

## Respostas às Questões dos Capítulos

### CAPÍTULO 2

---

#### QUESTÃO 2.1

Quando a aptidão, motivação, idade e outros fatores em  $u$  não estiverem relacionados com a frequência, (2.6) será válida. É pouco provável que esse seja o caso.

#### QUESTÃO 2.2

Em torno de \$9,64. Para verificar isso, a partir dos salários médios medidos em dólares de 1976 e 1977, podemos obter o deflator do IPC como  $16,64/5,90 \approx 2,82$ . Quando multiplicamos 3,42 por 2,82, obtemos aproximadamente 9,64.

#### QUESTÃO 2.3

54,65, como poderá ser verificado agregando-se  $partA = 60$  na equação (2.28). Esse resultado não é absurdo: se o Candidato A gastar 60% do total gasto, prevê-se que ele (ou ela) receberá quase 55% dos votos.

#### QUESTÃO 2.4

A equação será  $salârcent = 9.631,91 + 185,01 rma$ , como poderá ser facilmente verificado multiplicando-se a equação (2.39) por 10.

#### QUESTÃO 2.5

A equação (2.58) poderá ser escrita como  $\text{Var}(\hat{\beta}_0) = (\sigma^2 n^{-1}) \left( \sum_{i=1}^n x_i^2 \right) \left( \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{-1}$ , onde o termo que multiplica  $\sigma^2 n^{-1}$  é maior que ou igual a um, mas será igual a um se e somente se  $\bar{x} = 0$ . Nesse caso, a variância será tão pequena quanto possível:  $\text{Var}(\hat{\beta}_0) = \sigma^2/n$ .

### CAPÍTULO 3

---

#### QUESTÃO 3.1

Alguns poucos fatores incluem a distribuição por idade e por gênero, o tamanho da força policial (ou, de forma mais generalizada, os recursos alocados no combate ao crime), a população e fatores históricos gerais. Esses fatores certamente devem estar correlacionados com  $prcond$  e  $sentmed$ , o que significa que

(3.5) não se manterá. Por exemplo, o tamanho da força policial possivelmente estará correlacionado tanto com *prcond* como com *sentmed*, já que algumas cidades colocam mais empenho na prevenção e na imposição da lei. Devemos tentar levar para a equação tantos desses fatores quanto possível.

### QUESTÃO 3.2

Usamos a terceira propriedade do MQO em relação aos valores previstos e aos resíduos: quando agregamos os valores médios de todas as variáveis independentes na reta de regressão pelos MQO, obtemos o valor médio da variável dependente. Assim,  $\overline{nmgrad} = 1,29 + 0,453 \overline{nmem} + 0,0094 \overline{tac} = 1,29 + 0,453(3,4) + 0,0094(24,2) \approx 3,06$ . Você poderá conferir a média de *nmgrad* no arquivo GPA1.RAW, para verificar esse resultado até duas casas decimais.

### QUESTÃO 3.3

Não. A variável *partA* não é uma função linear exata de *gastoA* e de *gastoB*, embora ela seja uma função não-linear exata:  $partA = 100 \cdot [gastoA / (gastoA + gastoB)]$ . Portanto, é legítimo termos *gastoA*, *gastoB* e *partA* como variáveis explicativas.

### QUESTÃO 3.4

Como discutimos na Seção 3.4, se estamos interessados no efeito de  $x_1$  sobre  $y$ , a correlação entre as outras variáveis explicativas ( $x_2, x_3$  etc.) não afeta  $\text{Var}(\hat{\beta}_1)$ . Essas variáveis são incluídas como controles, e não temos que nos preocupar com a colinearidade entre as variáveis de controle. Naturalmente, nós as estamos controlando primariamente porque entendemos que elas estão correlacionadas com a frequência, mas isso é necessário para que possamos fazer uma análise *ceteris paribus*.

## CAPÍTULO 4

---

### QUESTÃO 4.1

Sob essas hipóteses, as hipóteses de Gauss-Markov serão satisfeitas:  $u$  é independente das variáveis explicativas, de modo que  $E(u|x_1, \dots, x_k) = E(u)$  e  $\text{Var}(u|x_1, \dots, x_k) = \text{Var}(u)$ . Além disso, é fácil verificar que  $E(u) = 0$ . Portanto, RLM.3 e RLM.5 se sustentam. As hipóteses do modelo linear clássico não serão satisfeitas, pois  $u$  não é normalmente distribuído (o que viola RLM.6).

### QUESTÃO 4.2

$H_0: \beta_1 = 0, H_1: \beta_1 < 0$ .

### QUESTÃO 4.3

Como  $\hat{\beta}_1 = 0,56 > 0$  e estamos testando  $H_0$  contra  $H_1: \beta_1 > 0$ , o  $p$ -valor unilateral é a metade do  $p$ -valor bilateral, ou 0,043.

