

الإحصاءات التفسيرية

سينت فيسر و جون بول جونز الثالث

الفصل 18

ترجمة بتصرف
أ.د. مضر خليل عمر

مقدمة

في هذا الفصل ، نواصل بحثنا في المنطق الإحصائي الذي بدأناه في الفصل 17. ولكننا هنا ، نتناول موضوع الإحصاءات التفسيرية في مقابل الإحصاءات الوصفية. وكما في ذلك الفصل ، نقدم عددًا محدودًا فقط من الأدوات . ومع ذلك ، يبقى التركيز الرئيسي : إعطاؤك فكرة أوضح عن كيفية تفكير الباحثين في مشكلاتهم . في هذا الفصل، تكمن المشكلة في السببية . وفيما يلي ، نقدم أولاً لمحة عامة عن بعض أساسيات السببية في بيانات البحث التجريبية وغير الخاضعة للرقابة . ثم نغطي تحليل الانحدار البسيط والمتعدد المتغيرات (انظر جونستون 1978). الانحدار هو العمود الفقري للتفسير الإحصائي . إن تعلم كيفية عملها يُساعدنا بشكل كبير في التفكير السببي في العالم : في كيفية تغير الأشياء وأسبابه ، وفي كيفية خداعنا لاستنتاجات خاطئة إذا لم نُعر اهتمامًا كافيًا لبياناتنا وللافتراضات التي نضعها في تحليلاتنا.

التفكير في السببية إحصائيًا

من الأهداف الرئيسية للإحصاء وصف قوة وطبيعة العلاقة بين متغيرين . ويتم ذلك بهدف تقديم دليل على أن أحد المتغيرين "يسبب" الآخر . يُعد المتغير السببي المتغير المستقل (X) ومتغير الاستجابة هو المتغير التابع (Y). المتغير المستقل هو المتغير الذي تُعطى قيمه ، أو يمكن التحكم فيها في حالة تجريبية . المتغير التابع هو المتغير الذي يُفترض أنه يتغير مع المتغير المستقل ، أو يستجيب له . لكي ينجح هذا النوع من التحليل العلمي ، يشترط أن يكون لـ X تأثير مستقل على Y مستقل عن المتغيرات السببية المحتملة الأخرى . غالبًا ما لا يكون هذا هو الحال . في كثير من الأحيان ، تشترك متغيرات X المختلفة في أنماط تباين متشابهة ، وأحيانًا تكون متشابهة لدرجة يصعب معها ، إن لم يكن من المستحيل ، تحديد آثارها المستقلة على Y . تُعد هذه مسألة بالغة الأهمية في إثبات السبب . إذا كان X_1 و X_2 يشتركان في نصف إجمالي تباينهما ، فكيف يمكننا تحديد أي من متغيري X يُسبب Y ؟ تُعرف هذه المسألة بمشكلة التعدد الخطي؛ وسنعود إليها لاحقًا . وبالمثل ، من المهم ألا تؤثر قيم المتغير التابع ، من الناحية النظرية ، على قيم المتغير المستقل . أما في الممارسة العملية ، وخاصة في الجغرافيا البشرية ، فقد لا يكون هذا هو الحال (ينظر الفصل 2) . إذا كانت العلاقة بين X و Y متكررة (أي، $X \leftrightarrow Y$) ، فكم مما نكتشفه يُسبب Y X ، وكم يُسبب Y ؟

يمكن تجنب تعقيدات الاستقلال في بعض التخصصات من خلال المنهج التجريبي . يدور هذا المنهج حول فكرة التأثيرات المستقلة ، وكيفية قياسها ، ومخاطر إعطاء تسمية "السبب" لمتغير X حتى لو كان تأثيرًا مستقلًا واضحًا . والأهم من ذلك ، أن التجربة المُتحكم بها هي أفضل طريقة لإزالة آثار المتغيرات المُربكة الأخرى التي تُربك تقييمنا للعلاقة بين X و Y . على سبيل المثال ، لتحديد ما إذا كانت المادة الكيميائية X تُسبب السرطان ، يُمكن اختيار مجموعتين من الفئران عشوائيًا من مجموعة واحدة من الفئران المتطابقة وراثيًا . تُمثل إحدى المجموعتين المجموعة الضابطة والأخرى المجموعة التجريبية . الفرق الوحيد بين المجموعتين

هو أن كل فأر في المجموعة التجريبية سيصاب بـ X بانتظام ، بينما لا يصاب به أيٌّ من الفئران في المجموعة الضابطة . إذا أصيب 20 فأراً من أصل 100 فأر في المجموعة التجريبية بالسرطان بعد عام واحد ، بينما أصيب به 4 فأر فقط من أصل 100 فأر في المجموعة الضابطة، فلا بد أن يكون X في النظام الغذائي هو السبب ، لأن هذا هو الفرق الوحيد بين المجموعتين .

إذا تفاوتت جرعات X من جرعات صغيرة إلى متوسطة إلى عالية ، واستجاب تطور السرطان لهذه الكميات المختلفة ، فسنحصل على المزيد من الأدلة على العلاقة بين X و Y . قد يُشير تغيير معدل الجرعة أيضاً إلى كميات عتبة مختلفة من المادة الكيميائية ، والتي يبدأ السرطان بعدها في الظهور . وهناك احتمال آخر وهو أن X يكون مسرطناً فقط عندما يتفاعل مع مادة أخرى ، والتي قد تكون موجودة في المختبر ولكنها غير موجودة عادةً . في العالم الواقعي ، عندما تتفاعل مادتان لتوليد تأثير ، لا يمكن لأي منهما إحداثه بمفرده ، يُسمى ذلك تآزراً . من الشائع ألا يُسبب X السرطان في الحالة التجريبية ، ولكنه يُسببه في العالم الواقعي ، بسبب تآزره مع مادة مجهولة من المرجح أن يلتقي بها .

التآزر الإيجابي هو عندما يكون التأثير المُجمع مُضاعفاً ، بدلاً من أن يكون التأثير ناتجاً عن جمع التأثيرين المُستقلين . التآزر السلبي هو عندما يُبطل وجود عاملين تأثير أحدهما أو كليهما ، أو يكون التأثير المُجمع للعاملين أقل من مجموع تأثيراتهما المُستقلة . التآزر الإيجابي والسلبي هما مفهومان ينطبقان على التأثيرات التي تُقاس كمتغيرات نسبية ، ولكل متغير تأثير على مُتغير الاستجابة . لكن العلم يُعلمنا أنه يُمكن أن يكون هناك أيضاً مُتغير مُحفز . قد يكون هناك شيء موجود في الحالة التجريبية لا يحدث تأثيراً على Y بحد ذاته ، ولكنه يحدث تفاعلاً بين X و Y عند وجوده ، ولا يوجد تفاعل أو علاقة بين X و Y عند غيابه . تُمثل متغيرات التآزر والعوامل المُحفزة مشكلة كبيرة في تحديد السبب والنتيجة ، وخاصةً في البحث الطبي ، لأنه يجب تجربة جميع تركيبات العوامل المُسببة للكشف عنها ، وهذا غير عملي من الناحية المالية (ينظر الجدول 18.1).

