

أخطاء توصيف النموذج: توصيف النموذج واختبارات التشخيص

لا يمكن تطبيق الاقتصاد القياسي بشكل آلي، فلا بد من فهم تداعيات الموقف والمهارات المتاحة.

عندما نعبّر جسراً ما لا يكون لدينا أي قلق من انهياره، نظراً للثقة الشديدة في المهندسين الذين قاموا بتصميم وبناء هذا الجسر. على الاقتصاديين أن يفعلوا الشيء ذاته في النماذج الاقتصادية، وإلا عليهم أن يلصقوا التحذير التالي بالنماذج المختارة "لا تستخدمه فقد ينهار بك!".

الاقتصاديون يبحثون عن "الحقيقة" على مرّ السنوات السابقة، على أساس أن الاقتصاديين أشخاص يبحثون عن قطة سوداء غير موجودة أصلاً في حجرة مظلمة، وبالتالي مستحيل أن يجدها.

أحد فروض نموذج الانحدار الخطي التقليدي (CLRM)، الفرض 9. إن نموذج الانحدار المستخدم في التحليل "صحيح" التوصيف، وإذا كان النموذج غير صحيح التوصيف، فإننا نتعرض إلى المشكلة المعروفة باسم "خطأ توصيف النموذج" أو "تحيز توصيف النموذج". في هذا الفصل، سنلقي الضوء على مثل هذا الفرض، لأن البحث عن النموذج الصحيح يشبه البحث عن Grail المقدس. بالتحديد سنناقش الأسئلة التالية (جوجاراتي، 2015 صفحة 649):

1. كيف يمكن للباحث تحديد النموذج "الصحيح"؟ أو بمعنى آخر، ما هي الأدوات التي يمكن استخدامها لتحديد النموذج المناسب للتحليل التطبيقي؟
2. ما هي أخطاء توصيف النموذج المحتملة عند التطبيق؟
3. ما هي عواقب أخطاء التوصيف؟
4. كيف يمكن للباحث أن يكتشف خطأ التوصيف؟ أو بمعنى آخر ما هي بعض أدوات التشخيص التي يمكن للباحث أن يستخدمها؟
5. إذا كانت هناك أخطاء في التوصيف، ما هي الأساليب العلاجية الممكن استخدامها وما هي فوائدها؟
6. كيف يمكن تقييم أداء النماذج المنافسة؟

موضوع توصيف النموذج وتقييمه يعتبر موضوعاً متعدّد الأبعاد، وله العديد من التطبيقات. ليس ذلك فقط ولكن هناك فروق فلسفية وراء النماذج المختلفة في هذا الموضوع. بالطبع لن نستطيع أن نغطي كل ذلك في فصل واحد، ولكن نتمنى أن نلقي الضوء على بعض المواضيع الأساسية الخاصة بتوصيف النموذج وتقييمه.

1- معيار اختيار النموذج: MODEL SELECTION CRITERIA

بناءً على دراسة Richard و Hendry فإن المعايير التي يجب استيفائها لاختيار نموذج ما للتحليل التطبيقي هي كالتالي:

1. أن يكون في إطار البيانات المتاحة: أي لابد أن تكون التنبؤات المتوقعة من النموذج يمكن فعلياً ومنطقياً الحصول عليها.

2. الاتساق مع النظرية: فلا بد أن يكون هناك معنى منطقي اقتصادي، فمثلاً إذا تحقق فرض الدخل الدائم لمـ Milton Friedman's فإن قيمة الجزء الثابت المقطوع من المحور **الصادي** في الانحدار الخاص بالاستهلاك الدائم على الدخل الدائم يجب أن يساوي الصفر.

3. المتغيرات المنحدرة تكون غير مترابطة: أي أن المتغيرات المفسرة أو المنحدرة يجب ألا تكون مرتبطة مع حد الخطأ.

4. اتساق المعالم: بمعنى أن قيم المعالم يجب أن تكون مستقرة. وإلا سيكون التنبؤ صعباً. فكما قال Friedman: "اختبار صلاحية النموذج الافتراضي الأفضل هو مقارنة تنبؤات النموذج بالواقع". في غياب اتساق المعالم لا يكون مثل هذا التنبؤ موجوداً.

5. ترابط البيانات: أي أن البواقي المقدرة من النموذج، يجب أن تكون عشوائية تماماً. بمعنى آخر إذا كان النموذج المختار مناسباً فإن بواقي هذا النموذج يجب أن تكون عشوائية تماماً **white noise** وإذا لم تكن كذلك، فإن هناك خطأ توصيف في النموذج. وسنناقش لاحقاً طبيعة أخطاء التوصيف.

6. النموذج الشامل: فيكون النموذج شاملاً عندما تكون قادراً من خلاله على توضيح نتائج باقي النماذج المحتملة. أي باختصار النماذج الأخرى لا تقدم أي جديد بعد اختيارك للنموذج الشامل.

أحيانا نختار معياراً ما للنموذج " الجيد" ونهمل معياراً آخر حتى نستطيع تكوين النموذج فعلياً، وبالتالي غالباً ما يوجد خطأ توصيف في النموذج المختار عملياً، وسنناقش ذلك بالتفصيل في الفقرة القادمة (جواراتي، 2015 صفحة 650).

2.13-أنواع أخطاء التوصيف :TYPES OF SPECIFICATION ERRORS

افترض أنه وفقاً للمعايير السابق ذكرها، **اخترنا** النموذج التالي كنموذج جيد. وافترض أن هذا النموذج يمكن كتابته كالتالي:

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \beta_4 X_i^3 + u_{1i} \dots \dots \dots (1.2.13)$$

حيث Y : إجمالي تكلفة الإنتاج و X : الناتج. المعادلة (1) تعتبر مثلاً شهيراً في كتب الاقتصاد، وتسمى دالة التكلفة الكلية التكميلية.

ولكن افترض أنه لأسباب ما (مثلاً شكل الانتشار) اختار باحث آخر النموذج التالي:

$$Y_i = \alpha_1 + \alpha_2 X_i + \alpha_3 X_i^2 + u_{2i} \dots \dots (2.2.13)$$

لاحظ أننا غيرنا الرموز حتى نستطيع التفرقة بين هذا النموذج والنموذج الصحيح.

بما أن (1.2.13) يفترض صحته، فإن (2.2.13) سيكون قيمة خطأ توصيف، والخطأ الموجود هنا هو حذف متغير مهم في النموذج وهو (X_i^3) وبالتالي فإن حد الخطأ u_{2i} في (2.2.13) سيكون في الحقيقة كالتالي:

$$u_{2i} = u_{1i} + \beta_4 X_i^3 \dots \dots \dots (3.2.13)$$

سنوضح لاحقاً أهمية هذه العلاقة.

والآن افترض أن باحثاً آخر اختار النموذج التالي:

$$Y_i = \lambda_1 + \lambda_2 X_i + \lambda_3 X_i^2 + \lambda_4 X_i^3 + \lambda_5 X_i^4 + u_{3i} \dots \dots \dots (4.2.13)$$

إذا كان (1.2.13) صحيحاً فإن (4.2.13) يوجد فيه أيضاً خطأ توصيف. هذا الخطأ هو إضافة متغير غير ضروري وغير مهم للنموذج، وذلك حيث إنه في النموذج الصحيح يفترض أن تكون 15 تساوي الصفر. وبناءً على ذلك يكون حد الخطأ في الحقيقة كالتالي:

$$u_{3i} = u_{1i} - \lambda_5 X_i^4 \dots \dots \dots (5.2.13)$$

$$= u_i \text{ since } 15 = 0 \text{ in the true model (لماذا؟)}$$

والآن افترض أن باحثاً آخر اختار النموذج التالي:

$$\ln Y_i = \gamma_1 + \gamma_2 X_i + \gamma_3 X_i^2 + \gamma_4 X_i^3 + u_{4i} \dots \dots \dots (6.2.13)$$

بالتالي بالنسبة للنموذج الصحيح، فإن هناك تحيزاً في توصيف النموذج السابق، هذا التحيز يرجع إلى استخدام شكل دالة غير صحيح: ففي (1.2.13) تكون Y خطية، بينما في (13.6.2) تظهر في صورة لوغاريتمية خطية.

وأخيراً افترض أن باحثاً آخر اختار النموذج التالي:

$$Y_i^* = \beta_1^* + \beta_2^* X_i^* + \beta_3^* X_i^{*2} + \beta_4^* X_i^{*3} + u_i^* \dots \dots \dots (7.2.13)$$

حيث $Y_i^* = Y_i + \varepsilon_i$ و $X_i^* = X_i + w_i$ وبالتالي فإن ε_i و w_i فإن الباحث استخدم Y_i و X_i الصحيحة فإن الباحث استخدم Y_i^* و X_i^* والتي تشتمل على حدود أخطاء. وبالتالي في (7.2.13) يوجد خطأ توصيف.

في الواقع العملي تكون البيانات بها أخطاء راجعة للتقريب أو أخطاء راجعة إلى عدم التغطية الكاملة للدراسة أو ببساطة أخطاء لحذف بعض المفردات. العلوم الاجتماعية تعتمد عادة على البيانات الثانوية، ولا تكون لدينا وسيلة لمعرفة أنواع الأخطاء المحتملة، والتي تقوم بها المؤسسة التي جمعت البيانات الأولية.