### QUESTÃO 4.4

$H_0: \beta_5 = \beta_6 = \beta_7 = \beta_8 = 0$ .  $k = 8$  e  $q = 4$ . A versão restrita do modelo é

$$nota = \beta_0 + \beta_1 tclasse + \beta_2 gasto + \beta_3 tosalp + \beta_4 matricl + u.$$

### QUESTÃO 4.5

A estatística  $F$  para testar a exclusão de *tac* é  $[(0,291 - 0,183)/(1 - 0,291)](680 - 3) \approx 103,13$ . Portanto, o valor absoluto da estatística  $t$  estará em torno de 10,16. A estatística  $t$  de *tac* será negativa, pois  $\hat{\beta}_{tac}$  é negativo, de modo que  $t_{tac} = -10,16$ .

**QUESTÃO 4.6**

Não muito. O teste  $F$  da significância conjunta de *taxevas* e *taxform* é facilmente computado a partir dos  $R$ -quadrados da tabela:  $F = [(0,361 - 0,353)/(1 - 0,361)](402/2) \approx 2,52$ . O valor crítico de 10% é obtido da Tabela G.3(a) como 2,30, enquanto o valor crítico de 5% da Tabela G.3(b) é 3. O  $p$ -valor está em torno de 0,082. Portanto, *taxevas* e *taxform* são conjuntamente significantes ao nível de 10%, mas não ao nível de 5%. Em qualquer caso, o controle dessas variáveis tem um efeito modesto sobre o coeficiente  $b/s$ .

**CAPÍTULO 5****QUESTÃO 5.1**

Isso requer algumas suposições. Parece razoável assumir que  $\beta_2 > 0$  (*nota* depende positivamente de *nmgradp*) e  $\text{Cov}(\textit{faltas}, \textit{nmgradp}) < 0$  (*faltas* e *nmgradp* são negativamente correlacionados); isso significa que  $\beta_2\delta_1 < 0$ , o que quer dizer que  $\text{plim } \tilde{\beta}_1 < \beta_1$ . Como  $\beta_1$  é entendido como negativo (ou pelo menos não-positivo), uma regressão simples provavelmente superestimar a importância de *faltar às aulas*.

**QUESTÃO 5.2**

$\hat{\beta}_j \pm 1,96\text{ep}(\hat{\beta}_j)$  é o intervalo de confiança assintótico de 95%. Ou podemos substituir 1,96 por 2.

**CAPÍTULO 6****QUESTÃO 6.1**

Como  $\textit{rendfamdol} = 1.000 \cdot \textit{rendfam}$ , o coeficiente de *rendfamdol* será o coeficiente de *rendfam* dividido por 1.000, ou  $0,0927/1.000 = 0,0000927$ . O erro-padrão também diminui por um fator de 1.000, e assim a estatística  $t$  não se altera, nem tampouco qualquer das outras estatísticas MQO. Para melhor leitura, é preferível medir a renda familiar em milhares de dólares.

**QUESTÃO 6.2**

Podemos responder de forma geral. A equação é

$$\log(y) = \beta_0 + \beta_1 \log(x_1) + \beta_2 x_2 + \dots,$$

onde  $x_2$  é uma proporção, em vez de um percentual. Então, *ceteris paribus*,  $\Delta \log(y) = \beta_2 \Delta x_2$ ,  $100 \cdot \Delta \log(y) = \beta_2 (100 \cdot \Delta x_2)$ , ou  $\% \Delta y \approx \beta_2 (100 \cdot \Delta x_2)$ . Agora, como  $\Delta x_2$  é a alteração na proporção,  $100 \cdot \Delta x_2$  é a alteração em pontos percentuais. Em particular, se  $\Delta x_2 = 0,01$ , então,  $100 \cdot \Delta x_2 = 1$ , que corresponde a uma alteração de um ponto percentual. Mas, então,  $\beta_2$  será a alteração percentual em  $y$  quando  $100 \cdot \Delta x_2 = 1$ .

**QUESTÃO 6.3**

O novo modelo seria  $\textit{respad} = \beta_0 + \beta_1 \textit{taxafreq} + \beta_2 \textit{nmgradp} + \beta_3 \textit{tac} + \beta_4 \textit{nmgradp}^2 + \beta_5 \textit{tac}^2 + \beta_6 \textit{nmgradp} \cdot \textit{taxafreq} + \beta_7 \textit{tac} \cdot \textit{taxafreq} + u$ . Portanto, o efeito parcial de *taxafreq* sobre *respad* é  $\beta_1 + \beta_6 \textit{nmgradp} + \beta_7 \textit{tac}$ . É isso que multiplicamos por  $\Delta \textit{taxafreq}$  para obter a alteração *ceteris paribus* em *respad*.

**QUESTÃO 6.4**

Da equação (6.21),  $\bar{R}^2 = 1 - \hat{\sigma}^2/[SQT/(n - 1)]$ . Para uma determinada amostra e uma determinada variável dependente,  $SQT/(n - 1)$  é fixo. Quando usamos conjuntos diferentes de variáveis explicativas, somente  $\hat{\sigma}^2$  é alterado. Conforme  $\hat{\sigma}^2$  diminui,  $\bar{R}^2$  aumenta. Se tornarmos  $\hat{\sigma}$ , e conseqüentemente  $\hat{\sigma}^2$ , tão pequeno quanto possível, estaremos tornando  $\bar{R}^2$  tão grande quanto possível.

