 تقريباً (وتعتمد القيمة الدقيقة على حجم العينة، ولكن يمكن استخدام القيمة 0.3 كنقطة قطع). ويجب استثناء العناصر ذات قيم الارتباط الأقل من 0.3 من الاستبيان. (2) قيمة Cronbach's alpha والتي يجب أن تكون أكبر من أو تساوي 0.8 وحذف العناصر التي لا يؤثر حذفها على تلك القيمة (انظر الملحق الخاص بتحليل الوثوقية).

النهاية؟

يجب أن تختم دراستك بوصف بنية العوامل ووثوقية المقياس، وذكر العناصر التي ستقوم بإهمالها من الاستبيان القادم. في عالم مثالي، نقوم بعد ذلك بتوليد عناصر جديدة وإضافتها إلى العناصر المتبقية وبدء العملية من جديد.

تحدّث أيضاً عن تطبيق هذا الاستبيان ومدى فائدته ومجال تطبيقه وهل يدعم نظرية موجودة حول البنية المقاسة.

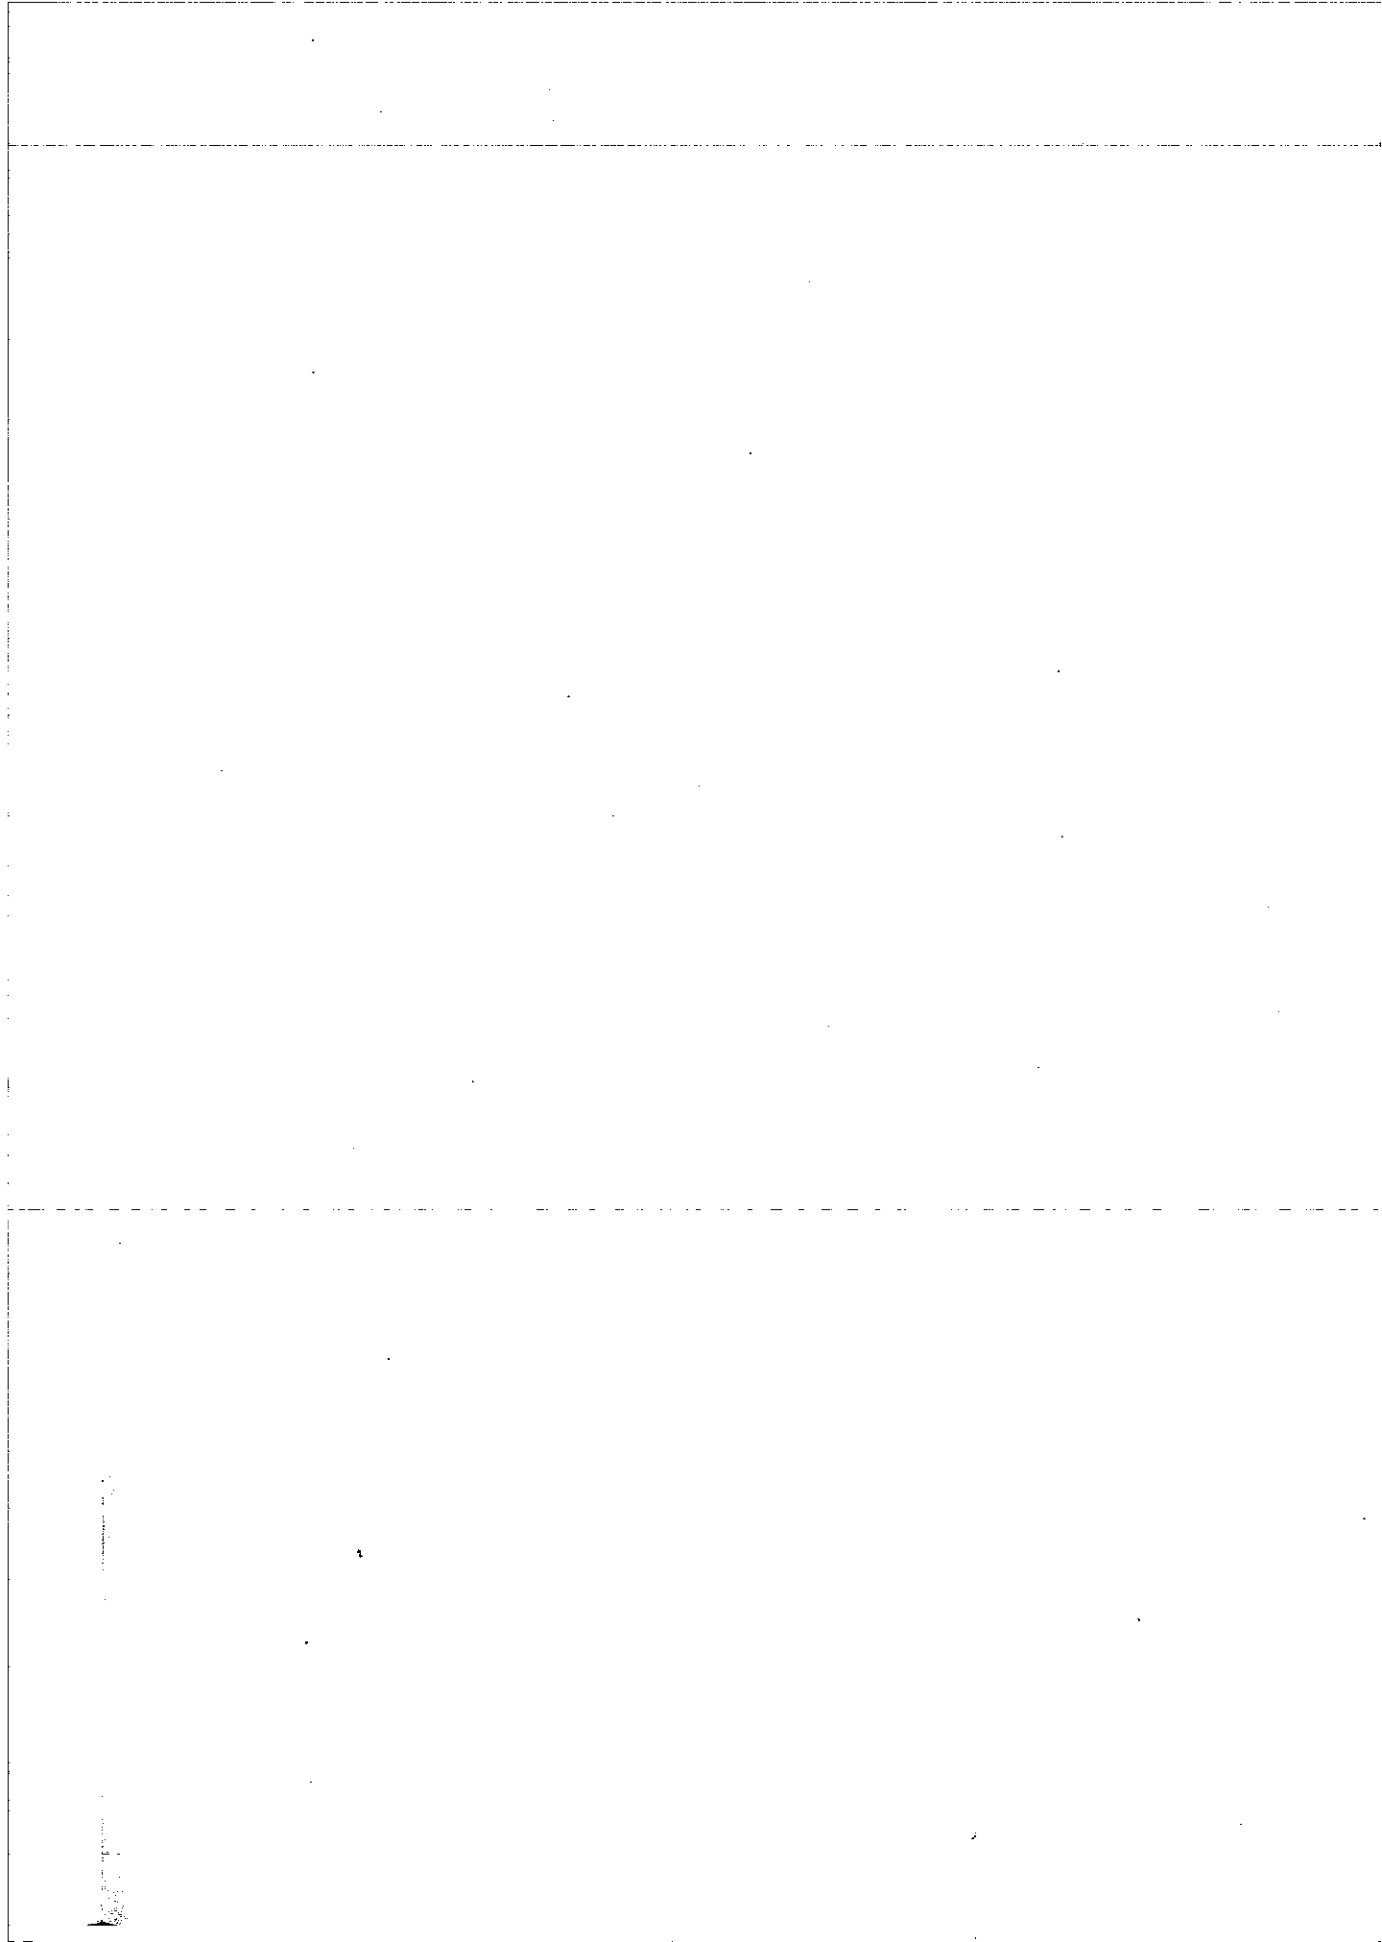

جدول المحتويات

1 كل ما تود معرفته عن الإحصاء 7

1.1 بماذا يخبرنا هذا الفصل 7

2.1 بناء النماذج الإحصائية 7

3.1 المجتمعات والعينات 9

4.1 النماذج الإحصائية البسيطة 10

1.4.1 المتوسط، مجموع المربعات، التباين والانحراف المعياري 10

5.1 التوزيعات التكرارية 14

1.5.1 خصائص التوزيع التكراري 15

2.5.1 الانحراف المعياري وشكل التوزيع 16

3.5.1 ما هو التوزيع الطبيعي المعياري؟ 17