Table 18.1 Types of causal relations

Type of relation	Graphic representation
Simple causal relation with independence	$X \rightarrow Y$
Multivariate causal relation with independence	X_2 $\searrow$ $X_1 \rightarrow Y$
Recursive relations	$X \leftrightarrow Y$
Multicollinearity	$X_1 \leftrightarrow X_2$ $\searrow \swarrow$ Y
Multiplicative synergy	$X_2 \cdot X_1 \rightarrow Y$
Catalyst effect	X_2 $\downarrow$ $X_1 \rightarrow Y$

ومما يزيد الأمر تعقيداً أنه إذا تسبب X في السرطان لدى الفئران ، فهذا لا يعني أنه سيُسبب السرطان لدى البشر . من المُحتمل أن يُسبب ذلك لأن الفئران لا تختلف وراثياً عن البشر، ولكن في حين أن مُعظم العوامل المُسببة للسرطان لدى الفئران تُسبب ذلك لدى البشر، فليست جميعها تُسبب ذلك ، نظراً لاختلافنا الجيني عن الفئران ، ولأن البيانات التي نعيش فيها (والعوامل المُحفزة والتآزرية التي نختبرها) مختلفة أيضاً إلى حد ما . لاحظ أن هذه المشكلة ليست مشكلة تشبيه خاطئ . التشبيهات الخاطئة معيبة منطقياً ، وهي مشكلة منفصلة في القياس والتفسير.

وأخيرًا ، قد تكون العلاقة بين X والسرطان مجرد مصادفة . تتمثل إحدى المهام الرئيسية للإحصاءات في الدراسة المذكورة أعلاه في تحديد ما إذا كان الفرق بين 4 من 100 (4%) و 20 من 100 (20%) ذا دلالة إحصائية . إذا لم تتلقَ أيُّ من مجموعتي الفئران X ، ما هي فرصة وجود 4 حالات إصابة بالسرطان في مجموعة و 20 حالة في الأخرى ؟ أي بمحض الصدفة ؟ يمكن حساب هذه الفرصة أو الاحتمالية ، وفي الواقع قيمتها 0.0004 أو 0.04% . وبالتالي ، من الممكن أن يكون الفرق قد حدث بالصدفة ، ولكنه مستبعد للغاية . وبالتالي ، يستنتج الباحثون أن الاختلافات في حدوث السرطان كانت بسبب X ، وأنه إذا أُجريت التجربة على مليون فأر ، فسيكون معدل الإصابة بالسرطان أعلى لدى أولئك الذين تلقوا X مقارنةً بمن لم يتلقوه .

هذا هو الاستدلال الإحصائي - وهو عملية الاستدلال من عينة من الملاحظات على مجموعة الملاحظات . مجموعة الملاحظات هي جميع الملاحظات الممكنة ذات الصلة بدراسة ما (الفصل 6) . في المثال أعلاه ، هي جميع الفئران في جميع الأوقات . أحد متطلبات العينة العشوائية هو أن تكون الملاحظات المختارة مستقلة عن بعضها البعض (مسألة ثالثة تتعلق بكلمة الاستقلال) . إذا لم يكن ذلك صحيحًا ، فلا يمكن تحديد التأثير المستقل لـ X على Y . في التجربة الموصوفة ، تم تجاهل هذا الشرط بالفعل ، لأن الفئران متطابقة وراثيًا ، وبالتالي لا تمثل جميع الفئران . لذلك قد نفتقر هذه الفئران إلى جين ضروري للإصابة بالسرطان نتيجة التعرض لـ X ، أو قد يكون لديها جين ، يفتقر إليه معظمها ، يسبب السرطان نتيجة التعرض لـ X .

لذا ، فإن قدرتنا على الاستدلال على السكان هي جزئيًا نتيجة لاستقلالية الملاحظات . يمكن التحكم في هذه المشكلات بسهولة أكبر في المواقف التجريبية ، ولكنها أقل سهولة في السياقات الاجتماعية . عندما يتم أخذ عينات من الأسر في حي ما للدراسة ، فإن الأشخاص الذين تمت مقابلتهم ليسوا مستقلين ؛ فهم يشتركون في "تأثير الحي السكني" (على سبيل المثال ، خلفيات طبقية ، وإثنية ، وأصلية قومية متشابهة) . عندما تُجرى المسوحات عبر الخطوط الأرضية ، فإنك تفوت الأشخاص الذين يحملون الهواتف المحمولة فقط . عندما تكون المقاطعات في ولاية ما هي وحدات الرصد ، فإن المقاطعات الأقرب إلى بعضها البعض تميل إلى أن تكون أكثر تشابهًا ، وبالتالي غير مستقلة . وينطبق الأمر نفسه على محطات الأرصاد الجوية ، ومقاييس الأنهار ، والبكسلات التي تسجل الغطاء النباتي من خلال جهاز استشعار عن بُعد . لقد تم اختراع الإحصاء لعالم من الاستقلالية ؛ ولكن خارج الحالات التجريبية ، فإن عددًا كبيرًا من ملاحظتنا مترابط مع بعضها البعض . تُسمى هذه المشكلة بالارتباط الذاتي ؛ فإذا كانت الوحدات المعنية مترابطة لأنها تشترك في جغرافية مشتركة (مثل : حدود مشتركة ، أو تقارب ، أو اتصال مكاني) ، فإن المشكلة تُسمى بالارتباط الذاتي المكاني.

تجارب على البشر؟

ماذا لو لجأنا إلى المختبر لتصميم تجربة على البشر تُحدد التأثير المستقل لمتغير وتزيل المتغيرات المربكة ؟ إحدى المشكلات التي قد نواجهها هي أخلاقية : هناك بعض التجارب التي يُجريها العلماء على الحيوانات والتي لا يُجيزون إجراؤها على البشر (لاحظ أن العديد من نشاطات حقوق الحيوان وعلماء الأخلاق يعارضون التجارب على الحيوانات أيضًا) . عندما يُجري الباحثون تجارب على البشر ، لمعرفة المواد أو العلاجات التي قد تُعالج الأمراض ، عادةً ما تتلقى مجموعة علاجًا (محفزًا) بينما لا تتلقى مجموعة أخرى . إذا كان العلاج فعالًا ، فقد يموت أعضاء المجموعة التي لم تتلقه أو يموتون قبل مجموعة العلاج . يبدو هذا

مُريعًا ، لكنه الطريقة الوحيدة لتحديد مدى فعالية العلاج . لقد مات الكثير من الناس لعدم حصولهم على العلاج المناسب ، وتلقى الكثيرون علاجات ضارة لم تُجدِ نفعًا .

هناك مشكلة أخرى في التجارب البشرية ، وهي عدم وجود أفراد متطابقين لتصنيفهم في مجموعات . لذلك ، يُختار الأشخاص عشوائيًا في مجموعتين . الأفراد في كل مجموعة ليسوا متطابقين ، ولكن يُؤمل أن يكون التباين في سمات الأفراد داخل المجموعتين هو نفسه . في هذه الحالة ، يتم التحكم في استقلالية الملاحظات من خلال أخذ العينات العشوائية . ومع ذلك ، قد تكون هناك مشكلة أخرى تتمثل في تلوث التجارب ، لأن المجموعات تعتقد أنها تعلم أنها تتلقى العلاج أم لا . هذا هو تأثير الدواء الوهمي . في تجربة مزدوجة التعمية ، لا يعرف الفريق الذي يُعطي الدواء للمرضى ما إذا كان الفرد يتلقى الدواء بالفعل أم الدواء الوهمي . وإلا ، فقد يؤثر على النتيجة . قد يشعرون بالأسف تجاه أولئك الذين يتلقون الدواء الوهمي ، ويظهرون بطريقة ما شعورًا "بانعدام الأمل" ، مما يُحبط المريض ويُقلل من فرص تحسنه . في تجربة ثلاثية التعمية ، لا يعرف الباحثون الذين يقيسون ما إذا كان المريض قد "تحسنوا" أو "شفوا" أيضًا من تلقى الدواء ومن تلقى الدواء الوهمي . وإلا ، فقد يكون تفسيرهم للتحسن متحيزًا.

