

Como o exemplo anterior sugere, com uma amostra grande raramente vemos discrepâncias importantes entre os resultados dos testes *LM* e *F*. Usaremos a estatística *F* para a maior parte dos problemas porque ela é rotineiramente calculada pela maioria dos programas de regressão. No entanto, você deve estar consciente sobre a estatística *LM* para reconhecê-la, pois ela é usada em trabalhos aplicados.

Um último comentário sobre a estatística *LM*. Assim como com a estatística *F*, devemos estar seguros de usar as mesmas observações nos passos (i) e (ii). Se faltarem dados para algumas das variáveis independentes excluídas sob a hipótese nula, os resíduos do passo (i) devem ser obtidos de uma regressão sobre o conjunto de dados reduzido.

5.3 EFICIÊNCIA ASSIMPTÓTICA DE MQO

Sabemos que, sob as hipóteses de Gauss-Markov, os estimadores de MQO são os melhores estimadores não viesados lineares. MQO também é, sob as hipóteses de Gauss-Markov, **assimptoticamente eficiente** dentro uma classe de estimadores. Um tratamento geral requer álgebra matricial e análise assintótica avançada. Em primeiro lugar, vamos descrever o resultado para o caso da regressão simples.

No modelo

$$y = \beta_0 + \beta_1 x + u, \quad (5.16)$$

u tem média condicional zero sob RLM.4: $E(ux) = 0$. Isso dá lugar a uma variedade de estimadores consistentes de β_0 e β_1 ; como habitual, vamos nos concentrar no parâmetro de inclinação, β_1 . Seja $g(x)$ qualquer função de x ; por exemplo, $g(x) = x^2$ ou $g(x) = 1/(1 + |x|)$. Então u é não correlacionado com $g(x)$ (veja a Propriedade CE.5 no Apêndice B, disponível no site da Cengage). Seja $z_i = g(x_i)$ para todas as observações i . Então, o estimador

$$\tilde{\beta}_1 = \left(\sum_{i=1}^n (z_i - \bar{z}) y_i \right) / \left(\sum_{i=1}^n (z_i - \bar{z}) x_i \right) \quad (5.17)$$

é consistente para β_1 , desde que $g(x)$ e x sejam correlacionados. [Lembre-se: é possível que $g(x)$ e x sejam não correlacionados porque a correlação mensura a dependência *linear*.] Para ver isso, podemos colocar $y_i = \beta_0 + \beta_1 x_i + u_i$ e escrever $\tilde{\beta}_1$ como

$$\tilde{\beta}_1 = \beta_1 + \left(n^{-1} \sum_{i=1}^n (z_i - \bar{z}) u_i \right) / \left(n^{-1} \sum_{i=1}^n (z_i - \bar{z}) x_i \right) \quad (5.18)$$

Agora, podemos aplicar a lei dos grandes números ao numerador e denominador, os quais convergem em probabilidade para $\text{Cov}(z, u)$ e $\text{Cov}(z, x)$, respectivamente. Na condição de que $\text{Cov}(z, x) \neq 0$ — de modo que z e x sejam correlacionados —, temos

$$\text{plim } \tilde{\beta}_1 = \beta_1 + \text{Cov}(z, u) / \text{Cov}(z, x) = \beta_1,$$

porque $\text{Cov}(z, u) = 0$ sob RLM.4.

É mais difícil mostrar que $\tilde{\beta}_1$ é assintoticamente normal. No entanto, usando argumentos semelhantes àqueles do apêndice deste capítulo, pode ser mostrado que $\sqrt{n}(\hat{\beta}_1 - \beta_1)$ é assintoticamente normal com média zero e variância assintótica $\sigma^2 \text{Var}(z) / [\text{Cov}(z, x)]^2$. A variância assintótica do estimador de MQO é obtida quando $z = x$, caso em que $\text{Cov}(z, x) = \text{Cov}(x, x) = \text{Var}(x)$. Portanto, a variância assintótica de $\sqrt{n}(\hat{\beta}_1 - \beta_1)$, em que $\hat{\beta}_1$ é o estimador de MQO, é $\sigma^2 \text{Var}(x) / [\text{Var}(x)]^2 = \sigma^2 / \text{Var}(x)$. Agora, a desigualdade de Cauchy-Schwartz (veja Apêndice B.4, disponível no site da Cengage) implica $[\text{Cov}(z, x)]^2 \leq \text{Var}(z) \text{Var}(x)$, o que implica que a variância assintótica de $\sqrt{n}(\hat{\beta}_1 - \beta_1)$ não é maior do que a de $\sqrt{n}(\tilde{\beta}_1 - \beta_1)$. Assim, para o caso da regressão simples, mostramos que, sob as hipóteses de Gauss-Markov, o estimador de MQO tem uma variância assintótica menor do que qualquer outro estimador da forma (5.17). [O estimador em (5.17) exemplifica um *estimador de variáveis instrumentais*, que estudaremos extensivamente no Capítulo 15.] Se a hipótese de homoscedasticidade não for válida, então há estimadores da forma (5.17) que têm uma variância assintótica menor do que a de MQO. Veremos isso no Capítulo 8.