6.1 هل العينة ممثلة للمجتمع؟ 20

1.6.1 الخطأ المعياري 20

2.6.1 مجالات الثقة 23

7.1 النماذج الخطية 26

8.1 كيف يمكننا القول أن النموذج يمثل العالم الحقيقي؟ 28

1.8.1 إحصائيات الاختبار 31

2.8.1 الاختبار وحيد الطرف والاختبار ثنائي الطرف 34

3.8.1 الأخطاء من النوع الأول ومن النوع الثاني 36

4.8.1 حجم الأثر 37

5.8.1 القدرة الإحصائية 38

9.1 بعض النصائح الختامية 40

10.1 ما الذي اكتشفناه عن الإحصاء؟ 40

11.1 المصطلحات الأساسية التي اكتشفناها 40

12.1 امتحان مختصر في الإحصاء 42

2 بيئة البرنامج SPSS 43

1.2 بماذا يخبرنا هذا الفصل 43

2.2 رقم نسخة البرنامج SPSS 43

3.2 البداية 43

4.2 محرر البيانات 44

1.4.2 إدخال البيانات في محرر البيانات 51
2.4.2 إنشاء متحول 52
3.4.2 صفحة عرض المتحولات Variable View 53
4.4.2 إنشاء متحولات الترميز 56
5.4.2 أنواع المتحولات 58
6.4.2 القيم المفقودة 59
7.4.2 تغيير التنسيق للأعمدة 61
8.4.2 اختبار سريع 61
5.2 عارض الخرج 61
6.2 نافذة القواعد 65
7.2 حفظ الملفات 66
8.2 استعادة ملف 67
9.2 ما الذي اكتشفناه عن الإحصاء 68
10.2 المصطلحات الأساسية التي اكتشفناها 69
11.2 مهمة ينبغي إنجازها 69