أحد أنواع أخطاء التوصيف يعتمد على طريقة إدخال الخطأ العشوائي u_i (أو u_t) إلى النموذج. فعلى سبيل المثال، اعتبر نموذج الانحدار ثنائي المتغيرات غير المشتمل على جزء ثابت كالتالي:

$$Y_i = \beta X_i u_i \dots \dots \dots (8.2.13)$$

حيث إن الخطأ العشوائي موجود في صورة مضروب، ويكون u_i مستوفيًا لفروض CLRM،

$$Y_i = \alpha X_i + u_i \dots \dots \dots (9.2.13)$$

وهنا يضاف حد الخطأ، على الرغم من أن المتغيرات لم تختلف في النموذجين إلا أننا نلاحظ أن معامل الميل في (8.2.13) هو النموذج الصحيح أو "الحقيقي" فهل α المقدرة تعتبر مقدارًا غير متحيز لـ β الحقيقية؟ أي هل ستكون $E(\hat{\alpha}) = \beta$ ؟ إذا لم يتحقق ذلك، يكون هناك خطأ في توصيف حد الخطأ العشوائي، والذي يعتبر أحد مصادر أخطاء التوصيف، وبالتالي لتجميع كل الملاحظات السابقة والخاصة بتكوين نموذج تطبيقي لتوصيف البيانات، فمن الممكن أن يقع الباحث في أحد أخطاء التوصيف التالية (جوجاراتي، 2015 صفحة 654):

1. حذف واحد أو أكثر من المتغيرات المهمة.

2. إضافة واحد أو أكثر من المتغيرات غير المهمة.

3. استخدام شكل دالة خاطئ.

4. أخطاء القياس.

5. توصيف غير سليم لحد الخطأ العشوائي.

قبل البدء في اختيار هذه الأنواع من أخطاء التوصيف بالتفصيل، يجب التفرقة بين أخطاء توصيف النموذج وأخطاء التوصيف غير الصحيح للنموذج. فالأنواع الأربعة الأولى السابقة أساسية في تحديد طبيعة أخطاء توصيف النموذج، حيث إن لدينا بشكل ما تحديدًا للنموذج، الصحيح، ولكن لأسباب ما لا نقدره. في أخطاء التوصيف غير الصحيح للنموذج، لا نعرف طبيعة النموذج الصحيح حتى نأخذ كخطوة مبدئية. وهنا يمكن أن

يسترجع القارئ التعارض بين الكينزيين والنقديين. فالنقديون يعطون أولوية أساسية للمال في تفسير التغير في GDP في حين أن الكينزيين يهتمون أكثر بدور الحكومة في تفسير التغير في GDP، وبالتالي هناك نموذجان متنافسان.

في المثال التالي، سنعتبر مبدئيًا أخطاء توصيف النموذج، ثم اختيار أخطاء التوصيف غير السليم للنموذج.

3- عواقب أخطاء توصيف النموذج: CONSEQUENCES OF MODEL SPECIFICATION ERRORS

بغض النظر عن مصدر أخطاء التوصيف ما هي العواقب؟ لتبسيط المناقشة، ستتم الإجابة على السؤال السابق في إطار نموذج الانحدار ثلاثي المتغيرات، وسنهتم بأول مصدرين للأخطاء **التوصيفة** السابق مناقشتها وهي بالتحديد: (1) توصيف النموذج بعدد من المتغيرات أقل من العدد الصحيح، أي أن هناك حذفًا لمتغير أو أكثر من المتغيرات المهمة بالنموذج و(2) توصيف النموذج بعدد من المتغيرات أكثر من العدد الصحيح، أي أن هناك إضافة لمتغير أو أكثر غير مهم بالنموذج. ناقشنا الحالية من الممكن بسهولة أن يتوسع نطاقها لتشمل أكثر من ثلاثة متغيرات بنموذج الانحدار، ولكنها تحتاج إلى مهارات جبرية، واستخدام جبر المصفوفات يصبح ضرورة ملحة إذا وجد أكثر من ثلاثة متغيرات في نموذج الانحدار.

توصيف النموذج بأقل من الصحيح (حذف متغير مهم): Underfitting a Model (Omitting a Relevant Variable)

افترض أن النموذج الصحيح كالتالي:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \beta_3 X_{3i} + u_i \dots \dots \dots (1.3.13)$$

ولكن لأسباب ما استخدمنا النموذج التالي:

$$Y_i = \alpha_1 + \alpha_2 X_{2i} + v_i \dots \dots \dots (2.3.13)$$

عواقب حذف المتغير X_3 تكون كالتالي:

1. إذا كان المتغير المحذوف مرتبطًا مع المتغير الموجود بالنموذج X_2 ، وكان معامل الارتباط r_{23} بين المتغيرين لا يساوي الصفر، فإن $\hat{\alpha}_1$ و $\hat{\alpha}_2$ ستكون مقدرات متحيزة وغير متسقة أيضًا. وبالتالي يكون $E(\hat{\alpha}_1) \neq \beta_1$ و $E(\hat{\alpha}_2) \neq \beta_2$ وهذا التحيز لا يختفي بزيادة حجم العينة.

2. حتى إذا لم يكن X_2 ، و X_3 ، مرتبطين فإن $\hat{\alpha}_1$ سيكون متحيزاً على الرغم من أن $\hat{\alpha}_2$ الآن سيكون غير متحيز.

3. مقياس التباين التقليدي ل $\hat{\alpha}_2 (= \sigma^2 / \sum x_{2i}^2)$ سيكون مقدراً متحيزاً لتباين المعلمة الحقيقية β_2 .

4. من توابع ذلك أيضاً أن تكون فترات الثقة اختبارات الفروض غير سليمة، وتؤدي إلى استنتاجات خاصة بمعنوية المعالم المقدرة خاطئة.

5. أحد العواقب المهمة أيضاً أن التنبؤ بناءً على النموذج غير الصحيح ستكون مضللة وغير سليمة، وأيضاً فترات الثقة المتنبأ بها.

بالطبع إثبات كل نقطة من النقاط السابقة يأخذنا بعيداً عن إطار هذا الكتاب. إلا أننا استعرضنا في الملحق A13، الفقرة 1.A13 التالي:

$$E(\hat{\alpha}_2) = \beta_2 + \beta_3 b_{32} \dots \dots \dots (3.3.13)$$

حيث b_{32} هو ميل الانحدار الخاص بالمتغير المحذوف X_3 على المتغير الموجود في النموذج $(b_{32} = \sum x_{3i}x_{2i} / \sum x_{2i}^2)X_2$ كما يتضح من (3.3.13) فإن $\hat{\alpha}_2$ مقدراً متحيزاً إلا إذا كان β_3 أو b_{32} أو كلاهما يساوي الصفر.

وقد أشرنا من قبل إلى أنه إذا كانت β_3 تساوي الصفر، فإنه لا يوجد في الأساس خطأ توصيف. المعامل b_{32} سيساوي الصفر إذا كان X_2 و X_3 غير مرتبطين. وهذا نادر الحدوث في أغلب البيانات الاقتصادية.

عموماً مقدار التحيز سيعتمد على حد التحيز b_{32} ، فإذا كان على سبيل المثال، β_3 موجبة (أي أن X_3 له تأثير طردي على Y) و b_{32} موجب (أي أن X_2 و X_3 مرتبطتين طردياً) فإن $\hat{\alpha}_2$ ، في المتوسط ستقدر بأعلى من قيمتها الحقيقية (أي تحيز موجب). وهذه النتيجة متوقعة، حيث إن X_2 لا تمثل فقط التأثير المباشر على Y ، ولكن أيضاً التأثير غير المباشر (عن طريق X_3) على Y . باختصار X_2 ، و يظهر لها دور مؤثر في النموذج من خلال تأثير X_3 ، والذي لا يظهر له أثر مباشر لأنه غير "مسموح" له بالظهور في النموذج. كمثال تطبيقي دعنا نسترجع المثال السابق مناقشته في الفصل (7).

مثال توضيحي: ILLUSTRATIVE EXAMPLE

وفيات الأطفال (مرة أخرى): Child Mortality Revisited

يعمل انحدار وفيات الأطفال (CM) على GNP للفرد (PGNP) ومعدل الأمية لدى السيدات (FLR) حصلنا على نتائج الانحدار الموضحة في المعادلة (2.6.7). وفي هذه النتائج، نجد معاملات الميل الجزئية للمتغيرين هي -0.0056 و -2.2346 بالترتيب. ولكن إذا حذفنا متغير FLR، نحصل على النتائج المعطاة في المعادلة (2.7.7) إذا اعتبرنا أن (2.6.7) هو النموذج الصحيح، إذاً (2.7.7) يعاني من خطأ التوصيف، حيث إنه تم حذف متغير مهم وهو FLR. نرى الآن أنه في النموذج الصحيح معامل PGNP كان -0.0056 في حين أنه في النموذج "غير السليم" (2.7.7) كان -0.0114 .

باستخدام القيم المطلقة، نرى أن PGNP الآن له تأثير أكبر على CM مقارنة مع النموذج الصحيح. ولكن إذا قمنا بعمل انحدار — FLR على PGNP (انحدار للمتغير المحذوف على المتغير الباقي في النموذج). معامل الميل في هذا الانحدار (b_2 في المعادلة (3.3.13)) يساوي 0.00256 وهذا يعني أنه كلما زاد PGNP بوحدة واحدة فإنه في المتوسط تزداد FLIR بحوالي 0.00256 وحدة. ولكن إذا زادت FLR بثلاث وحدات فإن تأثير ذلك على CM يكون كالتالي (جوجاراتي، 2015 صفحة 659):

$$(-2.2316)(0.00256) = \hat{\beta}_3 b_{32} = -0.00543$$

وبالتالي من (3.3.13) لدينا في النهاية:

$$(\hat{\beta}_2 + \hat{\beta}_3 b_{32}) = -0.0056 + (-2.2316)(0.00256) \approx -0.0111$$

وهذه نفس القيمة تقريباً الخاصة بمعامل PGNP التي نحصل عليها من النموذج غير الصحيح (2.7.7).