كما ترون ، حتى في بيئة البحث المثالية للتجارب ، فإن قياس علاقة مستقلة بين متغيرين محفوف بالخطأ ، وعرضة لسوء التفسير . وعلى الرغم من إدراك العلماء جيدًا لتأثير المتغيرات المربكة على العلاقة المستقلة بين متغيرين ، إلا أنهم يفشلون أحيانًا في التساؤل عما إذا كانت العلاقة تعتمد كليًا على السياق (أي وجود عامل محفز) . في معظم مشكلات البحث في العلوم الجغرافية والاجتماعية ، لا يمكن استخدام المنهج التجريبي . لا يمكن مطالبة مجموعة من المقاطعات بتجربة الأمور بطريقة ما ، بينما تحاول مجموعة أخرى من المقاطعات المتشابهة تجربة الأمور بطريقة أخرى . لذلك ، يتطلب تحديد علاقة مستقلة بين متغيرين محاولة التحكم في التباين في عدد كبير من المتغيرات ، بحيث نتمكن من التركيز على المتغير الذي تُعدّ فعاليته السببية ذات أهمية أساسية . من الناحية التحليلية ، قد يُمثل هذا صعوبات كبيرة ؛ إذ لا توجد سوى تجارب طبيعية قليلة جدًا في "العالم الحقيقي" .

الانحدار الخطي البسيط والارتباط

يصف الانحدار التباين المشترك لمتغيرين مُقاسين على مقياس فاصل / نسبة . يعني الانحدار البسيط وجود متغير مستقل واحد فقط . يصف الارتباط مدى قرب أو قوة هذا التباين المشترك (الفصل 17) . إذا بدت النقاط في مخطط التشتت وكأنها تتبع خطًا مستقيمًا ، فيمكن عندئذٍ تركيب خط يصف العلاقة المتوسطة على هذه النقاط . الانحدار الخطي هو إيجاد معادلة الخط التي تُطابق التشتت على أفضل وجه . يوضح الشكل 18.1 علاقة إيجابية ضعيفة بين تصويت الحزب الديمقراطي عام 1980 (Y)، أو (DEMVote) بين مقاطعات تكساس المختارة ونسبة سكان المقاطعة الذين يعيشون تحت خط الفقر (X)، أو (PERPOV) ، مع رسم خط الانحدار على التشتت (الفصل 17 وتبين 1990).




Figure 18.1 DEMVOTE (vertical axis) and PERPOV (horizontal axis)

معادلة خط الانحدار هي:

$$\hat{Y}_i = a + bX_i \quad (18.1)$$

هي القيمة المتوقعة باعتبار قيمة X . يشير الرمز السفلي "i" إلى الملاحظة i لـ X و Y . يُطلق على المعاملين "a" و "b" اسم الثابت ، ويُطلق على الانحدار اسم معامل الانحدار ، على التوالي . الثابت هو القيمة المتوقعة لـ Y حيث X تساوي صفرًا ؛ ويُسمى أيضًا نقطة التقاطع ، ويمكن قراءته من المحور Y عند تلك النقطة . يُسمى معامل الانحدار أيضًا بالميل ، لأنه ميل الخط . وهو أيضًا مقياس للتغير المتوقع في Y إذا زادت قيمة X بمقدار وحدة واحدة . يكون معامل الانحدار سالبًا إذا انخفضت Y مع زيادة X ، مما يصف علاقة عكسية .
خط الانحدار لمجموعة ملاحظات المقاطعات الثلاثين هو:

$$\text{DEMVote} = 28.55 + 0.86 \cdot \text{PERPOV} \quad (18.2)$$

For all of the state's 254 counties, the equation is:

$$\text{DEMVote} = 29.71 + 0.81 \cdot \text{PERPOV} \quad (18.3)$$

لجميع مقاطعات الولاية البالغ عددها 254، المعادلة هي:

تشير المعادلة الأخيرة إلى أنه في المتوسط ، يجب أن يكون لدى المقاطعة التي تزيد قيمة PERPOV فيها عن مقاطعة أخرى وحدة صوت واحدة أعلى من مقاطعة أخرى بنسبة 0.81 وحدة (نسبة مئوية) . يُستنتج من ذلك أن المقاطعات التي تضم عددًا أكبر من الفقراء تكون أكثر عرضة للتصويت للديمقراطيين . يُقاس PERPOV كنسبة مئوية ، كما هو الحال مع DEMVote ، لذا في هذه الحالة ، فإن زيادة بنسبة 1% في PERPOV تزيد من DEMVote بنسبة 0.81 نقطة مئوية . لتقدير قيمة Y لملاحظة معينة بالنظر إلى قيمة X الخاصة بها ، تدخل قيمة X ببساطة في معادلة الانحدار . الفرق الرأسي أو فرق المحور Y بين القيمة الفعلية للملاحظة على Y والقيمة المتوقعة من معادلة الانحدار هو خطأ التنبؤ لتلك الملاحظة .

على سبيل المثال، تبلغ قيمة PERPOV في إحدى المقاطعات 20.6% . يؤدي إدخال هذه القيمة في معادلة الانحدار للمقاطعات الثلاثين إلى توقع DEMVote بقيمة 46.27 (28.55 + 0.86 (20.6)) . بلغت القيمة الفعلية لـ DEMVote لتلك المقاطعة 30.1% . يُكتب خطأ التنبؤ على النحو التالي: $e_i = Y_i - \hat{Y}_i$ ، وكان $46.27 - 30.1 = 16.17$ لملاحظة المثال . ستحمل الملاحظات التي تقع أسفل خط الانحدار أخطاءً سلبية (القيمة الفعلية أقل من المتوقعة) ، بينما ستحمل الملاحظات التي تقع فوق خط الانحدار أخطاءً إيجابية (القيمة الفعلية أعلى من المتوقعة) . يُطلق على خطأ التنبؤ عادةً اسم المتبقي (البواقي) . إذا تم تربيع أخطاء التنبؤ لجميع الملاحظات ، ثم جُمعت مربعات الانحرافات ، يُسمى المجموع مجموع مربعات الخطأ أو مجموع المربعات المتبقية (RSS).