3 استكشاف البيانات 71

1.3 بماذا يخبرنا هذا الفصل 71
2.3 البيانات البارامترية 71
1.2.3 فرضيات البيانات البارامترية 71
3.3 رسم المخططات وتدقيق البيانات 73
1.3.3 الخطوة 1: اكتشاف الأخطاء البديهية باستخدام المخططات التكرارية 73
2.3.3 الخطوة 2: الإحصائيات الوصفية ورسم الصندوق 78
3.3.3 الخطوة 3: تصحيح المشاكل في البيانات 86
4.3.3 الخطوة 4: تحويل البيانات باستخدام SPSS 89
4.3 استكشاف مجموعات البيانات 95
1.4.3 تشغيل التحليل من أجل جميع البيانات 95
2.4.3 خرج SPSS من أجل جميع البيانات 97
3.4.3 تشغيل التحليل من أجل مجموعات مختلفة 98
4.4.3 الخرج من أجل مجموعات مختلفة 100
5.3 اختبار فيما إذا كان التوزيع طبيعياً 101
1.5.3 تنفيذ اختبار Kolmogorov-Smirnov في SPSS 102
2.5.3 الخرج من إجرائية explore 103
6.3 اختبار تجانس التباين 105
7.3 رسم قيم المتوسطات 110
8.3 ما الذي اكتشفناه عن الإحصاء؟ 114

9.3 المصطلحات الأساسية التي اكتشفناها 115
10.3 مهمات يجب إنجازها 115

4 الارتباط 117

1.4 بماذا يخبرنا هذا الفصل 117
2.4 كيف نقيس العلاقات 117
1.2.4 جولة في عالم التباين المشترك 117
2.2.4 التوحيد القياسي ومعامل الارتباط 120
3.4 إدخال البيانات لتحليل الارتباط في SPSS 122
4.4 الرسم البياني للعلاقات: المخطط المبعثر 123
1.4.4 المخطط المبعثر البسيط 123
2.4.4 المخطط المبعثر ثلاثي الأبعاد 127
3.4.4 المخطط المبعثر المنضد 128
4.4.4 مصفوفة المخططات المبعثرة 129
5.4 الارتباط ثنائي المتغيرات 132
1.5.4 معامل Pearson للارتباط 135
2.5.4 تحذير حول التفسير: السببية 138
3.5.4 استخدام R^2 للتفسير 139
4.5.4 معامل Spearman للارتباط 139
5.5.4 ارتباط Kendall (اللابارامتري) 141
6.5.4 الارتباط ثنائي التسلسل و ثنائي التسلسل النقطي 142
6.4 الارتباط الجزئي وشبه الجزئي 144
1.6.4 النظرية خلف الارتباط الجزئي 144
2.6.4 الارتباط الجزئي باستخدام SPSS 147
3.6.4 الارتباط شبه الجزئي 149
7.4 كيفية تقديم معاملات الارتباط 150
8.4 ما الذي اكتشفناه عن الإحصاء 151
9.4 المصطلحات الأساسية التي اكتشفناها 151
10.4 مهمات يجب إنجازها 152

5 التراجع 153

1.5 بماذا يخبرنا هذا الفصل 153
2.5 مدخل إلى التراجع 153
1.2.5 بعض المعلومات الهامة عن الخطوط المستقيمة 154
2.2.5 طريقة المربعات الصغرى 156

3.2.5 تقييم جودة التوافق: مجموع المربعات و R و R^2 157
4.2.5 تقييم المتحولات التنبؤية المنفصلة 160
3.5 إنجاز التراجع البسيط في برنامج SPSS 161
4.5 تفسير التراجع البسيط 163
1.4.5 التوافق الكلي للنموذج 163
2.4.5 بارامترات النموذج 165
3.4.5 استخدام النموذج 166
5.5 التراجع المتعدد: الأساسيات 166
1.5.5 مثال عن نموذج التراجع المتعدد 167
2.5.5 مجاميع المربعات و R و R^2 168
3.5.5 طرق التراجع 169
1.3.5.5 الإدخال الهرمي 169
2.3.5.5 الإدخال القسري 170
3.3.5.5 الطرق الخطوية 170
4.3.5.5 اختيار طريقة 171
6.5 ما مدى دقة نموذج التراجع؟ 171
1.6.5 تقييم نموذج التراجع: التشخيص 172
1.1.6.5 النقاط المنعزلة والبواقي 172
2.1.6.5 الحالات المؤثرة 174
3.1.5.6 تعليق أخير حول إحصائيات التشخيص 179
2.6.5 تقييم نموذج التراجع: التعميم 179
1.2.6.5 التحقق من الفرضيات 179
2.2.6.5 التحقق المتصالب من النموذج 182
3.2.6.5 حجم العينة في التراجع 182
4.2.6.5 الارتباط الخطي المتعدد 184
7.5 كيف ننفذ التراجع المتعدد في برنامج SPSS 186
1.7.5 الخيارات الأساسية 186
2.7.5 الإحصائيات 189
3.7.5 المخططات البيانية للتراجع 191
4.7.5 حفظ إحصائيات تشخيص التراجع 193
5.7.5 المزيد من الخيارات 194
8.5 تفسير التراجع المتعدد 196
1.8.5 الإحصائيات الوصفية 196
2.8.5 ملخص النموذج 198
3.8.5 بارامترات النموذج 202
4.8.5 المتحولات المستثناة 206