O caso geral é semelhante, mas matematicamente muito mais difícil. No caso de k regressores, a classe de estimadores consistentes é obtida ao generalizar as condições de primeira ordem de MQO:

$$\sum_{i=1}^n g_j(x_i) (y_i - \tilde{\beta}_0 - \tilde{\beta}_1 x_{i1} - \dots - \tilde{\beta}_k x_{ik}) = 0, \quad j = 0, 1, \dots, k, \quad (5.19)$$

em que $g_j(x_i)$ representa qualquer função de todas as variáveis explicativas para a observação i . Como pode ser visto ao comparar (5.19) com as condições de primeira ordem de MQO em (3.13), obtemos os estimadores de MQO quando $g_0(x_i) = 1$ e $g_j(x_i) = x_{ij}$, para $j = 1, 2, \dots, k$. A classe dos estimadores em (5.19) é infinita, pois podemos usar qualquer função de x_{ij} que quisermos.

TEOREMA 5.3 (EFICIÊNCIA ASSIMPTÓTICA DE MQO)

Sob as hipóteses de Gauss-Markov, sejam $\tilde{\beta}_j$ os estimadores que solucionam as equações da forma (5.19) e $\hat{\beta}_j$ os estimadores de MQO. Então, para $j = 0, 1, 2, \dots, k$, os estimadores de MQO têm as menores variâncias assintóticas: $\text{Avar } \sqrt{n}(\hat{\beta}_j - \beta_j) \leq \text{Avar } \sqrt{n}(\tilde{\beta}_j - \beta_j)$.

Provar a consistência dos estimadores em (5.19), sem mencionar que eles são assintoticamente normais, é matematicamente difícil. [Veja Wooldridge (2002, Capítulo 5).]

RESUMO

As afirmações subjacentes ao material deste capítulo são razoavelmente técnicas, mas suas implicações práticas são diretas. Mostramos que as quatro primeiras hipóteses de Gauss-Markov implicam que MQO é consistente. Além disso, todos os métodos de testar e construir intervalos de confiança que aprendemos no Capítulo 4 são aproximadamente válidos, sem presumir que os erros são extraídos de uma distribuição normal (equivalentemente, a distribuição de y , dadas as variáveis explicativas, não é normal). Isso significa que podemos aplicar MQO e usar os métodos anteriores para um conjunto de aplicações em que

a variável dependente não é de fato aproximada e normalmente distribuída. Também mostramos que, em vez da estatística F , a estatística LM pode ser usada para testar restrições de exclusão.

Antes de deixarmos este capítulo, devemos observar que situações como o Exemplo 5.3 podem muito bem apresentar problemas que, *de fato*, exigem atenção especial. Para uma variável como *npre86*, que é zero ou um para a maioria dos homens na população, um modelo linear pode não ser capaz de capturar adequadamente a relação funcional entre *npre86* e as variáveis explicativas. Além do mais, mesmo se um modelo linear descreve o valor esperado das prisões, a heteroscedasticidade poderia ser um problema. Problemas como esses não são mitigados quando o tamanho da amostra aumenta e, portanto, retornaremos a eles em capítulos posteriores.

PROBLEMAS

5.1 No modelo de regressão simples (5.16), sob as primeiras quatro hipóteses de Gauss-Markov, mostramos que o estimador da forma (5.17) é consistente com a inclinação β_1 . Dado tal tipo de estimador, defina um estimador de β_0 por $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$. Mostre que $\text{plim } \hat{\beta}_0 = \beta_0$.

5.2 O conjunto de dados do arquivo SMOKE.RAW contém informações sobre o comportamento tabagista e outras variáveis para uma amostra aleatória de adultos solteiros dos Estados Unidos. A variável *cigs* é o número (médio) de cigarros fumados por dia. Você acha que *cigs* tem uma distribuição normal na população adulta dos Estados Unidos? Explique.

5.3 Suponha que o modelo

$$pctação = \beta_0 + \beta_1 funds + \beta_2 risctol + u$$

satisfaça as quatro primeiras hipóteses de Gauss-Markov, em que *pctação* é a percentagem da pensão de um trabalhador investida no mercado de ações, *funds* é o número de fundos mútuos que o trabalhador pode escolher e *risctol* é alguma medida de tolerância de risco (*risctol* maior significa que a pessoa tem uma tolerância maior ao risco). Se *funds* e *risctol* são positivamente correlacionados, qual é a inconsistência em $\hat{\beta}_1$, o coeficiente de inclinação da regressão de *pctação* sobre *funds*?