كما يتضح من هذا المثال، التأثير الحقيقي لـ PGNP على CM أقل بـ (-0.0056) من الأثر المقترح

من النموذج غير الصحيح (2.7.7) والمساوي (-0.0114)

دعنا الآن نختبر تباينات $\hat{\alpha}_2$ و $\hat{\beta}_2$:

$$var(\hat{\alpha}_2) = \frac{\sigma^2}{\sum x_{2i}^2} \dots \dots \dots (4.3.13)$$

$$var(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2 (1 - r_{23}^2)} = \frac{\sigma^2}{\sum x_{2i}^2} VIF \dots \dots \dots (5.3.13)$$

حيث VIF (مقياس للتعدد الخطي) هو تباين معامل التضخم $(= 1/(1 - r_{23}^2))$ والذي سبق وناقشناه

في الفصل (10) و r_{23}^2 هو معامل الارتباط بين X_2 و X_3 . المعادلات (4.3.13) و (5.3.13) سبق

وتعرضنا لها في الفصلين 3 و 7.

بما أن المعادلات (4.3.13) و (5.3.13) غير متطابقة، فإنه في العموم تباين $(\hat{\alpha}_2)$ سيكون مختلفاً عن تباين $(\hat{\beta}_2)$. ولكننا نعلم أن $\text{var}(\hat{\beta}_2)$ غير متحيز (لماذا؟).

وبالتالي فإن $\text{var}(\hat{\alpha}_2)$ متحيز، وهذا يدعم ما سبق وذكرناه في النقطة (4) سابقاً.

بما أن $0 < r_{23}^2 < 1$ فإنه $\text{var}(\hat{\alpha}_2) < \text{var}(\hat{\beta}_2)$. وهنا لدينا مشكلة وهي كالتالي: على الرغم من أن $\hat{\alpha}_2$ مقدر متحيز، إلا أن تباينه أقل من تباين المقدّر غير المتحيز (بالطبع تم استبعاد الحالة التي يكون فيها $r_{23}^2 = 0$ ، بما أنه في الواقع يكون هناك بعض الارتباط بين المتغيرات المنحدرة) وبالتالي لابد من المفاضلة بين الأمرين السابقين.

الموضوع لم ينته عند هذا الحد، فالقيمة المقدرة لـ σ^2 من النموذج (2.3.13) والأخرى المقدرة من النموذج الصحيح (1.3.13) غير متساويين حيث إن RSS للنموذجين وكذلك درجات الحرية الخاصة بهما مختلفة. تذكر أننا حصلنا على تقدير لـ σ^2 كالتالي $\hat{\sigma}^2 = \text{RSS}/df$ وبالتالي فالتقدير يعتمد على عدد المتغيرات المنحدرة الموجودة في النموذج، بالإضافة إلى درجات الحرية (n ، عدد المعالم المقدرة). والآن إذا أضفنا متغيرات جديدة للنموذج، فإن RSS بوجه عام يقل (تذكر أنه كلما زاد عدد المتغيرات المضافة إلى النموذج، فإن R^2 يزداد ولكن درجات الحرية أيضاً تقل، حيث عدد المعالم المقدرة يزداد. المحصلة النهائية تعتمد على ما إذا كان RSS يقل بشكل كفاء أم لا مما يعوض مشكلة تقليل درجات الحرية الناتجة عن إضافة متغيرات منحدرة جديدة.

من المحتمل أنه مثلاً إذا كان لمتغير منحدر تأثير كبير على المتغير المنحدر عليه، فإنه يؤدي إلى تقليل RSS أقل من الخسارة في درجات الحرية كنتيجة لإضافة المتغيرات إلى النموذج. إضافة مثل هذا المتغير إلى النموذج لن يؤدي إلى تقليل التحيز فقط، وإنما سيزيد أيضاً من الدقة في التقدير (أي سيقبل الأخطاء المعيارية). على الجانب الآخر، إذا كان المتغير له تأثير محدود على المتغير المنحدر، وإذا كانوا مرتبطين بدرجة عالية (أي أن VIF كبير يمكننا تقليل التحيز في معاملات المتغيرات الموجودة فعلياً في النموذج، ولكن يزداد الخطأ المعياري لهم (أي سيكون أقل كفاءة).

بالطبع المفاضلة في هذه الحالة بين التحيز والدقة تكون مهمة وحيوية. وكما نرى من المناقشة السابقة، هذه المفاضلة ستعتمد على الأهمية النسبية للمتغيرات المنحدرة المختلفة.

يمكن أن نستنتج التالي من المناقشة السابقة: دعنا نعتبر الحالة الخاصة التي يكون فيها $r_{23} = 0$ أي أن X_2 و X_3 غير مرتبطتين. سيؤدي ذلك إلى أن يكون b_{23} يساوي الصفر (لماذا؟). وبالتالي نرى من

(3.3.13) أن $\hat{\alpha}_2$ الآن مقدر غير متحيز. ويبدو أيضًا من (4.3.13) و (5.3.13) أن تباينات $\hat{\alpha}_2$ و $\hat{\beta}_2$ متساوية.

هل لا يوجد أي ضرر من حذف المتغير X_3 من النموذج حتى وإذا كان مهمًا من الناحية النظرية؟ الإجابة بوجه عام هي لا. ولكن في هذه الحالة كما سبق وذكرنا، فإن $var(\hat{\alpha}_2)$ المقدر من (4.3.13) مازال متحيزًا وبالتالي اختبارات الفروض ستكون نتائجها غير موثوق فيها بالإضافة إلى أنه في العديد من الأبحاث الاقتصادية يكون X_2 و X_3 مرتبطين مما يؤدي إلى المشكلة السابق ذكرها.

وبالتالي، فالنقطة المهمة هنا هي: إذا تم تكوين النموذج على أساس نظري سليم، يكون حذف أي متغير من النموذج أمرًا لا ينصح به.

إدخال متغير غير ضروري في النموذج (توفيق النموذج بعدد من المتغيرات أكثر من المطلوب)

Inclusion of an Irrelevant Variable (Overfitting a Model)

دعنا الآن نفترض التالي:

$$Y_i = \beta_1 + \beta_2 X_{2i} + u_i \dots \dots \dots (6.3.13)$$

هو النموذج الصحيح، ولكننا استخدمنا النموذج التالي:

$$Y_i = \alpha_1 + \alpha_2 X_{2i} + \alpha_3 X_{3i} + u_i \dots \dots \dots (7.3.13)$$

وهذا يمثل خطأ توصيف ناتج عن إضافة متغير غير مهم إلى النموذج.

عواقب خطأ التوصيف السابق كالتالي:

1. مقدرات OLS لمعالم النموذج "غير الصحيح" تكون جميعها غير متحيزة ومتسقة. أي أن

$$E(\hat{\alpha}_3) = \beta_3 = 0 \text{ و } E(\hat{\alpha}_2) = \beta_2, E(\hat{\alpha}_1) = \beta_1$$

2. تباين الخطأ σ^2 مقدر بشكل سليم.

3. فترات الثقة العادية واختبارات الفروض سليمة.

4. عموماً مقدرات α_s ستكون غير كف، أي أن تباينها عموماً أكبر من نظيرها الخاص بـ $\hat{\beta}'_s$ للنموذج الصحيح.

إثبات بعض هذه النقاط موجود في ملحق A13 الفقرة 2A13. النقطة المهمة هنا هي الكفاءة النسبية

لـ $\hat{\alpha}'_s$ والتي يمكن توضيحها بسهولة كالتالي:

من الـ OLS التقليدية تعلم أن:

$$var(\hat{\beta}_2) = \frac{\sigma^2}{\sum x_{2i}^2} \dots \dots \dots (8.3.13)$$

$$var(\hat{\alpha}_2) = \frac{\sigma^2}{\sum x_{2i}^2(1-r_{23}^2)} \dots \dots \dots (9.3.13) \quad \text{و:}$$

$$\frac{var(\hat{\alpha}_2)}{var(\hat{\beta}_2)} = \frac{1}{1-r_{23}^2} \quad \text{وبالتالي:}$$

بما أن $0 \leq r_{23}^2 \leq 1$ ، يكون $var(\hat{\alpha}_2) \geq var(\hat{\beta}_2)$ أي أن تباين $\hat{\alpha}_2$ أكبر من تباين $\hat{\beta}_2$ وإن كان في المتوسط $\hat{\alpha}_2 = \hat{\beta}_2$ (أي أن $E(\hat{\alpha}_2) = \beta_2$) معنى هذه النتيجة أن إدخال متغير غير مهم مثل X_3 إلى النموذج جعل تباين $\hat{\alpha}_2$ أكبر من المفروض، وبالتالي قلت دقة $\hat{\alpha}_2$. وهذا ينطبق أيضاً على $\hat{\alpha}_2$.