5.8.5 تقييم فرضية عدم الارتباط الخطي المتعدد 207
6.8.5 أدوات تشخيص الحالة 210
7.8.5 التحقق من الفرضيات 213
9.5 كيفية تقديم التراجع المتعدد 218
10.5 المتحولات التنبؤية الفئوية والتراجع المتعدد 219
1.10.5 الترميز المزيف 219
2.10.5 خرج البرنامج SPSS للمتحولات المزيفة 223
11.5 ما الذي اكتشفناه عن الإحصاء؟ 226
12.5 المصطلحات الأساسية التي اكتشفناها 227
13.5 مهمات يجب إنجازها 228

6 التراجع المنطقي 231

1.6 بماذا يخبرنا هذا الفصل 231
2.6 لمحة نظرية عن التراجع المنطقي 231
3.6 ما هي مبادئ التراجع المنطقي؟ 232
1.3.6 تقييم النموذج: إحصائية لوغاريتم الاحتمال 234
2.3.6 تقييم النموذج: R و R^2 235
3.3.6 تقييم مساهمة المتحولات التنبؤية: إحصائية Wald 236
4.3.6 Exp(B) 237
5.3.6 طرق التراجع المنطقي 238
1.5.3.6 طريقة الإدخال القسري 238
2.5.3.6 الطرق الخطوية 239
3.5.3.6 كيف نختار الطريقة؟ 239
4.6 تنفيذ التحليل: مثال بحثي 240
1.4.6 التحليل الأساسي 241
2.4.6 طريقة التراجع 242
3.4.6 المتحولات التنبؤية الفئوية 242
4.4.6 الحصول على البواقي 244
5.4.6 المزيد من الخيارات 245
5.6 تفسير التراجع المنطقي 246
1.5.6 النموذج الأولي 246
2.5.6 الخطوة الأولى: فهم الاعتقاد الخاطئ 249
3.5.6 عرض الاحتمالات المتوقعة 257
4.5.6 تفسير البواقي 258
5.5.6 حساب حجم الأثر 260
6.6 كيفية تقديم التراجع المنطقي 260

7.6 مثال آخر 262
1.76 تنفيذ التحليل: التراجع ذو الإدخال الكتلي 263
2.76 تفسير الخرج 264
8.6 الاختبار من أجل الارتباط الخطي المتعدد 271
9.6 التعامل مع الأخطاء الممكنة 274
1.9.6 معلومات ناقصة عن المتحولات التنبؤية 274
2.9.6 الانفصال التام 275
10.6 ما الذي اكتشفناه عن الإحصاء؟ 277
11.6 المصطلحات الأساسية التي اكتشفناها 278
12.6 مهمات يجب تنفيذها 278

7 مقارنة متوسطين 281

1.7 بماذا يخبرنا هذا الفصل 281
2.7 مراجعة البحث التجريبي 282
1.2.7 طريقتان لجمع البيانات 282
2.2.7 نوعان من التغاير 283
3.2.7 العشوائية 284
3.7 إدخال البيانات وإظهار المتوسطات على مخطط أعمدة الخطأ 286
1.3.7 مخطط عمود الخطأ للتصميم بين المجموعات 288
2.3.7 مخطط عمود الخطأ لتصميم القياسات المكررة 291
1.2.3.7 الخطوة الأولى: حساب المتوسط لكل مشترك 293
2.2.3.7 الخطوة الثانية: حساب المتوسط الكلي 294
3.2.3.7 الخطوة الثالثة: حساب عامل التعديل 295
4.2.3.7 الخطوة الرابعة: إنشاء القيم المعدّلة لكل متحول 296
5.2.3.7 رسم مخطط عمود الخطأ 297
4.7 اختبار الفروق بين المتوسطات: الاختبار t 298
1.4.7 المنطق في الاختبار t 299
2.4.7 فرضيات الاختبار t 300
5.7 اختبار t التابع 300
1.5.7 توزيعات أخذ العينات والخطأ المعياري 301
2.5.7 شرح معادلة الاختبار t التابع 302
3.5.7 اختبار t التابع باستخدام SPSS 303
4.5.7 الخرج لاختبار t التابع 304
5.5.7 حساب حجم الأثر 306
6.5.7 تقديم الاختبار t التابع 307

6.7 اختبار t المستقل 308
1.6.7 شرح معادلة الاختبار t المستقل 308
2.6.7 الاختبار t المستقل باستخدام SPSS 311
3.6.7 الخرج لاختبار t المستقل 312
4.6.7 حساب حجم الأثر 315
5.6.7 تقديم اختبار t المستقل 315
7.7 التصميم بين المجموعات أم القياسات المكررة؟ 316
8.7 الاختبار t كنموذج خطي عام 316
9.7 ماذا لو كانت البيانات غير موزعة طبيعياً؟ 318
10.7 ما الذي اكتشفناه عن الإحصاء؟ 319
11.7 المصطلحات الأساسية التي اكتشفناها 319
12.7 مهمات يجب تنفيذها 320