يحسب الحاسوب قيم معامل الانحدار (b) والثابت (a) التي تُقلل الخطأ أو مجموع المربعات المتبقية . لذلك ، تُسمى معادلة الانحدار معادلة الانحدار الخطي بأقل مربعات ، وتُعد هذه المعادلة أيضًا أفضل خط

انحدار . يكون خط الانحدار الناتج فريداً . توجد قيمة واحدة فقط ممكنة لـ "a" وقيمة واحدة فقط ممكنة لـ "b" يُقلل مجموعها إلى أدنى حد . بصرياً ، إذا تخيلت زيادة أو نقصان ميل الخط في الشكل 18.1 ، فستلاحظ زيادةً في الخطأ التربيعي الإجمالي ؛ وبالمثل ، إذا رفعت الخط أو خفضته (زيادة أو نقصان النقطة المقطوعة) ، فسيبدو الخطأ أيضاً في ازدياد . وبالتالي ، يكون مجموع مربعات الأخطاء حول الخط أقل من مجموع مربعات الأخطاء حول أي خط آخر . لاحظ كيف يتتبع خط الانحدار الخطي γ لجميع الملاحظات التي لها قيمة مُحددة لـ X . لذا، فإن خط الانحدار هو في الواقع متوسط متحرك لـ γ ، وهو دالة خطية لمتغير X .

$$RSS = \sum e_i^2 = \sum (Y_i - \hat{Y}_i)^2 \quad (18.4)$$

أخطاء الانحدار تُعادل الانحرافات حول هذا المتوسط المتحرك.

حسابياً ، تُعامل الأخطاء حول خط الانحدار بنفس طريقة التعامل مع التباين في متغير حول متوسط (الفصل 17) . تُربّع الأخطاء ، وتُجمع عبر جميع الملاحظات ، ويُحسب متوسطها ، تماماً كما هو الحال في حساب التباين . يُعطي قسمة مجموع مربعات المتبقي على عدد الملاحظات تباين الانحدار . ومع ذلك ، يتطلب أفضل تقدير لتباين انحدار المجتمع قسمة مجموع مربعات المتبقي على $n - 2$. لذلك ، يُحسب الانحراف المعياري للمتبقيات بأخذ الجذر التربيعي لتباين الانحدار . ولكن هذا المصطلح لا يُسمى انحرافاً معيارياً ، بل يُسمى الخطأ المعياري للتقدير أو ببساطة الخطأ المعياري . رموزه هي e s لبيانات العينة، و σ_e للمجتمع .

الخطأ المعياري لتقدير انحدار DEMVOTE مقابل PERPOV هو 10.14. الانحراف المعياري لـ DEMVOTE هو 11.72. وبالتالي ، فقد "شرح" PERPOV بعض التباين في متغير DEMVOTE. لمعرفة مقدار التفسير الإحصائي الذي حدث ، نعود إلى التباين الكلي في المتغير . يمكن عد الفرق بين قيمة γ ومتوسطها $(\gamma_i - \bar{\gamma})$ مكوناً من جزأين : التباين الذي يمكن تفسيره (أو "ينتج عنه") بواسطة قيمة $X_i - \bar{X}$ ، والخطأ $\gamma_i - \hat{\gamma}_i$ ، وهو الجزء الذي لا يمكن لـ X تفسيره . تم شرح المتبقي أو مجموع مربعات الخطأ (RSS) أعلاه . تم تقديم التباين الكلي أو مجموع المربعات الكلي في الفصل 17. هنا نكتبه على النحو الاتي : مجموع المربعات الموضح هو $ESS = \sum (\hat{\gamma}_i - \bar{\gamma})^2$ وقد ثبت أن مجموع المربعات الموضح زائد مجموع المربعات المتبقي (أو غير الموضح) يساوي المجموع الكلي للمربعات.

إذا قُسم مجموع المربعات الموضح على المجموع الكلي للمربعات ، فإن النتيجة هي نسبة التباين الكلي في قيم γ المفسر "بواسطة المتغير X . هذه النتيجة هي معامل التحديد ، أو r^2 : نسبة التباين الكلي لـ γ الموضحة بالعلاقة الخطية مع المتغير المستقل . وبما أن r^2 نسبة ، فإن قيمها تتراوح بين 0 و 1 . تعني القيمة 1 أن مجموع المربعات الموضح يساوي المجموع الكلي للمربعات ؛ لذا ستكون جميع نقاط مخطط التشتت على الخط المستقيم ، ولن تكون هناك أخطاء . إذا كانت قيمة r^2 تساوي صفراً ، فإن مجموع المربعات غير المُفسر يساوي مجموع المربعات ، وأن خط الانحدار سيكون أفقياً ومساوياً لمتوسط γ أو $\bar{\gamma}$.

كما أن معامل الانحدار سيكون صفراً ، والثابت يساوي متوسط γ . الجذر التربيعي لـ r^2 هو $\pm r$ ، وهو في حالة الانحدار البسيط مماثل لمعامل ارتباط بيرسون ، الموصوف في الفصل 17. قيمة r^2 لـ DEMVOTE المُنحدرة مقابل PERPOV هي 0.255 لجميع المقاطعات الـ 254 . ومعامل بيرسون هو + 0.505 . دائماً ما تكون قيمة بيرسون المطلقة أكبر من r^2 ، وبالتالي فإن ذكرها وحدها يجعل العلاقة تبدو أقوى مما هي عليه في الواقع ، بالإضافة إلى أنها تصف قوة واتجاه علاقة خطية برقم واحد . إذا كانت r^2

تساوي 0.20 ، فإن r^- تساوي 0.04 ، مما يشير إلى عدم وجود علاقة خطية تقريبًا ، ولكن r^- لا تبدو سيئة للغاية . يجب النظر إلى الأبحاث التي تُبلغ فقط عن معامل الارتباط بعين الشك . هل العلاقة الخطية هي الأنسب ؟ هل توجد العلاقة بسبب قيمة ملاحظة واحدة أو اثنتين ؟ هل للأخطاء توزيع طبيعي؟

$$TSS = \sum (Y_i - \bar{Y})^2 \quad (18.6)$$

هناك معنى لـ r^- قيمة r^- تساوي 0.8 ضعف قيمة r^- 4 لكن هذا لا ينطبق على r^- . R^- هي مجرد مؤشر على قرب العلاقة الخطية ، وقيمة 0.5 أفضل من 0.25 ، ولكنها ليست ضعف قيمتها . إذا لم تكن هناك علاقة بين X و Y ، فإن $r = r^2 = b = 0$ ، ولكن ، إذا كانت $r = r^2 = b = 0$ ، فهذا لا يعني عدم وجود علاقة بين X و Y ؛ بل يعني فقط عدم وجود علاقة خطية بينهما . في حالة الانحدارات ثنائية المتغير (البسيطة) ، يكون معامل الارتباط هو أيضًا معامل الانحدار المعياري (بيتا) . إذا زادت قيمة X بمقدار انحراف معياري واحد ، فإن قيمة Y تزداد في المتوسط بمقدار 0.505 انحراف معياري عن Y (باستخدام $r = 0.505$) . يخبرنا معامل الانحدار بمدى تغير DEMVOTE (بوحدة قياسها) إذا زادت PERPOV بإحدى وحدات قياسها (كلا النسبتين المؤيتين في هذه الحالة).

النماذج الخطية متعددة المتغيرات

يمكن ربط متغير مقياس الفاصل / النسبة بالعديد من المتغيرات المستقلة في آن واحد ، وذلك من خلال التعبير عنه كدالة خطية لعدة متغيرات . وتكون صيغة المعادلة كالآتي :

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_n X_n \quad (18.7)$$

X_s هي المتغيرات المستقلة المختلفة المقاسة على مقياس فاصل/ نسبة ، مع أنها قد تكون متغيرات اسمية ثنائية التفرع (متغيرات وهمية) . هذه متغيرات لها قيمتان محتملتان فقط : صفر و واحد . تعني قيمة واحد وجود سمة ، بينما تعني قيمة صفر عدم وجودها . الثابت هو $b_0 = 0$ ، وهو القيمة المتوقعة لـ Y عندما تكون جميع متغيرات X مساوية للصفر ، وهو حدث غير محتمل . قيم b هي معاملات الانحدار الجزئي التي تصف تأثير متغير X على Y . تشير معاملات المتغيرات الوهمية إلى مدى اختلاف متوسطات Y للمجموعتين اللتين تُشكّلان المتغيرات الوهمية .