لاحظ عدم التماثل بين نوعي الخطأ السابق ذكرهما من أخطاء التوصيف. فإذا حذفنا متغيراً مهماً وضرورياً، فإن معاملات المتغيرات الباقية في النموذج ستكون بوجه عام متحيزة وغير متسقة، وتباين الخطأ سيقدر بشكل غير سليم، واختبارات الفروض تكون غير سليمة على الجانب الآخر، إضافة متغير غير مهم أو غير ضروري إلى النموذج ستظل التقديرات غير متحيزة ومنسقة، وتباين الخطأ سيقدر بشكل سليم وكل خطوات ونتائج اختبارات الفرض التقليدية تكون سليمة. المشكلة الوحيدة لإدخال نموذج غير مهم إلى النموذج أن التباين المقدر للمعاملات سيكون أكبر من المفروض، وبالتالي كنتيجة لذلك استبدلنا الإحصائي عن المعالم سيكون له دقة أقل (جوجاراتي، 2015 صفحة 663).

وليس من المطلوب الآن أن تستنتج عزيزي القارئ أنه من الأفضل إضافة متغير غير مهم إلى النموذج عن حذف متغير مهم، حيث إن إضافة هذا المتغير غير المهم ستؤدي إلى خسارة في كفاءة المقدرات، وقد تؤدي إلى مشكلة التعدد الخطي (لماذا؟) بالإضافة إلى مشكلة تقليل درجات الحرية وبالتالي:

عموماً، الأسلوب الأفضل هو إضافة المتغيرات المفسرة إلى النموذج على أساس نظري، وتكون هذه المتغيرات مؤشرة بشكل مباشر على المتغير التابع وتأثيرها لا يكفي تضمينه في المتغيرات الأخرى الموجودة فعلاً في النموذج.

4.13 اختبارات لأخطاء التوصيف: TESTS OF SPECIFICATION ERRORS

معرفة عواقب أخطاء التوصيف تعتبر موضوعاً قائماً بذاته ومختلفاً عن اكتشاف خطأ التوصيف. في الأساس غالباً ما يظهر تحيز التوصيف بدون قصد أو بدون عمد. ويكون بسبب رغبتنا في تكوين نموذج دقيق

بأكبر قدر ممكن معتمدين على أن النظرية ضعيفة أو ليس لدينا البيانات الكافية لاختبار مثل هذا النموذج. وكما لاحظ Davidson نظراً للطبيعة غير القابلة للتجربة للاقتصاد، لا نستطيع الجزم بكيفية تجميع البيانات. **فاختبار** أي فرض في الاقتصاد يعتمد في الأساس على المزيد من الفروض التي تجعلنا قادرين على تكوين نموذج مناسب مع العلم بأن هذه الفروض قد تكون منطقية أو لا.

السؤال العملي الآن ليس عن تحليل وجود أخطاء التوصيف، ولكن الأهم هو كيف يمكن اكتشافها. فمجرد التأكد من حدوث خطأ في التوصيف، فإن طرق العلاج يمكن اتباعها لتجنب العواقب. فمثلاً العلاج الواضح لمشكلة خطأ التوصيف الناتجة عن حذف متغير مهم من النموذج هو إضافة هذا المتغير إلى النموذج مباشرة بعد التأكد من وجود بيانات خاصة به.

في الفقرة التالية، سنناقش بعض الاختبارات التي يمكن استخدامها لاكتشاف وجود خطأ التوصيف.

اكتشاف وجود متغير غير مهم في النموذج (توفيق النموذج بعدد من المتغيرات أكثر من المطلوب)

Detecting The Presence of Unnecessary Variables (Overfitting a Model)

افترض أن لدينا نموذجاً له متغير لتفسير ظاهرة ما كالتالي:

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + u_i \dots \dots \dots (1.4.13)$$

عموماً، نحن غير متأكدين من أن مثلاً، المتغير X_k فعلاً يجب أن يتواجد في هذا النموذج. أحد الطرق البسيطة لاكتشاف ذلك هو اختبار معنوية القيمة المقدرة لـ β_k باختبار t التقليدي $t = \hat{\beta}_k / se(\hat{\beta}_k)$. ولكن افترض أننا غير متأكدين من أهمية وجود X_3 و X_4 معاً في النموذج. يمكن اختبار ذلك مباشرة باختبار F السابق مناقشته في الفصل (8). وبالتالي اكتشاف وجود متغير غير مهم في النموذج ليس عملية صعبة.

ولكن من المهم تذكر أنه حتى يمكنك القيام بمثل هذه الاختبارات، يجب أن يكون هناك في الأساس نموذج للتعامل معه، فنحن نقبل هذا النموذج أولاً ثم نتعامل معه. وبالتالي، فإنه وفقاً لهذا النموذج يمكن تحديد ما إذا كان واحداً أو أكثر من المتغيرات المنحدرة غير مهم في النموذج باستخدام اختبارات t و F التقليدية.

ولكن لاحظ أننا لا نستخدم اختبارات t و F لبناء النموذج، فلا يجب أن نستنتج أن Y مرتبطة بـ X_2 مثلاً لأن $\hat{\beta}_3$ لها معنوية إحصائية ثم تبدأ في توسيع النطاق وإدخال X_3 للنموذج وإبقائه فيه إذا كانت $\hat{\beta}_3$ لها معنوية إحصائية وهكذا (جوجاراتي، 2015 صفحة 667).

فهذه الطريقة في بناء النموذج تسمى أسلوب الأعلى-الأسفل (حيث نبدأ بنموذج أصغر ويتسع نطاقه تدريجياً) أو تسمى أيضاً التقريب عن البيانات (مسميات أخرى مثل انحدار الأسماك، تجميع البيانات).

الهدف الأساس للتتقيب عن البيانات هو تكوين النموذج "الأفضل" بعد عمل العديد من اختبار التشخيص، وبالتالي يكون النموذج النهائي المختار هو نموذج "جيد" بمعنى أن كل المعاملات المقدرة لها الإشارة "الصحيحة" ولها معنوية إحصائية بناء على اختبارات t و F ، و، وقيمة R^2 تكون كبيرة بدرجة معقولة و Durbin Watson لها قيمة مقبولة (قريبة من 2) وهكذا. أما الجانب الفني الخاص بتطبيق تنقيب البيانات فنجد في مقولة William Pool التالية "... الاعتماد على التطبيق العملي بدلاً من تطبيق نظرية اقتصادية سيكون دائماً خطراً. أحد أسباب إدانة تنقيب البيانات كالتالي:

مستوى المعنوية الحقيقي والأسمى في حالة استخدام تنقيب البيانات

Nominal versus True Level of Significance in the Presence of Data Mining

خطر استخدام تنقيب البيانات والذي قد يواجهه الباحث هو مستوى المعنوية التقليدي (α) مثل 1، 5 أو 10% فلن يكون هو مستوى المعنوية الحقيقي. وقد اقترح Lovell أنه إذا كان هناك من المتغيرات المنحدرة وتم اختيار k كعدد نهائي ($k \leq c$) بناءً على أسلوب تنقيب البيانات، فإن مستوى المعنوية الحقيقي (α^*) مرتبط بمستوى المعنوية الاسمي (α) كالتالي:

$$\alpha^* = 1 - (1 - \alpha)^{c/k} \dots \dots (2.4.13)$$

$$\alpha^* = (c/k)\alpha \quad \text{أو تقريباً كالتالي:}$$

فمثلاً إذا كان $c = 15$ ، $k = 5$ و $\alpha = 5\%$ فمن (3.4.13) يكون مستوى المعنوية الحقيقي هو $15\% = (5/15) \cdot 5\%$. وبالتالي إذا استخدم الباحث تنقيب البيانات واختار 5 من 15 متغير منحدر واستعرض نتائجه على أساس أنه استخدم مستوى معنوية 5%، واستعرض بعد ذلك نتائج المعنوية الإحصائية، يجب علينا أن ندرك أن هذه النتائج غير سليمة بالمرّة، حيث إننا نعلم أن مستوى المعنوية (الحقيقي) هو 15%. ويجب ملاحظة أنه إذا كان $c = k$ فلا يوجد تنقيب للبيانات، ومستوى المعنوية الحقيقي والاسمي متساويان. بالطبع في الواقع معظم الباحثين يسجلون نتائجهم الخاصة بالانحدار "النهائي". بدون توضيح استخدم أسلوباً لتتقيب البيانات أو الخطوات المختلفة التي قام بها للوصول إلى هذا النموذج.

وعلى الرغم من العيوب الواضحة لهذه الطريقة، فإن هناك زيادة عملية تم استخدامها خصوصاً في الاقتصاد القياسي التطبيقي. وبالتالي يصبح أسلوب الوصول إلى نموذج (بدون استخدام تنقيب البيانات من الصعب الحفاظ عليه.

وكما لاحظ Zaman: للأسف التجارب المختلفة بيانات حقيقية أوضحت أن (الأسلوب الذي لا يعتمد على تنقيب البيانات) غير متاح وغير مرغوب فيه أيضًا. غير متاح لأنه من النادر في نظرية الاقتصاد أن تجد ما يشير إلى نموذج فريد لتوصيف البيانات. وغير مرغوب فيه، لأن بعض المفاهيم التي يتعلم الباحث من البيانات لاستخدام أو عدم استخدام نماذج معينة لا يمكن الاعتماد عليها في هذا الأسلوب، حتى ولو على سبيل الصدفة. كان النموذج المبدئي نموذجًا جيدًا. يكون من المفيد البحث عن أنواع من النماذج الأخرى التي قد تتفق أو تختلف مع البيانات محل الدراسة.

وقد اتفق Kery Patlerson مع ذلك ووضح التالي: أسلوب (تنقيب البيانات) يقترح أن يتم الفصل بين النظرية الاقتصادية من جهة، وبين التطبيق العلمي للبيانات من جهة أخرى.