8 مقارنة عدة متوسطات ANOVA (GLM1) 321

1.8 ماذا يخبرنا هذا الفصل 321
2.8 الأسس النظرية لتحليل التباين ANOVA 321
1.2.8 معدلات الخطأ المتضخم 321
2.2.8 ANOVA كتراجع 323
3.2.8 المنطق وراء النسبة F 327
4.2.8 المجموع الكلي للمربعات SS_T 330
5.2.8 مجموع المربعات للنموذج SS_M 331
6.2.8 مجموع مربعات البواقي SS_R 332
7.2.8 متوسط المربعات 333
8.2.8 النسبة F 334
9.2.8 فرضيات ANOVA 335
10.2.8 أنواع المقارنات المنظمة 336
1.10.2.8 اختيار المقارنة التي نريد تنفيذها 336
2.10.2.8 تحديد المقارنة باستخدام التثقيل 341
3.10.2.8 المقارنات غير المتعامدة 346
4.10.2.8 لمقارنات القياسية 347
5.10.2.8 المقارنات كثيرة الحدود: تحليل المنحى 349
11.2.8 الإجرائيات Post hoc 350
1.11.2.8 الإجرائيات Post hoc ومعدلات الخطأ من النوع الأول (α) ومن النوع الثاني 351
2.11.2.8 الإجرائيات Post hoc وخرق فرضيات الاختبار 352

3.11.2.8 ملخص الإجرائيات Post hoc 352
3.8 تنفيذ ANOVA وحيد الاتجاه في برنامج SPSS 353
1.3.8 المقارنات المنظمة باستخدام SPSS 354
2.3.8 الاختبارات post hoc في برنامج SPSS 357
3.3.8 الخيارات 358
4.8 الخرج من ANOVA وحيد الاتجاه 360
1.4.8 الخرج للتحليل الأساسي 360
2.4.8 الخرج للمقارنات المنظمة 364
3.4.8 الخرج لاختبارات post hoc 365
5.8 حساب حجم الأثر 369
6.8 تقديم نتائج ANOVA وحيد الاتجاه المستقل 370
7.8 خرق الفرضيات في ANOVA وحيد الاتجاه المستقل 371
8.8 ما الذي اكتشفناه عن الإحصاء؟ 371
9.8 المصطلحات الأساسية التي اكتشفناها 372
10.8 مهمات يجب تنفيذها 373

9 تحليل التباين المشترك ANCOVA (GLM2) 375

1.9 ماذا يخبرنا هذا الفصل 375
2.9 ما هو تحليل التباين المشترك ANCOVA؟ 375
3.9 تنفيذ ANCOVA في برنامج SPSS 376
1.3.9 إدخال البيانات 378
2.3.9 التحليل الأساسي 378
3.3.9 المقارنات والخيارات الأخرى 379
4.9 تفسير الخرج من ANCOVA 382
1.9.4 التحليل الأساسي 382
2.4.9 المقارنات 385
3.4.9 تفسير المتغير المشترك 387
5.9 تنفيذ ANCOVA كتراجع متعدد 387
6.9 فرضيات إضافية في ANCOVA 392
1.6.9 تجانس انحدارات التراجع 392
2.6.9 اختبار تجانس انحدارات التراجع في برنامج SPSS 393
7.9 حساب حجم الأثر 396
8.9 تقديم النتائج 396
9.9 ما الذي اكتشفناه عن الإحصاء 397
10.9 المصطلحات الأساسية التي اكتشفناها 397
11.9 مهمات يجب تنفيذها 398

10 تحليل التباين العاملي (GLM3) 399

1.10 ماذا يخبرنا هذا الفصل 399
2.10 نظرية ANOVA العاملي (بين المجموعات) 399
1.2.10 التصاميم العاملية 399
2.2.10 مثال بمتحولين مستقلين اثنين 400
3.2.10 المجموع الكلي للمربعات (SS_T) 401
4.2.10 مجموع المربعات للنموذج (SS_M) 402
1.4.2.10 الأثر الرئيسي للجنس (SS_A) 403
2.4.2.10 الأثر الرئيسي للكحول (SS_B) 404
3.4.2.10 أثر التفاعل ($SS_{A\times B}$) 405
5.2.10 مجموع المربعات للبواقي (SS_R) 405
6.2.10 النسب F 406
3.10 تنفيذ ANOVA العاملي باستخدام برنامج SPSS 407
1.3.10 إدخال البيانات والوصول لمربع الحوار الرئيسي 407
2.3.10 النماذج المخصصة 408
3.3.10 رسم التفاعلات 409
4.3.10 المقارنات 410
5.3.10 اختبارات post hoc 411
6.3.10 الخيارات 412
4.10 الخرج من ANOVA العاملي 412
1.4.10 الخرج من التحليل التمهيدي 412
2.4.10 اختبار Levene 413
3.4.10 جدول ANOVA الأساسي 414
4.4.10 المقارنات 417
5.4.10 تحليل post hoc 419
5.10 تفسير مخططات التفاعل 422
6.10 حساب حجم الأثر 426
7.10 تقديم نتائج ANOVA ثنائي الاتجاه 428
8.10 ANOVA العاملي كتراجع 429
9.10 ما الذي اكتشفناه عن الإحصاء 433
10.10 المصطلحات الأساسية التي اكتشفناها 434
11.10 مهمات يجب تنفيذها 434