على سبيل المثال ، إذا كان العائد بالبوشل متغيرًا تابعًا ، وكان المتغير الوهمي هو $Entisols = 1$ ، وليس $Entisols = 0$ ، وكان معامل الانحدار 10 ، فإن ذلك يشير إلى أن متوسط الغلات أعلى بمقدار 10 بوشل في تربة Entisol مقارنةً بأنواع الترب الأخرى ، مع ثبات جميع العوامل الأخرى . ربما تكون كلمة "جزئي" في معامل الانحدار الجزئي مشتقة من "مشتق جزئي" في حساب التفاضل والتكامل ، لأنها تصف التأثير المستقل لأي X مُعطى على Y ؛ أي أنه تأثير X_1 على Y عند التحكم في X_2 وجميع قيم X الأخرى في المعادلة . وهذا بدوره يعني أن قيم b المرتبطة بقيم X تُحدد تأثير متغير X على Y عندما لا يتغير أي من متغيرات X الأخرى . على سبيل المثال ، لنفترض وجود معادلة بمتغيرين مستقلين :

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 \quad (18.8)$$

من حيث المبدأ ، يُجري الحاسوب انحدارًا بين Y و X_1 مقابل X_2 ، ويحسب الأخطاء أو البقايا لكل منهما ، ثم يُجري انحدارًا بين هذه البقايا . وبالتالي ، يُزال تأثير تباين X_2 على Y وعلى X_1 ، وبالتالي ، تكون العلاقة بين Y و X_1 مستقلة عن تباين X_2 . وبالمثل ، يصف معامل الانحدار لـ X_2 تأثير X_2 على Y دون أي تباين في X_1 . إن الرياضيات المستخدمة في حساب معاملات الانحدار ليست متسلسلة في الواقع كما هو موضح ، ولكنها متكافئة . تُسمى هذه التقنية الانحدار المتعدد باستخدام طريقة المربعات الصغرى العادية (OLS) . كما هو الحال في الانحدار البسيط ، يُقلل مجموع مربعات الأخطاء في الانحدار المتعدد . فإذا قيل إن الانحدار البسيط بمتغير مستقل واحد يُقلل مجموع مربعات جميع النقاط حول خط يمر بها ، فإن الانحدار المتعدد بمتغيرين مستقلين يُقلل مجموع مربعات الانحرافات لجميع النقاط حول مستوى (تخيل المستوى عائماً في ثلاثة أبعاد، بحيث يكون Y على المحور الرأسي، و X_1 و X_2 على المحورين الأفقيين، ونقاط البيانات تقع أعلى وأسفل) .

للمستوى ارتفاع يُقاس بمقطع معادلة الانحدار المتعدد ، ويمكن حساب معاملات الارتباط الجزئي لكل متغير مستقل ؛ وهذه المعاملات هي أيضاً ميل المستوى في بُعد المتغير المعني . أخيراً ، تتضمن نتائج الانحدار المتعدد بالمربعات الصغرى العادية معامل تحديد متعدد ، R^2 ، وهو نسبة مجموع المربعات الكلي الذي تفسره جميع المتغيرات المستقلة معاً .

مسائل السببية في الانحدار المتعدد

يُعد الانحدار المتعدد تقنية فعالة . لكنه لا يستطيع حل المشكلات الكامنة في البيانات أو التفكير الدقيق في السببية . لتوضيح ذلك ، دعونا نعود إلى مشكلة التعدد الخطي ، التي طُرحت بإيجاز في بداية هذا الفصل . تذكر البيانات الواردة في الجدول 4.2 (الفصل 4)، المأخوذة من فيسر (1979؛ 1980). كانت المشكلة تكمن في تحديد أسباب التباين في الكثافة الزراعية . الكثافة هي نفقات رأس المال والعمالة لكل فدان من الأراضي الزراعية . ووفقاً للنظرية الزراعية التقليدية ، فإن المقاطعات الأبعد عن سوق المنتجات الزراعية ينبغي أن تكون كثافة الإنتاج أقل نظراً لضرورة إنفاق المزيد على تكاليف النقل وتكاليف الزراعة بشكل أقل . ومع ذلك ، فإن الخصوبة هي العامل الأكثر أهمية على كثافة الإنتاج ، والتي يمكن قياسها بمتوسط هطول الأمطار السنوي ، وطول موسم النمو، ونوع التربة . مع زيادة كثافة الإنتاج ، تكون الزيادة في الغلة أكبر في الأراضي الأكثر خصوبة .

لذلك ، يجب التحكم في تأثير الخصوبة على كثافة الإنتاج لمعرفة ما إذا كان هناك تأثير مستقل للمسافة إلى السوق على كثافة الإنتاج . ولكن ما يزيد الأمور تعقيداً هو أن المقاطعات الأبعد عن السوق تشهد أيضاً أقل معدل لهطول الأمطار في المتوسط . هناك علاقة عكسية وثيقة بين المتغيرين . من المرجح أن يؤدي انخفاض هطول الأمطار وارتفاع تكاليف النقل إلى تقليل كثافة الإنتاج ، ولكن ما هي التأثيرات المستقلة النسبية للمتغيرين ؟ ترتبط المسافة وهطول الأمطار ارتباطاً وثيقاً ، بحيث لا يوجد سوى تباين ضئيل في المسافة وكثافة الإنتاج مستقل عن هطول الأمطار . نظراً للدرجة العالية من التعدد الخطي ، لا يمكن للانحدار المتعدد أن يخبرنا ما إذا كان هطول الأمطار أم المسافة هو المؤثر على الشدة . تتباين المتغيرات بشكل وثيق لدرجة أنه لا يمكن فصل آثارها المستقلة ، خاصةً على النطاق الجغرافي الصغير للدراسة . ولجميع الأغراض ، فهي متغير واحد ونفس الشيء.

يمكن أن تنشأ مشكلة أخرى إذا تم استبعاد المتغيرات المستقلة ذات الصلة من التحليل . في هذه الحالة ، قد لا تكون معاملات الانحدار الجزئي صحيحة ، بمعنى أنه لم يتم اكتشاف التأثير المستقل لمتغير X على متغير Y . هذه هي مشكلة التحديد (أو التحديد الخاطئ)، والتي تُعد المتغيرات المفقودة جزءًا منها . تُعد المتغيرات المفقودة مشكلة مهمة للغاية ومُتجاهلة في محاولة إثبات السببية بين X و Y ، لأن إدخال متغير تم استبعاده سابقًا من التحليل قد يتسبب في تحول العلاقة بين X و Y معينين بشكل كبير . على سبيل المثال ، في حالة الارتباط الزائف ، قد يكون لمتغير محذوف ارتباط مشترك مع كل من X و Y ، والأهم من ذلك ، قد يكون سببًا للتباين المشترك في كلا المتغيرين . قد تؤدي إضافة المتغير المستقل الجديد ، المفقود سابقًا ، إلى اختفاء العلاقة بين Y وأحد متغيري X ، حيث أصبح الآن مسؤولاً عن التباين في كليهما . في حالات أخرى ، حيث لا يوجد ارتباط بين متغيرين ، قد يظهر ارتباط إذا تمت إضافة متغير جديد .