5.4 No modelo de regressão simples sob os RLM.1 até RLM.4, afirmamos que o estimador de inclinação, $\hat{\beta}_1$, é consistente com β_1 . Usando $\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x}$, demonstre que $\text{plim } \hat{\beta}_0 = \beta_0$. [Você precisará usar a consistência de $\hat{\beta}_1$ e a lei dos grandes números, juntamente com o fato de que $\beta_0 = E(y) - \beta_1 E(x)$.]

APÊNDICE 5A

Normalidade Assimptótica dos MQO

Vamos delinear uma prova da normalidade assimptótica de MQO [Teorema 5.2(i)] no caso da regressão simples. Escreva o modelo de regressão simples como na equação (5.16). Em seguida, por meio da álgebra usual da regressão simples, podemos escrever

$$\sqrt{n}(\hat{\beta}_1 - \beta_1) = (1/s_x^2) \left[n^{-1/2} \sum_{i=1}^n (x_i - \bar{x}) u_i \right],$$

em que usamos s_x^2 para representar a variância amostral de $\{x_i; i = 1, 2, \dots, n\}$. Pela lei dos grandes números (veja o Apêndice C, disponível no site da Cengage), $s_x^2 \xrightarrow{p} \sigma_x^2 = \text{Var}(x)$. A Hipótese RLM.3 exclui a perfeita colinearidade, o que significa que $\text{Var}(x) > 0$ (x varia na amostra, e portanto x não é constante na população). Em seguida, $n^{-1/2} \sum_{i=1}^n (x_i - \bar{x}) u_i = n^{-1/2} \sum_{i=1}^n (x_i - \mu) u_i + (\mu - \bar{x}) [n^{-1/2} \sum_{i=1}^n u_i]$, em que $\mu = E(x)$ é a média populacional de x . Agora $\{u_i\}$ é a sequência de variáveis aleatórias independentes e identicamente distribuídas (i.i.d.) com média zero e variância σ^2 , e portanto $n^{-1/2} \sum_{i=1}^n u_i$ converge para a distribuição Normal(0, σ^2) quando $n \rightarrow \infty$; isso é exatamente o teorema do limite central do Apêndice C, disponível no site da Cengage. Pela lei dos grandes números, $\text{plim}(\mu - \bar{x}) = 0$. Um resultado padrão da teoria assimptótica é que se $\text{plim}(w_n) = 0$ e z_n tem uma distribuição normal assimptótica, então $\text{plim}(w_n z_n) = 0$. [Veja Wooldridge (2002, Capítulo 3) para mais discussão.] Isso implica $(\mu - \bar{x}) [n^{-1/2} \sum_{i=1}^n u_i]$ plim zero. Em seguida $\{(x_i - \mu) u_i; i = 1, 2, \dots\}$ é uma sequência indefinida de variáveis aleatórias i.i.d. com média zero — porque u e x são não correlacionados sob RLM.4 — e variância $\sigma^2 \sigma_x^2$, pela hipótese de homoscedasticidade RLM.5. Portanto, $n^{-1/2} \sum_{i=1}^n (x_i - \mu) u_i$ tem uma distribuição Normal(0, $\sigma^2 \sigma_x^2$) assimptótica. Acabamos de mostrar que a diferença entre $n^{-1/2} \sum_{i=1}^n (x_i - \bar{x}) u_i$ e $n^{-1/2} \sum_{i=1}^n (x_i - \mu) u_i$ tem plim zero. Um resultado da teoria assimptótica é que se z_n tem uma distribuição normal e $\text{plim}(v_n - z_n) = 0$, então v_n tem a mesma distribuição normal assimptótica que z_n . Em decorrência $n^{-1/2} \sum_{i=1}^n (x_i - \bar{x}) u_i$ também tem uma distribuição Normal(0, $\sigma^2 \sigma_x^2$) assimptótica. Colocando todas essas peças juntas, temos

$$\begin{aligned} \sqrt{n}(\hat{\beta}_1 - \beta_1) &= (1/\sigma_x^2) \left[n^{-1/2} \sum_{i=1}^n (x_i - \bar{x}) u_i \right] \\ &+ [(1/s_x^2) - (1/\sigma_x^2)] \left[n^{-1/2} \sum_{i=1}^n (x_i - \bar{x}) u_i \right], \end{aligned}$$

e como $\text{plim}(1/s_x^2) = 1/\sigma_x^2$, o segundo termo tem plim zero. Portanto, a distribuição assimptótica de $\sqrt{n}(\hat{\beta}_1 - \beta_1)$ é Normal(0, $\{\sigma^2 \sigma_x^2\} / \{\sigma_x^2\}^2) = \text{Normal}(0, \sigma^2 / \sigma_x^2)$. Isso completa a prova para o caso da regressão simples, quando $a_1^2 = \sigma_x^2$ neste caso. Veja Wooldridge (2002, Capítulo 4) para o caso geral.