وبدلاً من الاستمرار في المقارنة بين الأسلوب التقليدي الذي (لا يوجد فيه تنقيب للبيانات) وأسلوب التنقيب في البيانات، يمكن للباحث أن يستخدم وجهة نظر Peter Kennedy والتي تنص على التالي: (توصيف النموذج) يجب أن يتم وفقاً للمزج بين النظرية والبيانات، والاختبارات المختلفة المستخدمة للتوصيف، يجب أن تستخدم لتقليل تكلفة تنقيب البيانات. أمثلة على تلك الأساليب هي: تجنب البيانات التي لا ينطبق عليها اختبارات التنبؤ، تعديل مستويات المعنوية [a la lovell] وتجنب الطرق المشكوك فيها مثل تكبير R^2 .

إذا اقتصرنا النظر لتنقيب البيانات على أنه أسلوب يعتمد على بيانات عملية قد يكون بها أخطاء، وقد يكون بها فائدة كبيرة لتوصيف النموذج يكون تنقيب البيانات في ذلك الحين أسلوباً فعالاً جداً وينصح باستخدامه. وفقاً لـ Kennedy مرة أخرى، "فن الاقتصاد القياسي التطبيقي يعتمد على اختيار البيانات وفقاً للنظرية، ومحاولة تفادي الأخطار المحتملة للتنقيب في البيانات" (جوجاراتي، 2015 صفحة 669).

اختبارات للمتغيرات المحذوفة وشكل الدالة غير الصحيح: Tests for Omitted Variables and Incorrect Functional Form

في الواقع لا نستطيع الجزم بأن النموذج المختار وفقاً لاختبارات تطبيقه هو "النموذج السليم ولا شيء غير ذلك". فبناءً على النظرية والجانب التطبيقي السابق في نفس المجال، نصل إلى نموذج نعتقد أنه يتناول كافة جوانب الموضوع محل الدراسة، ثم نطبق هذا النموذج باستخدام اختبارات تطبيقية. بعد أن نحصل على النتائج، نبدأ في تحليل البيانات واضعين في الاعتبار الأساليب التي تم بناءً على اختيار النموذج الجيد والسابق ذكرها مباشرة عند هذه المرحلة، نحن نحاول معرفة درجة دقة النموذج المختار، لتحديد دقة النموذج نستعرض بعض النتائج مثل قيمة R^2 ، قيم t المقدرة، إشارات المعاملات المقدرة وعلاقتها بتوقعاتنا السابقة، إحصاء Durbin-Watson صغير جداً، هنا يجب أن نقلق على جودة ودقة النموذج ونفكر في أساليب علاجية: فقد نكون

حذفنا متغيراً مهماً، أو استخدمنا شكل دالة غير سليم، أو لم تستخدم الفروق وكانت لدينا بيانات سلسلة زمنية لإزالة أثر الارتباط التسلسلي) وهكذا. لمعرفة ما إذا كان النموذج المختار يعاني من واحد أو أكثر من هذه المشاكل، يمكن أن نستخدم بعض الأساليب التالية.

اختبار البواقي: Examination of Residuals

كما سبق وأشرنا في الفصل (12)، اختبار البواقي يعتبر أداة تشخيص بصرية مهمة لاكتشاف الارتباط الذاتي أو اختلاف التباين، ولكن هذه البواقي يمكن اختبارها أيضاً، خصوصاً في البيانات المقطعية، وبالنسبة لأخطاء التوصيف المتعلقة بحذف أحد المتغيرات المهمة أو استخدام شكل دالي غير سليم. إذا كان هناك أحد هذه الأخطاء، فإن الرسم البياني الخاص بالبواقي سيكون له نمطٌ محدد.

للتوضيح، دعنا نعتبر دالة التكلفة التكميلية والتي سبق وناقشناها في الفصل (7).

افترض أن دالة التكلفة الكلية الحقيقية كالتالي حيث $Y =$ الكلية التكلفة و الناتج $x =$:

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 X_i^2 + \beta_4 X_i^3 + u_i \dots \dots (4.4.13)$$

ولكن إذا قام البحث باستخدام الدالة التربيعية التالية:

$$Y_i = \alpha_1 + \alpha_2 X_i + \alpha_3 X_i^2 + u_i^2 \dots \dots (5.4.13)$$

وإذا افترضنا أن باحثاً آخر اختار الدالة الخطية التالية:

$$Y_i + \lambda_1 + \lambda_2 X_i + u_{3i} \dots \dots \dots (6.4.13)$$


على الرغم من أننا نعلم أن كلاً من الباحثين السابقين قد وقعوا في خطأ التوصيف، فدعنا نستعرض شكل البواقي المقدرة في كل من النماذج الثلاثة السابقة. [بيانات التكلفة - النتائج معطاة في جدول (47)]. شكل (1.13) يتضح منه التالي: كلما انتقلنا من اليسار إلى اليمين، أي نقرب من الحقيقة، ليس فقط نقل البواقي (بصورة مطلقة) ولكن أيضاً يختفي الشكل أو النمط الدائري المصاحب للنماذج غير الصحيحة.

وبالتالي فائدة استخدام شكل البواقي واضحة تماماً. فإذا كان هناك خطأ توصيف، فإن البواقي سيظهر فيها نمط محددٌ وواضح.

اختبار d لـ Durbin-Watson مرة أخرى The Durbin-Watson d Statistic Once Again

إذا اخترنا إحصاء Durbin Watson d المحسوب من جدول (1.13) نرى أنه يساوي 0.716 بالنسبة لدالة التكلفة الخطية، ممّا يعني أن هناك "ارتباط طردي في البواقي المقدرة: بالنسبة لـ $n = 10$ و $k = 1$ فإن

الـ 5% قيمة حرجة لـ d هي $d_L = 0.879$ و $d_u = 1.320$



شكل (1.13) البواقي $\hat{u}_i$ محسوبة بناء على (a) دالة تكلفة خطية، (b) دالة تكلفة تربيعية و (c) دالة تكلفة تكعيبية

جدول (113) البواقي المقدرة من دالة التكلفة الكلية الخطية، التربيعية والتكعيبية

Observation Number	$\hat{u}_{in}$ Inear Model*	$\hat{u}_{in}$ Quadratic Model [†]	$\hat{u}_{in}$ Cubic Model**
1	6.600	-23.900	-0.222
2	19.667	9.500	1.607
3	13.733	18.817	-0.915
4	-2.200	13.050	-4.426
5	-9.133	11.200	4.435
6	-26.067	-5.733	1.032
7	-32.000	-16.750	0.726
8	-28.933	-23.850	-4.119
9	4.133	-6.033	1.859
10	54.200	23.700	0.022
$\star \hat{Y}_i = 166.467 + 19.933 X_i$ (19.021) (3.066) (8.752) + (6.502)			$R^2 = 0.8409$ $\bar{R}^2 = 0.8210$ $d = 0.716$
$\dagger \hat{Y}_i = 222.383 - 8.0250 X_i + 2.542 X_i^2$ (23.488) (9.809) (0.869) (9.468) (-0.818) (2.925)			$R^2 = 0.9284$ $\bar{R}^2 = 0.9079$ $d = 1.038$

$**\hat{Y}_i = 141.767 + 63.478 X_i + 12.962_i^2 + 0.939X_i^3$	$R^2 = 0.9983$
(6.375) (4.778) (0.9856) (0.0592)	$\bar{R}^2 = 0.99975$
(22.238) (13.285) (-13.151) (15.861)	$d = 2.70$

وبالمثل فإن قيمة d المحسوبة بناء على دالة التكلفة التربيعية هي 1.038 وتكون الـ 5% قيم حرجة هي $d_U = 1.641$ و $d_L = 0.697$ مما يعني عدم القدرة على اتخاذ قرار في هذه الحالة. ولكن إذا استخدمنا اختبار d المعدل (انظر الفصل 12) سنجد أن هناك ارتباط طردي في البواقي. حيث إن قيمة d ، المحسوبة أقل من d_U . أما بالنسبة لدالة التكلفة التكعيبية، التوصيف الصحيح، فإن قيمة d_U المقدرة لا تشير إلى أي "ارتباط" طردي في البواقي¹.

"الارتباط" الموجب المشاهد في البواقي، عندما نستخدم نموذجاً خطياً أو تربيعياً ليس دليلاً على وجود ارتباط ذاتي (من الدرجة الأولى) في البواقي ولكن دليل على وجود خطأ في توصيف (النموذج). الارتباط المشاهد ببساطة يعبر عن المتغيرات المهمة التي لم يتم استخدامها في النموذج، وتوجد في الخطأ، ويجب فصلها من حد الخطأ وتقديمها كمتغيرات مفسرة في النموذج: فمثلاً إذا حذفنا X_i^3 من دالة التكلفة كما في (3.2.13)، فإن حد الخطأ في النموذج غير الصحيح (2.2.13) هو في الواقع يساوي $(u_{1i} + \beta_4 X_i^3)$ وسيظهر فيها نمط محدد (أي الارتباط الذاتي الموجب) وذلك دليل على أن X_i^3 تؤثر معنوياً على الـ Y .

لاستخدام اختبار Durbin Watson لاكتشاف خطأ التوصيف نقوم بالتالي:

1. من النموذج المفترض، نحصل على بواقي الـ OLS .
2. إذا اعتقدنا أن النموذج يعاني من خطأ التوصيف، حيث تم حذف متغير مفسر مثلاً Z من النموذج. لاحظ أن المتغير Z قد يكون أحد متغيرات X المتضمنة في النموذج المفترض، أو قد تكون دالة ما في هذا المتغير مثل X_2 أو X_3

3. احسب الإحصاء d من البواقي بناءً على المعادلة التقليدية التالية:

$$d = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2}$$

لاحظ أن: الترميز t يشير إلى المشاهدة وليس بالضرورة يعني أن البيانات تعتبر سلسلة زمنية.