11 تصاميم القياسات المكررة (GLM4) 435

1.11 ماذا يخبرنا هذا الفصل؟ 435
2.11 مدخل إلى تصاميم القياسات المكررة 435
1.2.11 فرضية الكروية 436
2.2.11 كيف نقيس الكروية؟ 437
3.2.11 تقييم حدة الانحراف عن الكروية 437
4.2.11 ما هو الأثر الناتج عن خرق فرضية الكروية؟ 438
5.2.11 ماذا نفعل عند خرق فرضية الكروية؟ 438
3.11 نظرية ANOVA وحيد الاتجاه للقياسات المكررة 439
1.3.11 المجموع الكلي للمربعات (SS_T) 441
2.3.11 مجموع المربعات ضمن المشترك (SS_W) 442
3.3.11 مجموع المربعات للنموذج (SS_M) 443
4.3.11 مجموع المربعات للبواقي (SS_R) 444
5.3.11 متوسط المربعات 444
6.3.11 النسبة F 445
4.11 استخدام برنامج SPSS لتنفيذ ANOVA وحيد الاتجاه للقياسات المكررة 445
1.4.11 التحليل الأساسي 445
2.4.11 تعريف التباينات للقياسات المكررة 447
3.4.11 الاختبارات post hoc والخيارات الإضافية 448
5.11 الخرج من ANOVA وحيد الاتجاه للقياسات المكررة 451
1.5.11 الإحصائيات الوصفية 451
2.5.11 تقييم الكروية وتصحيحها 451
3.5.11 ANOVA الأساسي 452
4.5.11 المقارنات 455
5.5.11 اختبارات post hoc 457
6.11 حجم الأثر لـ ANOVA للقياسات المكررة 459
7.11 تقديم ANOVA وحيد الاتجاه للقياسات المكررة 460
8.11 القياسات المكررة مع عدة متحولات مستقلة 461
1.8.11 التحليل الأساسي 462
2.8.11 المقارنات 465
3.8.11 رسم التفاعلات 468
4.8.11 الخيارات الأخرى 469
9.11 الخرج من ANOVA العاملي للقياسات المكررة 470
1.9.11 الإحصائيات الوصفية والتحليل الأساسي 470
2.9.11 أثر المتحول Drink 471

3.9.11 أثر المتحول imagery 474
4.9.11 أثر التفاعل (drink×imagery) 475
5.9.11 المقارنات لمتحولات القياسات المكررة 477
1.8.9.11 البيرة مقابل الماء والصورة الإيجابية مقابل الحيادية 478
2.5.9.11 البيرة مقابل الماء والصورة السلبية مقابل الحيادية 479
3.5.9.11 النبيذ مقابل الماء والصورة الإيجابية مقابل الحيادية 480
4.5.9.11 النبيذ مقابل الماء والصورة السلبية مقابل الحيادية 480
5.5.9.11 محدودية هذه المقارنات 481
10.11 حجم الأثر من أجل ANOVA العاملي للقياسات المكررة 482
11.11 تقديم نتائج ANOVA العاملي للقياسات المكررة 483
12.11 ما الذي اكتشفناه حول الإحصاء؟ 484
13.11 المصطلحات الأساسية التي اكتشفناها 484
14.11 مهمات يجب تنفيذها 485

12 تصميم ANOVA المختلط (GLM5) 487

1.12 ماذا يخبرنا هذا الفصل؟ 487
2.12 عما يبحث الإنسان في الشريك؟ 487
3.12 ANOVA المختلط في برنامج SPSS 489
1.3.12 التحليل الأساسي 489
2.3.12 الخيارات الأخرى 492
4.12 الخرج من أجل ANOVA العاملي المختلط: التحليل الأساسي 493
1.4.12 أثر المتحول gender 496
2.4.12 أثر المتحول looks 498
3.4.12 أثر المتحول charisma 500
4.4.12 التفاعل بين المتحولين gender و looks 502
1.4.4.12 التفاعل الأول من looks×gender: جذاب مقابل متوسط، ذكر مقابل أنثى 502
2.4.4.12 التفاعل الثاني من looks×gender: قبيح مقابل متوسط، ذكر مقابل أنثى 503
5.4.12 التفاعل بين المتحولين gender و charisma 504
1.5.4.12 التفاعل الأول من charisma×gender: عالي مقابل بعض الكاريزما، ذكر مقابل أنثى 505
2.5.4.12 التفاعل الثاني من charisma×gender: ممل مقابل بعض الكاريزما، ذكر مقابل أنثى 505
6.4.12 التفاعل بين المتحولين looks و charisma 506

1.6.4.12 التفاعل الأول من looks×charisma: جذاب مقابل متوسط، عالي مقابل بعض الكاريزما 507
2.6.4.12 التفاعل الثاني من looks×charisma: جذاب مقابل متوسط، ممل مقابل بعض الكاريزما 508
3.6.4.12 التفاعل الثالث من looks×charisma: قبيح مقابل متوسط، عالي مقابل بعض الكاريزما 508
4.6.4.12 التفاعل الرابع من looks×charisma: قبيح مقابل متوسط، ممل مقابل بعض الكاريزما 509
7.4.12 التفاعل بين المتحولات looks×charisma×gender 510
1.7.4.12 التفاعل الأول من looks×gender×charisma: جذاب مقابل متوسط، عالي مقابل بعض الكاريزما، ذكر مقابل أنثى 511
2.7.4.12 التفاعل الثاني من looks×gender×charisma: جذاب مقابل متوسط، ممل مقابل بعض الكاريزما، ذكر مقابل أنثى 512
3.7.4.12 التفاعل الثالث من looks×gender×charisma: قبيح مقابل متوسط، عالي مقابل بعض الكاريزما، ذكر مقابل أنثى 513
4.7.4.12 التفاعل الرابع من looks×gender×charisma: قبيح مقابل متوسط، ممل مقابل بعض الكاريزما، ذكر مقابل أنثى 514
8.4.12 الخلاصة 514
5.12 حساب حجم الأثر 516
6.12 تقديم نتائج ANOVA المختلط 518
7.12 ما الذي اكتشفناه عن الإحصاء؟ 520
8.12 المصطلحات الأساسية التي اكتشفناها 520
9.12 مهمات يجب تنفيذها 521