الافتراضات

بموجب قيمة معينة لمعلمة مجتمع (سواء كانت معروفة أو مفترضة) ، توفر الإحصاءات الاستدلالية احتمال أن تكون إحصائية العينة ، المحسوبة لعينة عشوائية مأخوذة من هذا المجتمع ، أكبر من أو أقل من قيمة معينة . لا تثبت هذه الإحصاءات أو تدحض أو تفسر أي شيء : إنها تشير فقط إلى مدى احتمالية الحصول على نطاق من قيم إحصائية العينة بهذا الحجم إذا كان لمعلمة المجتمع قيمة معينة . ولكن في الوقت نفسه ، تُعد اختبارات احتمالية أن تكون إحصائية مُقدّرة ، مثل معامل الانحدار ، ذات قيمة معينة (مثل $0 \neq$) بالغة الأهمية في تقييم قوة العلاقات ، ولهذا السبب نهتم بها . إذا كان احتمال حدوث إحصائية محسوبة بحجم معين منخفضًا للغاية بمجرد أخذ عينة عشوائية من مجتمع لا توجد فيه علاقة ، فإننا نكون واثقين إلى حد ما من القول بوجود علاقة .

ومع ذلك ، يتطلب استخلاص استنتاجات إحصائية في الانحدار معالجة افتراضات معينة . ولكن ، في كثير من الأحيان ، لا يتحقق الباحثون لمعرفة ما إذا كان الافتراضات المتعلقة بطبيعة البيانات مُتحققة بالفعل . ومن المؤكد أنها نادرًا ما تُبين ما إذا كانت الافتراضات مُتحققة ، ومن الخطأ افتراض ذلك ، لأن العالم الاجتماعي لا يوفر عادةً متغيرات ذات توزيعات متماثلة . كما سنرى ، لا ينبغي أن تكون هناك قيم كبيرة أو صغيرة بشكل استثنائي لمتغير ، وعادةً ما تكون موجودة . لذلك ، يُمكن النظر إلى العديد من العلاقات المذكورة في أدبيات العلوم الاجتماعية بعين الشك . وعلى وجه التحديد ، تتضمن اختبارات الدلالة الإحصائية للانحدارات الخطية عدة افتراضات . في حالة انتهاك هذه الافتراضات ، تُصبح الاختبارات الإحصائية المرتبطة بها غير صالحة .

تشمل هذه الافتراضات : يجب أن يكون لبقايا الانحدار e_i أو $Y_i - \hat{Y}_i$ توزيع طبيعي تقريبيًا ؛ يجب ألا تكون هناك قيم شاذة ؛ يجب أن يكون تباين المتبقيات ثابتًا نسبيًا لجميع قيم المتغير المستقل ؛ ويجب تحديد النموذج بشكل صحيح على أنه خطي ؛ ويجب أن تكون المتبقيات مستقلة عن بعضها البعض (لا يوجد ارتباط ذاتي) . إذا كان لكلا المتغيرين أو أحدهما توزيع منحرف ، فستميل هذه الافتراضات إلى الانتهاك . تجانس التباين هو الحالة التي يميل فيها تباين قيم Y إلى أن يكون هو نفسه لجميع قيم X . غالبًا ، في علاقة موجبة بين متغيرين ، تميل قيم Y الأعلى إلى التباين بشكل أكبر عند قيم X الأعلى . وهذا ما يسمى تباين التباين . يميل مخطط التشتت للباقيات مقابل قيم X إلى أن يكون له شكل مكبر صوت أو قمع .

بما أن الانحدار الخطي يقلل من مجموع مربعات أخطاء الانحدار ، فإن القيم الأعلى القليلة لـ Y و X سيكون لها تأثير أكبر من قيم المتغيرات الأصغر على موضع خط الانحدار . أي أن موقع خط الانحدار يصبح

أكثر اعتمادًا على عدد قليل من الملاحظات ، وبالتالي أقل موثوقية ، مما يُبطل اختبار الدلالة . القيمة الشاذة هي عندما يكون المتبقي لملاحظة كبيرة بشكل استثنائي . قد يكون أكثر من ثلاثة أخطاء معيارية من خط الانحدار ، ولأن الانحدار يقلل من مجموع مربعات الأخطاء حول الخط ، فقد يكون لملاحظة واحدة أو اثنتان فقط تأثير كبير على موضع الخط . يوضح الشكلان 18.2 و 18.3 كيف يمكن لملاحظة واحدة أن تنفي وجود علاقة خطية قوية بين متغيرين . يوضح الشكل 18.2 علاقة وثيقة بين X و Y . معامل الارتباط مرتفع جدًا عند 0.905 و يُظهر تحليل الانحدار دلالة إحصائية (لم تُناقش تفاصيل هذه الاختبارات هنا؛ انظر روجرسون 2006) . في الشكل 18.3 ، أُضيفت إلى البيانات نفسها ملاحظة متطرفة $X = 23$ ، $Y = 1$.




Figure 18.3 The effect of an outlier




Figure 18.4 The problem of skew

وقد غيّرت هذه الملاحظة المفردة موقع الخط بشكل كبير، وانخفض معامل الارتباط إلى 0.407 . واستنادًا إلى الاختبارات الإحصائية التي أُجريت (لم تُذكر هنا) ، لن نتمكن من استنتاج أن العينة قد أخذت من مجتمع توجد فيه علاقة خطية بين المتغيرات . ولكن ، من الواضح أن هناك علاقة خطية ، باستثناء القيمة المتطرفة . فقد ألغت ملاحظة واحدة تمامًا علاقة جيدة جدًا . عندما تكون X تساوي 23 ، تتنبأ المعادلة $\hat{Y} = 5.174 + 0.279X$ بأن قيمة Y يجب أن تكون 11.591 . القيمة الفعلية لـ Y هي 1؛ لذا ، فإن الخطأ المعياري هو 3.15 من خط الانحدار (كان 3.36 في تحليل الانحدار الثاني) . قيمة كبيرة كهذه تُعد ، بحكم التعريف ، قيمة متطرفة . سيكشف رسم بياني للأخطاء - وهو المعيار في معظم الحزم الإحصائية - أنها لا تتبع توزيعًا طبيعيًا ، وبالتالي فإن اختبار الدلالة الإحصائية غير صحيح . ومن المثير للاهتمام أن هذه القيمة

المتطرفة ليست نتيجة انحراف حاد في أي من متغيري X أو Y ؛ بل هي ناتجة عن توليفتهما الخاصة (X كبير، Y صغير جدًا).