¹ - في السياق الحالي، قيمة $d = 2$ تعني عدم وجود خطأ في التوصيف. (لماذا؟)

4. من جداول Durbin-Watson، إذا كانت قيمة d المقدرة معنوية، فإنه من الممكن قبول الفرض الخاص بوجود خطأ توصيف في النموذج، وإذا حدث ذلك فعلاً، بالتالي الطرق العلاجية تقترح نفسها بوضوح كالتالي:


في مثالنا الحالي، المتغير $Z(X) =$ (الناتج) كان مرتباً بالفعل² وبالتالي، لا توجد ضرورة الحساب إحصاء d مجدداً. فقد رأينا أن إحصاء d لكل من دوال التكلفة الخطية والتربيعية يقترح وجود أخطاء في التوصيف. العلاج في هذه الحالة واضح ويكون كالتالي: قم بإدخال القيم التربيعية والتكعيبية في دالة التكلفة الخطية، وأدخل القيم التكعيبية على دالة التكلفة التربيعية. أو باختصار استخدم نموذج التكلفة التكعيبية.

اختبار RESET Test لـ Ramsey:

اقترح Ramsey اختباراً عاماً لخطأ التوصيف وسماه RESET (اختبار خطأ التوصيف للانحدار Regression Specification error test) سنستعرض هنا الشكل الأبسط لهذا الاختبار لتوضيح الفكرة دعنا نستخدم مرة أخرى مثال التكلفة - الناتج، ونفترض أن دالة التكلفة. هي دالة خطية في الناتج كالتالي:

$$Y_i = \lambda_1 + \lambda_2 X_i + u_{3i} \dots \dots \dots (6.4.13)$$

حيث $Y =$ الكلية التكلفة و $x =$ الناتج . الآن إذا رسمنا البواقي $\hat{u}_i$ التي حصلنا عليها من هذا الانحدار ضد $\hat{Y}_i$ القيمة المقدرة لـ Y_i من النموذج، سنحصل على الشكل الموجود في (2.13).



شكل (2.13) البواقي $\hat{u}_i$ و Y المقدرة من دالة التكلفة الخطية: $Y_i = \lambda_1 + \lambda_2 X_i + u_i$

² - لا يهم ما إذا قمنا بترتيب $\hat{u}_i$ ، بناءً على X_i^2 أو X_i^3 حيث إن هذه الدوال في x مرتبة بالفعل.

على الرغم أن $\sum \hat{u}_i$ و $\sum \hat{u}_i \hat{Y}_i$ بالضرورة يساويان الصفر (لماذا؟ انظر الفصل 3)، إلا أن البواقي تظهر في علاقتها بـ $\hat{Y}_i$ نمط محدد في الشكل البياني الخاص بهما، ممّا يعني أننا إذا استطعنا استخدام $\hat{Y}_i$ في شكل ما كمتغيرات محدّدة في (6.4.13) فإن ذلك سيؤدي إلى زيادة R^2 ، وإذا كانت هذه الزيادة معنوية إحصائيًا (على أساس اختبار F السابق مناقشته في الفصل 8) فإن ذلك يعني أنه كان من الخطأ استخدام دالة التكلفة الخطية (6.4.13) وهذه هي الفكرة وراء استخدام $RESET$ خطوات الـ $RESET$ تكون كالتالي:

1. من النموذج المختار مثل (6.4.13) نحصل على رقم Y_i المقدرة أي $\hat{Y}_i$.
2. نعيد عمل (6.4.13) مع تقديم $\hat{Y}_i$ للنموذج في بعض الصور الدالية المختلفة كمتغير أو متغيرات منحدره من الشكل (2.13) نرى أن هناك علاقة غير خطية بين $\hat{Y}_i$ و $\hat{u}_i$ ممّا يعني إمكانية استخدام $\hat{Y}_i^2$ و $\hat{Y}_i^3$ كمتغيرات منحدره إضافية. وبالتالي نتقوم بعمل الانحدار التالي:

$$Y_i = \beta_1 + \beta_2 X_i + \beta_3 \hat{Y}_i^2 + \beta_4 \hat{Y}_i^3 + u_i \dots \dots (7.4.13)$$

3. ارمز R^2 التي حصلت عليها من (7.4.13) بـ R_{new}^2 والتي حصلت عليها من (6.4.13) ارمز لها بـ R_{old}^2 . وبالتالي تستطيع استخدام اختبار F الذي سبق وقدمناه في (18.5.8) وهو كالتالي :

$$F = \frac{\text{عدد المتغيرات المنحدرة} / (R_{new}^2 - R_{old}^2)}{(1 - R_{new}^2) / (n - \text{عدد المعالم في النموذج الجديد})} \dots \dots (18.5.8)$$

- ونرى ما إذا كانت الزيادة في R^2 باستخدام (7.4.13) لها معنوية إحصائية.
4. إذا كانت قيمة F المحسوبة معنوية، مثلاً عند مستوى المعنوية 5% يمكن قبول الفرض القائل بأن النموذج (7.4.13) نموذج غير صحيح.

بالعودة إلى مثالنا التوضيحي، لدينا النتائج التالية (الأخطاء المعيارية موجودة بين الأقواس):

$$\hat{Y}_i = 166.467 + 19.933X_i \quad \dots \dots \dots (8.4.13) \\ (19.021) \quad (3.066) \quad R^2 = 0.8409$$

$$\hat{Y}_i = 2140.7223 + 476.6557X_i - 0.09187\hat{Y}_i^2 + 0.000119\hat{Y}_i^3 \quad \dots \dots \dots (9.4.13) \\ (132.0044) \quad (33.3951) \quad (0.00620) \quad (0.0000074) \quad R^2 = 0.9983$$

لاحظ أن: $\hat{Y}_i^2$ و $\hat{Y}_i^3$ في (9.4.13) تم الحصول من (8.4.13) والآن بتطبيق اختبار F نحصل على:

$$F = \frac{(0.9983 - 0.8409)/2}{(1 - 0.9983)/(10 - 4)} = 284.4035 \dots \dots \dots (10.4.13)$$

يمكن للقارئ بسهولة أن يثبت أن هذه القيمة لـ F لها معنوية إحصائية عالية، مما يعني أن النموذج (8.4.13) نموذج غير صحيح. بالطبع سنصل إلى نفس الاستنتاج مستخدمين الاختبار البصري للبواقي أو قيمة إحصاء d لـ Durbin-Watson.

إحدى مميزات استخدام RESET هي سهولة التطبيق، حيث إنها لا تتطلب تحديد النموذج البديل. ولكنها في نفس الوقت تعتبر نقطة ضعف في هذه الطريقة، حيث إن معرفة النموذج غير صحيح فقط لا يساعدنا في اختيار بديل أفضل.

اختبار مضروب (LM) lagrange لإضافة المتغيرات: Lagrange Multiplier (LM) Test for Adding Variables

هذا الاختبار يعتبر بديلاً لاختبار RESET لـ Ramsey. لتوضيح هذا الاختبار، سنستعرضه وفقاً لمثالنا السابق التوضيحي.

إذا قارنا بين دالة التكلفة الخطية (6.4.13) ودالة التكلفة التكعيبية (4.13.4)، الأولى تعتبر صورة مقيدة من الأخيرة (تذكر ما سبق وناقشناه بخصوص المربعات الصغرى المقيدة في الفصل 8).

الانحدار المقيد (6.4.13) يفترض أن معامل الحدود المربعة والمكعبة من الناتج تساوي الصفر. لاختبار ذلك باستخدام أسلوب LM نقوم بالخطوات التالية:

1. قدر الانحدار المقيد (6.4.13) باستخدام OLS واحصل على البواقي $\hat{u}_i$.
2. إذا كان في الحقيقة الانحدار المقيد (4.4.13) هو النموذج الصحيح، فإن البواقي التي حصلنا عليها من (6.4.13) ستكون مرتبطة مع الحدود المربعة والمكعبة للناتج أي X_i^2 و X_i^3 .
3. وذلك يعني أن نقوم بعمل انحدار لـ $\hat{u}_i$ التي حصلنا عليها من الخطوة 1 على كل المتغيرات المنحدرة (مشتقة على المتغيرات الموجودة في النموذج المقيد) وذلك في مثالنا الحالي.

يعني التالي (جوجاراتي، 2015 صفحة 670):

$$\hat{u}_i = \alpha_1 + \alpha_2 X_i + \alpha_3 X_i^2 + \alpha_4 X_i^3 + v_i \dots \dots \dots (11.4.13)$$

حيث v هو حد الخطأ ومتوافر فيه الخصائص التقليدية المعروفة.

4. في حالة إحكام العينات الكبيرة، أثبت Engle أن n (حجم العينة) مضروب في قيمة R^2 المقدرة من الانحدار (المساعد) (11.4.13) تتبع توزيع كلي تربيعي بدرجة حرية تساوي عدد القيود المفروضة في

نموذج الانحدار المقيد، وتلك الدرجة تساوي اثنين في مثالنا الحالي، حيث إن القيمة X_i^2 و X_i^3 تم إسقاطهما من النموذج.

رمزيًا لدينا التالي:

$$nR^2 \text{asy} X^2_{(\text{number of restrictions})} \dots \dots \dots (12.4.13)$$

حيث إن asy تعني تقاربياً، أي في الحالات التي يكون فيها حجم العينة كبيراً.