13 الاختبارات اللابارامترية 523

1.13 بماذا يخبرنا هذا الفصل؟ 523
2.13 مقارنة حالتين مستقلتين: اختبار Wilcoxon لمجموع المراتب واختبار Mann-Whitney 523
1.2.13 نظرية 524
2.2.13 إدخال البيانات والتحليل المؤقت 527
3.2.13 تنفيذ التحليل 528
4.2.13 الخرج لاختبار Mann-Whitney 531
5.2.13 حساب حجم الأثر 532
6.2.13 كتابة النتائج 533
3.13 مقارنة حالتين مرتبطتين: اختبار Wilcoxon للمرتبة ذات الإشارة 535
1.3.13 نظرية اختبار Wilcoxon للمرتبة ذات الإشارة 535
2.3.13 تنفيذ التحليل 537
3.3.13 الخرج لمجموعة المنشط 539

4.3.13 الخرج لمجموعة الكحول 540
5.3.13 حساب حجم الأثر 541
6.3.13 كتابة النتائج وتفسيرها 541
4.13 الفروق بين عدة مجموعات مستقلة: اختبار Kruskal-Wallis 542
1.4.13 نظرية اختبار Kruskal-Wallis 543
2.4.13 إدخال البيانات والتحليل المؤقت 544
3.4.13 تنفيذ اختبار Kruskal-Wallis في برنامج SPSS 545
4.4.13 الخرج لاختبار Kruskal-Wallis 547
5.4.13 اختبارات post hoc لاختبار Kruskal-Wallis 549
6.4.13 اختبار المناحي: اختبار Jonckheere-Terpstra 552
7.4.13 حساب حجم الأثر 553
8.4.13 كتابة النتائج وتفسيرها 554
5.13 الفروق بين عدة مجموعات مرتبطة: Friedman's ANOVA 556
1.5.13 نظرية Friedman's ANOVA 556
2.5.13 إدخال البيانات والتحليل المؤقت 557
3.5.13 تنفيذ Friedman's ANOVA في برنامج SPSS 558
4.5.13 الخرج من Friedman's ANOVA 559
5.5.13 اختبارات post hoc من أجل Friedman's ANOVA 560
6.5.13 حساب حجم الأثر 563
7.5.13 كتابة النتائج وتفسيرها 564
6.13 ما الذي اكتشفناه عن الإحصاء؟ 565
7.13 المصطلحات الأساسية التي اكتشفناها 565
8.13 مهمات يجب تنفيذها 566

14 التحليل متعدد المتغيرات للتباين (MANOVA) 569

1.14 بماذا يخبرنا هذا الفصل؟ 569
2.14 مدخل: نقاط التشابه والاختلاف مع ANOVA 569
1.2.14 تحذير 570
2.2.14 نقاط الجدل الحالية 571
3.2.14 المثال لهذا الفصل 571
3.14 نظرية MANOVA 573
1.3.14 مدخل إلى المصفوفات 573
2.3.14 بعض المصفوفات الهامة 574
3.3.14 حساب MANOVA يدوياً 575
1.3.3.14 ANOVA وحيد المتغير من أجل المتحول الأول (Actions) 575
2.3.3.14 ANOVA وحيد المتغير من أجل المتحول الثاني (Thoughts) 576

3.3.3.14 العلاقة بين المتحولات التابعة: الجداءات المتصالبة 577
4.3.3.14 المصفوفة T (Total SSCP) 581
5.3.3.14 المصفوفة E (Residual or Error SSCP) 581
6.3.3.14 المصفوفة H (Model or Hypothesis SSCP) 582
4.3.14 مبدأ إحصائية الاختبارMANOVA 583
1.4.3.14 متغيرات التابع المميز 584
2.4.3.14 أثر Pillai-Bartlett (V) 586
3.4.3.14 أثر Hotelling (T^2) 587
4.4.3.14 قيمة Wilks's Lambda (Λ) 587
5.4.3.14 جذر Roy الأكبر 587
4.14 فرضيات MANOVA 588
1.4.14 التحقق من الفرضيات 588
2.4.14 اختيار إحصائية الاختبار 589
3.4.14 التحليل الملحق 590
5.14 تنفيذ MANOVA في برنامج SPSS 590
1.5.14 التحليل الأساسي 590
2.5.14 المقارنات المتعددة في MANOVA 592
3.5.14 الخيارات الإضافية 592
6.14 الخرج من MANOVA 593
1.6.14 التحليل التمهيدي واختبار الفرضيات 593
2.6.14 إحصائيات اختبار MANOVA 595
3.6.14 إحصائيات الاختبار وحيدة المتغير 596
4.6.14 مصفوفات SSCP 598
5.6.14 المقارنات 599
7.14 متابعة MANOVA بتحليل المميز 601
8.14 الخرج من تحليل المميز 604
9.14 بعض الملاحظات النهائية 609
1.9.14 التفسير النهائي 609
2.9.14 ANOVA وحيد المتغير أم تحليل المميز؟ 611
10.14 ما الذي اكتشفناه عن الإحصاء؟ 611
11.14 المصطلحات الأساسية التي اكتشفناها 611
12.14 مهمات يجب تنفيذها 612