تشير هذه النتيجة إلى أهمية النظر في توزيع تكراري للبقايا لتحديد ما إذا كان افتراض الانحدار قد انتهك . يجب عدم استبعاد القيم المتطرفة لمجرد أنها كذلك ، فهذا يُعد تزيفًا للبيانات . ومع ذلك ، فإن ما يجب فعله حيالها يتجاوز نطاق هذا الفصل . يُقدّم هذا المثال للتأكيد ببساطة على أهمية التحقق من افتراضات الاختبار الإحصائي . يمكن للانحراف الشديد في أحد المتغيرين أو كليهما أن يُنشئ علاقات حيث لا توجد ، أو ينفي علاقة حيث توجد . يوضح الشكل 18.4 الحالة الأولى . حيث تُكتشف علاقة قوية بسبب ملاحظة واحدة ، حيث لا ينبغي أن تكون هناك علاقة . كلا المتغيرين في الشكل 18.4 لهما انحراف يميني شديد ، ويحدث أن تكون للملاحظة نفسها ($Y = 17$ ، $X = 23$) قيمة كبيرة بشكل استثنائي لكلا المتغيرين.

هذه الملاحظة ليست قيمة شاذة ، لأنها قريبة جدًا من خط الانحدار (0.783 خطأ معياري أسفل الخط) . لن يكشف الرسم البياني التكراري للبقايا عن توزيع غير طبيعي . ولكن التوزيع التكراري لكل متغير (كما هو موضح في الفصل 17) سيُظهر الانحراف . عند استبعاد الملاحظة المفردة ، تكون قيمة r تساوي 0 . وعند تضمينها ، تكون القيمة 0.675 . إذا لم يتم التحقق من افتراضات الانحدار ، فستستنتج أنك اكتشفت علاقة قوية . يوضح المثال التالي (الشكل 18.5) كيف يمكن للانحراف الشديد في متغير X أن ينفي علاقة خطية قوية بين متغيرين .




Figure 18.5 Another case of skewness

مرة أخرى، خلق المثال مشكلة مع ملاحظة واحدة فقط ، ومرة أخرى ، قد لا يتم الكشف عن ملاحظة المشكلة كقيمة شاذة . على الرغم من أن الرسم التوضيحي يُظهر انحرافًا يمينيًا في متغير X ، إلا أنه يمكن تخيل كيف يمكن للانحراف الشديد لليساير في X أن ينفي أيضًا علاقة خطية قوية بين متغيرين . للعلاقة في الشكل 18.5 قيمة r تساوي 0.142 ، وتحليل الانحدار ليس ذا دلالة إحصائية . إذا غابت الملاحظة عند $X = 25$ ، يرتفع r إلى 0.955 ، وهو أمر بالغ الأهمية بالطبع . يلزم رسم بياني ترددي للبقايا للكشف عن هذا النوع من التأثير ، على الرغم من أنه واضح هنا في مخطط التشتت الأصلي . تُفيد مخططات التشتت أيضًا في الكشف عن العلاقات غير الخطية ؛ إذ يُمكن رسم قيمتي Y و X بشكل فردي ، أو يُمكن رسم كل قيمة متبقية مقابل كل قيمة X في انحدار متعدد . العلاقات غير الخطية شائعة في العلوم الطبيعية والاجتماعية ، لذا تُعدّ هذه تمارين مهمة . يظهر التأثير في الشكل 18.6 . هنا ، لا يُظهر الانحدار الخطي (الموضح بالخط المنقطع) أي علاقة . ومع ذلك ، توجد علاقة خطية منحنية ممتازة تُوصف بمعادلة تربيعية . للعلاقة التربيعية $r^2 = 0.627$ معاملات الانحدار لكل من X و X^2 معنوية . سيؤدي عدم رسم البيانات إلى استنتاج عدم وجود علاقة بين المتغيرين، بينما في الواقع ، لا توجد علاقة خطية.

هناك حلول متنوعة لتعديل البيانات عندما لا تُلبى الافتراضات اللازمة لاختبار دلالة العلاقات الخطية . العديد من المتغيرات في العلوم الاجتماعية لها انحراف يميني . غالبًا ما يؤدي أخذ لوغاريتم المتغير، ثم انحدار القيم اللوغاريتمية مقابل متغير آخر ، إلى إزالة الانحراف يميني . يُسمى هذا تحويل المتغير، وهو مقبول تمامًا ، على الرغم من أنه سيغير طبيعة العلاقة . على سبيل المثال ، يُنتج انحدار اللوغاريتم الطبيعي لـ Y مقابل اللوغاريتم الطبيعي لـ X المعادلة الخطية التالية:

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_1^2 \quad (18.9)$$

يصف هذا في الواقع علاقة منحنية بين المتغيرين الأصليين من الشكل وأخيرًا، يُفترض أن تكون البقايا مستقلة عن بعضها البعض (غير مرتبطة ذاتيًا). مع الأخذ في الحسبان التباين (أي محتوى المعلومات) الذي تحتويه هذه المقاييس كقيم e_i (أي، $Y_i - \hat{Y}_i$)، يتضح كيف يمكن انتهاك هذا الافتراض بسهولة باستخدام البيانات المكانية . على وجه التحديد ، تمثل قيم e_i البيانات الأصلية " Y_i " المزالة من (أو المُرعاة لـ) التأثيرات التفسيرية لجميع X s في نموذج الانحدار . وبالتالي ، لا يمكن أن تحتوي إلا على أربعة أنواع من المعلومات :

- (أ) التباين العشوائي غير المُراعى الذي كان موجودًا في متغير Y الأصلي؛
- (ب) معلومات من التحديدات الخاطئة الموجودة في النموذج (مثل التأثيرات غير الخطية مثل تلك الموضحة في الشكل 18.6)؛
- (ج) معلومات المتغير المفقودة في Y_i التي لم يلتقطها النموذج؛ أو
- (د) نوع من الترابط المكاني في الملاحظات Y_i التي وجدت طريقها إلى e_i لأنها لم تُحذف من النموذج.




Figure 18.6 Specifying the relationship

هذا التبعية الأخيرة ، التي عُرضت سابقًا باسم الارتباط الذاتي المكاني ، تُمثل انتهاكًا لافتراضات الانحدار. أسهل طريقة لاكتشافها هي رسم خريطة للبقايا من تحليل الانحدار. إذا وجدت أن البقايا الإيجابية (فوق الخط) تتجمع جغرافيًا ، بينما ترتبط البقايا السلبية أيضًا مكانيًا ، فهناك دليل على وجود ارتباط ذاتي مكاني . يمكن أن تنتج البقايا المرتبطة ذاتيًا عن أنماط مكانية لمتغيرات مفقودة ، أو عن آثار انتشار حقيقية ناجمة عن عدم التزام العمليات المكانية بحدود وحدات الرصد . في كلتا الحالتين ، تحتوي البقايا المرسومة على معلومات مهمة . العلاقة التي يمكن أن تؤثر على السببية . كان الجغرافيون في طليعة من تناولوا الارتباط الذاتي المكاني ، عادةً من خلال محاولة تحديد التأثير وإزالته من خلال إجراءات إحصائية متقدمة (أنسلين وآخرون، 2004).

الخلاصة

سعى هذا الفصل إلى تزويدك بفهم لمشاكل قياس التأثيرات أو الأسباب المستقلة لمتغير على آخر. وقد أغفل الكثير، لا سيما تفاصيل اختبار الفرضيات، والاحتمالية، والدلالة. في هذه المواضيع، الهدف هو تحديد ما إذا كان بإمكانك استنتاج أن العلاقة بين متغيرين موجودين في عينة عشوائية من البيانات تعكس علاقة في مجموعة الملاحظات التي استخرجت منها تلك العينة. تتضمن الاختبارات البارامترية القوية، التي تُمكنك من إجراء هذه الاستدلالات، العديد من الافتراضات التي يجب التحقق منها. لا تتضمن الاختبارات غير المعلمية افتراضات حول توزيعات المتغيرات، ولكنها ليست بنفس القوة، ولا تتضمن جميع المعلومات التي قد تكون موجودة في البيانات.