5. إذا زادت قيمة chi-square التي حصلت عليها من (12.4.13) من القيمة الحرجة عند مستوى المعنوية المختار نرفض الانحدار المقيد، وبخلاف ذلك نقبله.

نتائج الانحدار في مثالنا الحالي كالتالي:

$$\hat{Y}_i = 166.467 + 19.333X_i \dots \dots \dots (13.4.13)$$

حيث Y هي التكلفة الكلية و X هي الناتج. الأخطاء القياسية لهذا الانحدار معطاة في جدول (1.13).

إذا قمنا بعمل انحدار البواقي (13.4.13) كما هو مقترح في الخطوة 3. نحصل على النتائج التالية:

$$\begin{aligned} \hat{u}_i &= -24.7 + 43.5443X_i - 12.9615 X_i^2 + 0.9396 X_i^3 \\ se &= (6.375) \quad (4.779) \quad (0.986) \quad (0.059) \quad (14.4.13) \\ R^2 &= 0.9896 \end{aligned}$$

على الرغم من أن حجم العينة يساوي 10 وهو ليس بالحجم الكبير. إلا أننا نرغب في توضيح آلية LM كالتالي: سنحصل على $nR^2 = (10)(0.9896) = 9.896$ عن جدول كاي التربيعي، وباستخدام 2 درجات حرية، و 1% مستوى معنوية، نجد أن قيمة كاي التربيعية تساوي تقريباً 9.21. وبالتالي القيمة المشاهدة والمساوية لـ 9.896 لها معنوية إحصائية عند مستوى المعنوية 1% ونستنتج أنه يجب رفض النموذج المقيد (أي دالة التكلفة الخطية). ونلاحظ أننا قد توصلنا إلى نفس النتيجة باستخدام اختبار RESET - Ramsey.

5.13 أخطاء القياس: ERRORS OF MEASUREMENT

في كل ما سبق، تم الافتراض صراحةً بأن المتغير التابع Y ، والمتغيرات المفسرة X 's تم قياسها بدون أخطاء. وبالتالي في انحدار نفقات الاستهلاك على الدخل و ثروة رب الأسرة، افترضنا أن بيانات هذه المتغيرات "دقيقة"، وبالتالي لا مجال للتخمين أو التدشير أو التقريب بأي شكل منتظم مثل التقريب إلى مئة دولار وهكذا.

للأسف هذا الوضع النموذجي لا يحدث كثيراً في الواقع العملي، وذلك وفقاً للعديد من الأسباب مثل أخطاء عدم الاستجابة، وأخطاء التسجيل، وأخطاء الحساب. وبغض النظر عن السبب فإن أخطاء القياس مشكلة

محتملة عن التطبيق العملي، وهي تعتبر أحد مصادر تحيز التوصيف. وسنستعرض فيما يلي العواقب المحتملة لذلك:

أخطاء قياس في المتغير التابع Y : Errors of Measurement in the Dependent Variable Y

اعتبر النموذج التالي:

$$Y_i^* = \alpha + \beta X_i + u_i \dots \dots \dots (1.5.13)$$

حيث Y_i^* : نفقات الاستهلاك الدائمة.

X_i : الدخل الحالي خطأ عشوائي

u_i : خطأ عشوائي

بما أن Y_i^* لا يمكن قياسها مباشرة، نستخدم النفقات المشاهدة (Y_i المتغير) كالتالي:

$$Y_i = Y_i^* + \varepsilon_i \dots \dots \dots (2.5.13)$$

حيث ε_i ترمز للخطأ في قياس Y_i^* . وبالتالي بدلاً من تقدير (1.5.13)، فإننا نقدر:

$$Y_i = (\alpha + \beta X_i + u_i) + \varepsilon_i = \alpha + \beta X_i + (u_i + \varepsilon_i) = \alpha + \beta X_i + v_i \dots \dots \dots (3.5.13)$$

حيث $v_i = u_i + \varepsilon_i$ وهو يعتبر حد خطأ مركب، يشتمل على خطأ المجتمع (والذي يمكن تسميته معادلة

حد الخطأ) وحد الخطأ في القياس.

للتبسيط افترض أن $cov(X_i, \varepsilon_i) = 0$, $E(u_i) - E(\varepsilon_i) = 0$ (والذي يعتبر فرضاً من فروض

الانحدار الخطي التقليدي و $cov(X_i, \varepsilon_i) = 0$ أي أن أخطاء القياس في Y_i^* غير مرتبطة مع X_i

و $cov(X_i, \varepsilon_i) = 0$ أي أن خطأ المعادلة وخطأ القياس غير مرتبطين. بالإضافة إلى بعض الفروض الخاصة

بـ β المقدرة سواء من (1.5.13) أو (3.5.13) والتي تنص على أنها مقدر غير متحيز للمعلمة الحقيقية β

(انظر تمرين 7.13). وبالتالي أخطاء القياس الموجودة في المتغير التابع Y لا تؤثر على خاصية عدم التحيز

لمقدرات OLS. عمومًا التباين والأخطاء القياسية لـ β المقدرة من (1.5.13) و (3.5.13) ستكون مختلفة،

باستخدام المعادلات المعتادة (انظر الفصل 3) نحصل على:

$$var(\hat{\beta}) = \frac{\sigma_u^2}{\sum x_i^2} \dots \dots \dots (4.5.13) \quad \text{نموذج (1.5.13)}$$

$$var(\hat{\beta}) = \frac{\sigma_u^2}{\sum x_i^2} = \frac{\sigma_u^2 + \sigma_\varepsilon^2}{\sum x_i^2} \dots \dots \dots (5.5.13) \quad \text{نموذج (3.5.13)}$$

نلاحظ أن التباين الأخير أكبر من التباين الأول³. وبالتالي على الرغم من وجود أخطاء القياس في المتغير التابع Y فإن مقدرات المعالم والتباينات مازالت غير متحيزة، إلا أن التباين المقدر أكبر من نظيره في الحالة التي لا يوجد فيها مثل هذا الخطأ من أخطاء القياس.

أخطاء القياس في المتغير المفسر X : Errors of Measurement in the Explanatory Variable X

الآن افترض أنه بدلاً من (1.5.13) لدينا النموذج التالي:

$$Y_i = \alpha + \beta X_i^* + u_i$$

حيث Y_i : نفقات الاستهلاك الحالية.

X_i^* : الدخل الدائم

u_i : حد الخطأ العشوائي (معادلة الخطأ)

وافترض أنه بدلاً من مشاهدة X_i^* ، نشاهد التالي:

$$Y_i = X_i^* + w_i \dots \dots \dots (7.5.13)$$

حيث w_i تمثل خطأ في قياس X_i^* . وبالتالي بدلاً من تقدير (6.5.13) نقدر التالي:

$$Y_i = \alpha + \beta(X_i - w_i) + u_i = \alpha + \beta X_i + (u_i + \beta w_i) = \alpha + \beta X_i + z_i \dots (8.5.13)$$

حيث $z_i = u_i - \beta w_i$ ، وبالتالي لدينا مزيج من معادلة الأخطاء وأخطاء القياس.

والآن حتى لو افترضنا أن w_i لها وسط يساوي الصفر، وغير مرتبطة تسلسلياً، وغير مرتبطة بالـ u_i ، لا

نستطيع افتراض أن حد الخطأ المركب z_i مستقل عن المتغير المفسر X_i ، وذلك بسبب التالي (افتراض أن

$$E(z_i) = 0$$

$$\text{cov}(z_i, X_i) = E[z_i - E(z_i)][X_i - E(X_i)] = E(u_i - \beta w_i)(w_i) \text{ using (13.5.7)}$$

$$= E(-\beta w_i^2) = -\beta \sigma_w^2 \dots \dots \dots (9.5.13)$$

وبالتالي المتغير المفسر وجد الخطأ في (8.5.13) مرتبطان، وذلك يخالف فرضاً مهماً في نموذج الانحدار

الخطي التقليدي، وهو الفرض القائل بأن المتغير المفسر غير مرتبط مع - حد الخطأ العشوائي. إذا خالفنا هذا

³ - لكن نلاحظ أن هذا التباين مازال غير متحيز، حيث إنه وفقاً للشروط الموضوعية الخطأ المركب $v_i = u_i + \varepsilon_i$ مازال مستوفياً لكل الفروض الخاصة بطريقة المربعات الصغرى.

الفرض، فإنه يمكن إثبات أن مقدرات OLS لم تعد فقط متحيزة، ولكن غير منسقة أيضًا، أي ستكون مقدرات متحيزة حتى لو زاد حجم العينة n وأصبح غير محدود.

بالنسبة للنموذج (8.5.13) مثبت في الملحق A13، الفقرة 3A.13 أن (جوجاراتي، 2015 صفحة 671):

$$plim \hat{\beta} = \beta \left[\frac{1}{1 + \sigma_w^2 / \sigma_{X^*}^2} \right] \dots \dots \dots (10.5.13)$$

حيث σ_w^2 و $\sigma_{X^*}^2$ تمثل تباين w_i و X^* بالترتيب و $plim \hat{\beta}$ تعني النهاية الاحتمالية لـ β .

بما أن المقدار ما بين الأقواس متوقع أن يكون أقل من 1 (لماذا؟) فإن (10.5.13) توضح أنه حتى إذا زاد حجم العينة بشكل غير محدود فإن $\hat{\beta}$ لن يؤول إلى β . في واقع الأمر إذا افترضنا أن β موجبة، فإن $\hat{\beta}$ ستقدر قيمة β بأقل من قيمتها الحقيقية، وبالتالي يكون التحيز أقل من الصفر. بالطبع إذا لم يكن هناك أي أخطاء في القياس في X (أي أن $\sigma_w^2 = 0$) فإن $\hat{\beta}$ سيعتبر مقدارًا متسقًا بالنسبة لـ β .