15 التحليل العاملي الاستكشافي 615

1.15 بماذا يخبرنا هذا الفصل؟ 615
2.15 العوامل 615

1.2.15 التمثيل البياني للعوامل 617
2.2.15 التمثيل الرياضي للعوامل 618
3.2.15 علامات العامل 621
1.3.2.15 طريقة التراجع 621
2.3.2.15 الطرق الأخرى 623
3.3.2.15 استخدامات علامات العامل 623
3.15 اكتشاف العوامل 624
1.3.15 اختيار طريقة 624
2.3.15 التشاركية 625
3.3.15 التحليل العاملي مقابل تحليل المكونات الأساسية 625
4.3.15 نظرية تحليل المكونات الأساسية 626
5.3.15 استخراج العوامل: القيم الخاصة ومخطط المنحدر 627
6.3.15 تحسين التفسير: دوران العوامل 629
1.6.3.15 اختيار طريقة تدوير العوامل 631
2.6.3.15 الأهمية الجوهرية لقيم تحميل العامل 632
4.15 مثال بحثي 632
1.4.15 الاعتبارات الأولية 634
1.1.4.15 حجم العينة 634
2.1.4.15 تصفية البيانات 635
5.15 تنفيذ التحليل 636
1.5.15 استخراج العوامل في برنامج SPSS 638
2.5.15 الدوران 639
3.5.15 العلامات 641
4.5.15 الخيارات 641
6.15 تفسير الخرج من برنامج SPSS 642
1.6.15 التحليل التمهيدي 643
2.6.15 استخراج العوامل 647
3.6.15 دوران العوامل 652
1.1.6.15 الدوران المتعامد (Varimax) 652
2.1.6.15 الدوران المائل 655
4.6.15 علامات العامل 657
5.6.15 الخلاصة 659
7.15 تحليل الوثوقية 659
1.7.15 قياسات الوثوقية 659
2.7.15 تفسير Cronbach's α 661
3.7.15 تحليل الوثوقية في برنامج SPSS 664

4.7.15 تفسير الخرج 666
8.15 ما الذي اكتشفناه عن الإحصاء 670
9.15 المصطلحات الأساسية التي اكتشفناها 670
10.15 مهمات يجب تنفيذها 672

16 البيانات الفئوية 675

1.16 ماذا يخبرنا هذا الفصل 375
2.16 نظرية تحليل البيانات الفئوية 375
1.2.16 اختبار كاي مربع لـ Pearson 676
2.2.16 نسبة الاحتمالية 678
3.2.16 تصحيح Yates 678
3.16 فرضيات اختبار كاي مربع 679
4.16 تنفيذ كاي مربع في برنامج SPSS 679
1.4.16 إدخال البيانات: العلامات الصفّية 679
2.4.16 إدخال البيانات: العلامات المثقّلة 680
3.4.16 تنفيذ التحليل 681
4.4.16 الخرج لاختبار كاي مربع 683
5.4.16 حساب حجم الأثر 686
6.4.16 تقديم نتائج كاي مربع 687
5.16 عدة متحولات فئوية: التحليل الخطي اللوغاريتمي 688
1.5.16 كاي مربع كتراجع 688
2.5.16 التحليل الخطي اللوغاريتمي 694
6.16 الفرضيات في التحليل الخطي اللوغاريتمي 696
7.16 تنفيذ التحليل الخطي اللوغاريتمي في برنامج SPSS 697
1.7.16 الاعتبارات الأولية 697
2.7.16 التحليل الخطي اللوغاريتمي 699
8.16 الخرج من التحليل الخطي اللوغاريتمي 701
9.16 متابعة التحليل الخطي اللوغاريتمي 706
10.16 حجم الأثر في التحليل الخطي اللوغاريتمي 708
11.16 تقديم النتائج للتحليل الخطي اللوغاريتمي 709
12.16 ما الذي اكتشفناه عن الإحصاء؟ 711
13.16 المصطلحات الأساسية التي اكتشفناها 711
14.16 مهمات يجب تنفيذها 711

المسرد 713

A الملحق 751

A.1 جدول التوزيع الطبيعي المعياري 743
A.2 القيم الحرجة للتوزيع t 747
A.3 القيم الحرجة للتوزيع F 748
A.4 القيم الحرجة لتوزيع كاي مربع 752
A.5 اختبار Welch F: النسبة F عندما لا تتحقق فرضية تجانس التباين 753
A.6 حساب الآثار البسيطة 756
A.7 اختبار Jonckheere للمنحنى 759
A.8 ملحق الفصل 14 765
A.9 حساب معاملات علامات العامل 767
A.10 تعريف المقارنات باستخدام القواعد 769
A.11 تصميم استبيان 780

جدول المحتويات 789

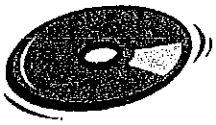

محتويات القرص المرفق

الإحصاء
باستخدام SPSS

- يحوي القرص المضغوط المرفق ملفات البيانات للأمثلة الواردة في الكتاب مع بيانات المهمات المطلوب إنجازها وكذلك الإجابات على هذه المهمات.
- كما يحتوي أيضاً على النسخة الحديثة من كتالوغ منشورات دار شعاع للنشر والعلوم.

في حال واجهت أية مشكلة في القرص المرفق أو في محتوياته نرجو مراسلتنا على عنوان البريد الإلكتروني التالي quality@raypub.com.

ابق على اتصال معنا...

www.raypub.com

وتابع أحدث إصداراتنا في مختلف العلوم والمجالات عبر هذا الموقع، الذي نقدم من خلاله معلومات وافية عن العناوين التي تم إصدارها. واستمتع بالمزايا التالية:

- ❖ متابعة الإصدارات الجديدة فور صدورها
- ❖ البحث البسيط والمتقدم عن الكتب ومن خلال عدة معايير
- ❖ الشراء الفوري من الموقع
- ❖ مطالعة فهارس محتويات الكتب المختصرة والتفصيلية والحصول على فصل مجاني من الكتاب

ونرحب عزيزي القارئ بآرائك ومقترحاتك ونقدك المتعلق بكتبنا، أو الآراء المتعلقة بالموقع أيضاً. ولمزيد من الاستفسار يمكنك مراسلتنا على البريد الإلكتروني **info@raypub.com**.