تنظر العلوم الطبيعية، دون خجل، إلى العلوم الاجتماعية على أنها العلوم الناعمة. أسباب السلوكيات الفردية أو الجماعية معقدة للغاية، والعلاقات التي تُقدم دليلاً على السبب غالباً ما تكون غير قابلة للقياس المباشر، أو لا يمكن التحكم في التأثيرات الأخرى على متغير تابع من خلال المنهج التجريبي. حتى في المنهج التجريبي، من السهل تشويه النتائج، ولا يمكننا معرفة ما إذا كانت العلاقة الموجودة في تجربة معملية ستكون مستقرة خارج المختبر. في الأبحاث غير التجريبية، قد تكون الارتباطات زائفة أو عرضية. قد لا يتم العثور على علاقة مفترضة لأن الباحث لم يضبط متغيراً يكبت العلاقة المستقلة بين المتغيرين المعنيين. وحتى عندما تقتنع الأغلبية بوجود علاقة، وأنها سببية، وأنها دائمة، نجد أنها ليست كذلك. فمعظم العلاقات الاجتماعية غير مستقرة فيما يتعلق بالزمن والسياقات الأخرى، مثل المكان أو الثقافة (الملحق 18.1). في بعض الأحيان، يمكن قياس هذه السياقات كمتغيرات، ولكن في كثير من الأحيان لا يمكن ذلك. يستخدم الاقتصاديون مصطلح "ثبات العوامل الأخرى"، أي ثبات جميع العوامل الأخرى، للدلالة على أنهم يتحدثون عن التأثير المستقل لمتغير على آخر. وللأسف، ليس هذا عالمًا تستقر فيه العوامل الأخرى. فلم تأخذ علاقاتهم في الحسبان جميع التأثيرات الأخرى، وليست حتمية، وليست صحيحة في جميع الأوقات (فهي ليست مستقرة)، والثقافات، والسياقات الأخرى. وبالتالي، فإن الاعتماد على هذه العلاقات يؤدي إلى تنبؤات بالأحداث الاقتصادية المستقبلية، والتي هي في الواقع أقل دقة من التخمينات العشوائية. لا يُفهم الاستدلال الإحصائي أي بيانات حول السببية، بل يُشير فقط إلى احتمال وجود علاقة. ومن المسائل الأخرى ما إذا كان متغيرك المستقل يُسبب بالفعل تغير المتغير التابع.

التمرين 18.1

تقييم تحليل الانحدار المتعدد

خصص ساعة تقريباً لتصفح الصفحات الأخيرة من بعض المجالات ذات التوجه التجريبي في مجالات الجغرافي المفضل. ابحث عن أمثلة عملية على الانحدار المتعدد. من بين المجالات التي يمكنك الاطلاع عليها: الجغرافيا التطبيقية، والجغرافيا المكانية، والجغرافيا الاقتصادية، والجغرافيا الطبيعية (السلسلة أ)، والجيومورفولوجيا، والمجلة الدولية لجغرافيا السكان، ومجلة الأرصاد الجوية التطبيقية وعلم المناخ، ومجلة جغرافيا النقل، والتقدم في الجغرافيا الطبيعية، والعلوم الاجتماعية والطب، والجغرافيا الحضرية، والجغرافي المحترف. لن يتضمن كل عدد بحثاً يستخدم الانحدار المتعدد، ولكنه تقنية شائعة بما يكفي لأنك ستجد في النهاية مقالاً يستخدم هذه التقنية. بمجرد العثور عليها، اقرأها وأجب عن الأسئلة الآتية:

- ما هي المتغيرات التابعة والمستقلة المستخدمة في التحليل؟
- هل استند اختيار المتغيرات إلى أساس نظري متين، أم كان الهدف استكشافياً أكثر؟

- ما هي الآثار السببية المحددة التي كان المؤلف (المؤلفون) يبحثون عنها؟
- هل هناك دليل على أن المؤلف (المؤلفين) أولوا اهتمامًا دقيقًا لجودة البيانات؟
- كم عدد النماذج التي يبدو أنها قُدرت خلال عملية البحث؟
- ما هي الافتراضات المتعلقة بالانحدار التي تمت مناقشتها؟ هل من الواضح أنه تم إجراء اختبارات لضمان عدم انتهاك الافتراضات؟
- ما هي النتائج الرئيسية؟ هل كانت هناك أية مفاجآت ظهرت من خلال التحليلات؟

الملحق 18.1

المعاملات المتغيرة مكانيًا

من المسائل الأخرى التي يجب معالجتها في تحليلات الانحدار استقرار العلاقات عبر الوحدات المكانية المختلفة . تخيل أنك تُجري انحدارًا لأكثر من 3000 مقاطعة في الولايات المتحدة . ثم تُقسّم هذه المقاطعات إلى ثلاث مناطق (مثل : الشمال ، والجنوب ، والغرب) وتُعيد إجراء الانحدار . هل تتوقع الحصول على نفس النتيجة ؟ يُقدّم التحليل الأول صورةً وطنيةً للعلاقات بين المتغيرات . تصف معاملات الانحدار الجزئي ما يحدث ، بالنسبة لـ X ، على مستوى البلد بأكمله . ولكن ماذا لو كانت هذه الصورة مجرد نظرة عامة على المعاملات التي تختلف في الواقع إقليميًا ؟ ألا ترغب في معرفة ما إذا كانت العلاقات بين متغيراتك تختلف عبر الوحدات المكانية في مجموعة بياناتك ؟ من المؤكد أن ذلك يتوافق مع فكرة أهمية الجغرافيا في تفسير العمليات .

هناك تقنيات طُوّرت لتقييم ما يُسمى "تباين المعلمات المكانية" (جونز ، ١٩٨٤) . تعتمد إحداها على "طريقة التوسيع" ، وهي نهج ابتكره الجغرافي إميليو كاسيتي (١٩٧٢) يدمج نماذج فرعية لمعاملات الانحدار ضمن نماذج الانحدار . في نهج التوسيع الذي طوره جونز (١٩٨٤) ، أُعيد تعريف المعلمات كدالة لإحداثيات سطح الاتجاه (السبر الديكارتي من الشمال إلى الجنوب في p ، q ، p_2 ، q_2 ، إلخ) . توفر هذه تقديرات على نطاق إقليمي لتباين المعلمات . هناك نهج آخر لتباين المعاملات ، طوره كاسيتي ، يُسمى "تحليل انجراف معاملات الانحدار" (DARP) (كاسيتي وجونز 1983؛ كاسيتي وكان 1999) . وفي هذا النهج ، تُختار نقطة مركزية ، وتُرجّح الوحدات المكانية في الانحدار وفقًا لبعدها عن هذه النقطة . وتُستبعد الملاحظات الأبعد عن نقطة الارتكاز ، وتكون النتيجة انحدارًا محليًا . وقد وسّع فوثرينغهام وآخرون (2000) نطاق DARP وشاع استخدامه تحت اسم "الانحدار الموزون جغرافيًا" .