وبالتالي تمثل أخطاء القياس مشكلة حقيقية عندما تظهر في المتغير أو المتغيرات المفسرة، حيث إنهم يؤديون إلى عدم إمكانية الحصول على مقدار متسق. بالطبع، كما سبق ورأينا، إذا ظهرت أخطاء القياس في المتغير التابع فقط، فإن المقدرات لا تزال غير متحيزة ومتسقة أيضًا. أما إذا ظهرت أخطاء القياس في المتغيرات المفسرة. ما الحل؟ الإجابة ليست بالسهولة المتوقعة. إحدى الإجابات المتطرفة، أننا يمكن أن نفترض أن σ_w^2 صغير للغاية مقارنة مع $\sigma_{X^*}^2$ ، وبالتالي لكل التطبيقات العلمية يمكن أن نفترض عدم حدوث المشكلة، ونستمر في استخدام تقدير OLS التقليدي. بالطبع، هنا يمكننا مشاهدة أو قياس أي من σ_w^2 أو $\sigma_{X^*}^2$ ، وبالتالي لا يمكن الحكم على مدى تأثيرهما.

إحدى الإجابات الأخرى والتي يمكن اعتبارها أسلوب علاج للمشكلة الحالية هو التعامل مع المتغيرات المساعدة، وعلى الرغم من أنها ستكون مرتبطة بدرجة كبيرة مع المتغيرات X الأصلية، إلا أنها غير مرتبطة مع حد خطأ المعادلة أو حدود أخطاء القياس (أي w_i و u_i). إذا استطاع إيجاد مثل هذا المتغير المساعد، وبالتالي يمكنك الحصول على مقدار متسق لـ β .

ولكن هذه العملية، التحدث عنها أسهل بكثير من تنفيذها. في الواقع العملي ليس من السهل إيجاد مثل هذه المتغيرات المساعدة، فنحن في الأغلب كثير الشكوى من المناخ، ولكننا لا نستطيع فعل أي شيء حياله، وإلى جانب صعوبة الحصول على المتغيرات المساعدة، فإنه أيضًا من الصعب معرفة ما إذا كانت المتغيرات المساعدة بالفعل مستقلة عن حدود الخطأ w_i و u_i أم لا.

في الأدبيات هناك اقتراحات أخرى لحل هذه المشكلة.

ولكن أغلب هذه الحلول خاصة بأوضاع محددة ومبنية على فروض مقيدة عديدة وبالتالي لا توجد حلول محددة لمشكلة أخطاء القياس. ولذلك لابد من القياس الدقيق على قدر المستطاع للبيانات محل الدراسة.

مثال: An Example

سنلخص الفقرة السابقة في المثال التالي:

جدول (213) يعطي بيانات افتراضية عن نفقات الاستهلاك الحقيقية Y^* ، الدخل الحقيقي X^* ، الاستهلاك المقاس Y والدخل المقاس X ، الجدول أيضًا يتضح فيه كيفية قياس تلك المتغيرات.

أخطاء القياس في المتغير التابع Y فقط: Measurement Errors in the Dependent Variable Y only

بناءً على البيانات المعطاة، دالة الاستهلاك الحقيقية هي:

$$\begin{aligned}\hat{Y}_i^* &= 25.00 + 0.6000X_i^* \\ (10.477) \quad (0.0584) \\ t &= (2.3861) \quad (10.276) \\ R^2 &= 0.9296\end{aligned}\quad (11.5.13)$$

في حين أنه إذا استخدمنا Y_i بدلاً من Y_i^* ستحصل على:

$$\begin{aligned}\hat{Y}_i &= 25.00 + 0.6000X_i \\ (12.218) \quad (0.0681) \\ t &= (2.0461) \quad (8.8118) \\ R^2 &= 0.9066\end{aligned}\quad (12.5.13)$$

كما يتضح من النتائج السابقة وبناءً على النظرية، القيمة المقدرة للمعاملات تظل كما هي. الأثر الوحيد لخطأ القياس في المتغير التابع هو أن الأخطاء القياسية المقدرة للمعاملات تزداد [انظر (5.5.13)] ويتضح ذلك في (12.5.13) عمومًا لاحظ أن معاملات الانحدار في (11.5.13) و (12.5.13) | متساوية، حيث أن البيانات تم توليدها لتتماشى مع فروض نموذج أخطاء القياس.

أخطاء القياس في X : Errors of Measurement in X

نحن نعرف أن الانحدار الحقيقي هو (11,5,13)، افترض الآن أنه بدلاً من استخدام X_i^* ، استخدمنا X_i (لاحظ أنه في الواقع نادرًا ما نستطيع قياس X_i^*) نتائج الانحدار ستكون كالتالي:

$$\begin{aligned}\hat{Y}_i^* &= 25.992 + 0.5940X_i \\ (11.0810) \quad (0.068117) \\ t &= (2.3457) (9.6270) \\ R^2 &= 0.90205\end{aligned}\quad (13.5.13)$$

هذه النتائج عندما تكون هناك أخطاء قياس في المتغير أو المتغيرات المفسرة.

المعاملات المقدرة متحيزة. لحسن الحظ في هذا المثال التحيز صغير نسبيًا - من (10.5.13) نرى أن التحيز يعتمد على $\sigma_u^2/\sigma_{X^*}^2$ ، وعند توليد البيانات افترضنا أن $\sigma_u^2 = 36$ و $\sigma_{X^*}^2 = 3667$ ما يجعل معامل التحيز صغيرًا يساوي تقريبًا 0.98% (36/3667)

سنترك للقارئ تحديد ما يحدث إذا كان هناك خطأ في قياس كل من Y و X . أي عندما نقوم بعمل انحدار لـ Y_i على X_i بدلاً من Y_i^* على X_i^* (انظر تمرين 23.13).

جدول (213) بيانات افتراضية عن Y^* (نفقات الاستهلاك الحقيقية)، X^* (الدخل الحقيقي) و Y (نفقات الاستهلاك المقاسة) و X (الدخل المقاس) البيانات كلها بالدولار.

Y^*	X^*	Y	X	e	w	u
75.4668	80.00	67.6011	80.0940	-7.8655	0.0940	2.4666
74.9801	100.00	75.4438	94.5721	0.4638	-8.4279	-10.0199
102.8242	120.00	109.6956	112.1406	6.8714	2.1406	5.8242
125.7651	140.00	129.4159	145.5969	3.6509	5.5969	16.7651
106.5035	160.00	104.2388	168.5579	-2.2647	8.5579	-14.4965
131.4318	180.00	125.8319	171.4793	-5.5999	-8.5207	-1.5662
149.3693	200.00	153.9926	203.5333	4.6233	3.5366	4.3693
143.8628	220.00	152.9208	222.8533	9.0579	2.8533	-13.1372
177.5218	240.00	176.3344	232.9879	-1.1874	-7.0120	8.5218
182.2748	260.00	174.5252	261.1813	-7.7496	1.1813	1.2748

Note: The data on X^* are assumed to be given. In deriving the other variable the assumption made were as follows : (1) $E(u_i) = E(\varepsilon_i) = E(w_i) = 0$; (2) $cov(X, u) = cov(X, \varepsilon) = cov(U, \varepsilon) = cov(w, u) = cov(\varepsilon, w) = 0$; (3) $\sigma_u^2 = 100$, $\sigma_x^2 = 36$, and $\sigma_w^2 = 36$; and (4) $Y_i^* = 25 + 0.6X_i^* + u_i$, $Y_i = Y_i^* + \varepsilon_i$, and $X_i = X_i^* + w_i$

6.13 التوصيف الخاطئ لحد الخطأ العشوائي:

INCORECT SPECIFICATION OF THE STOCHASTIC ERROR TERM

المشكلة الأكثر ظهوراً أمام الباحث هي توصيف حد الخطأ u_i داخل نموذج الانحدار. فيما أن حد الخطأ لا يشاهد مباشرة، فإنه لا توجد طريقة لتحديد الشكل الذي يظهر به في النموذج. لتوضيح ذلك دعنا نعود إلى النماذج المعطاة في (8.2.13) و (9.2.13). للتبسيط، افترضنا عدم وجود الحد الثابت المقطوع من المحور الصادي في النموذج، وافترضنا أيضاً أن u_i الموجود في (8.2.13) يستوفي فيه $\ln u_i$ كل فروض OLS التقليدية.

إذا افترضنا أن (8.2.13) هو النموذج "الصحيح"، ولكن قدرنا (9.2.13) ما هي عواقب ذلك؟ يتضح من ملحق A13، الفقرة 4A.13 أنه إذا كان $\ln u_i \sim N(0, \sigma^2)$ فإن:

$$u_i \sim \log normal [e^{\sigma^2/2}, e^{\sigma^2}(e^{\sigma^2} - 1)] \dots \dots \dots (1.6.13)$$

وكنتيجة لذلك يكون لدينا التالي:

$$E(\hat{\alpha}) = \beta e^{\sigma^2/2} \dots \dots \dots (2.6.13)$$

حيث e هي أساس اللوغاريتم الطبيعي.

كما ترى $\hat{\alpha}$ مقدار متحيز، حيث إن قيمة المتوسط لا تساوي القيمة الحقيقية لـ β . سنستعرض المزيد من التفاصيل عن توصيف حد الخطأ العشوائي في الفصل الخاص بنماذج الانحدار غير الخطية في المعالم.