**QUESTÃO 6.5**

Uma possibilidade seria coletar dados sobre rendimentos anuais de um grupo de atores com a lucratividade dos filmes nos quais cada um deles apareceu. Em uma análise de regressão simples, poderíamos relacionar os rendimentos à lucratividade. Mas provavelmente teríamos de controlar outros fatores que podem afetar os salários, tais como a idade, o sexo e os tipos de filmes nos quais os atores trabalharam. Os métodos para a inclusão de fatores qualitativos em modelos de regressão estão considerados no Capítulo 7.

**CAPÍTULO 7**

---

**QUESTÃO 7.1**

Não, pois não ficaria claro quando *partido* seria um ou zero. Um nome melhor seria algo como *Dem*, que seria um para os candidatos Democratas, e zero, para os Republicanos. Ou *Rep*, que seria um para os Republicanos, e zero, para os Democratas.

**QUESTÃO 7.2**

Com *jardtext* como o grupo base, incluiríamos as variáveis *dummy pribase*, *segbase*, *terbase*, *interbase* e *receptor*.

**QUESTÃO 7.3**

A hipótese nula neste caso seria  $H_0: \delta_1 = \delta_2 = \delta_3 = \delta_4 = 0$ , de forma a haver quatro restrições. Como sempre, usaríamos um teste *F* (onde  $q = 4$  e  $k$  dependerá do número de outras variáveis explicativas).

**QUESTÃO 7.4**

Como *perm* aparece na forma quadrática, deveríamos permitir termos quadráticos diferentes para homens e mulheres. Isto é, adicionaríamos as variáveis explicativas *feminino · perm* e *feminino · perm<sup>2</sup>*.

**QUESTÃO 7.5**

Agregamos *pcond* = 0, *sentmed* = 0, *temptot* = 0, *ptemp86* = 0, *empr86* = 4, *negro* = 1 e *hispan* = 0 em (7.31):  $\hat{pr}86 = 0,380 - 0,038(4) + 0,170 = 0,398$ , ou quase 0,4. É difícil saber se isso é “razoável”. Para alguém que nunca tenha sido condenado, que estava empregado durante todo o ano, essa estimativa parece ser alta, mas lembre-se de que a população consiste de homens que já foram presos pelo menos uma vez antes de 1986.

**CAPÍTULO 8**

---

**QUESTÃO 8.1**

Essa declaração é claramente falsa. Por exemplo, na equação (8.7), o erro-padrão usual de *negro* é 0,147, enquanto o erro-padrão robusto em relação à heteroscedasticidade é 0,118.

**QUESTÃO 8.2**

O teste  $F$  seria obtido pela regressão de  $\hat{u}^2$  sobre *hcasados*, *mcasadas* e *msolteiras* (*hsolteiros* é o grupo base). Com  $n = 526$  e três variáveis independentes nessa regressão, os *gl* serão 3 e 522.

**QUESTÃO 8.3**

Na realidade, não. Como esse é um modelo de regressão simples, a heteroscedasticidade somente importará se ela estiver relacionada a *renda*. Entretanto, o teste de Breusch-Pagan nesse caso é equivalente a uma estatística  $t$  na regressão de  $\hat{u}^2$  sobre *renda*. Uma estatística  $t$  de 0,96 não é suficientemente grande para rejeitar a hipótese de homoscedasticidade.

**QUESTÃO 8.4**

Podemos usar os mínimos quadrados ponderados, mas computando os erros-padrão robustos em relação à heteroscedasticidade. Na equação (8.26), se nosso modelo da variância estiver incorreto, ainda teremos heteroscedasticidade. Assim, poderemos fazer uma suposição sobre a forma de heteroscedasticidade e executar o MQP, mas nossa análise poderá se tornar robusta quanto a formas incorretas de heteroscedasticidade.

**CAPÍTULO 9**

---

**QUESTÃO 9.1**

Elas são variáveis binárias, e elevá-las ao quadrado não produzirá nenhum efeito:  $negro^2 = negro$  e  $hispan^2 = hispan$ .

**QUESTÃO 9.2**

Quando  $educ \cdot QI$  está na equação, o coeficiente de *educ*, digamos  $\beta_1$ , indica o efeito de *educ* sobre  $\log(\text{salário})$  quando  $QI = 0$ . (O efeito parcial da educação é  $\beta_1 + \beta_9 QI$ ). Não há ninguém na população de interesse com um QI próximo de zero. No QI médio da população, que é 100, o retorno estimado da educação da coluna (3) é  $0,018 + 0,00034(100) = 0,052$ , que é quase o que obtemos como o coeficiente de *educ* na coluna (2).

**QUESTÃO 9.3**

Não. Se  $educ^*$  for um inteiro — o que significa que alguém não tem nenhuma escolaridade após à série anterior concluída —, o erro de medida será zero. Se  $educ^*$  não for um inteiro,  $educ < educ^*$  e, assim, o erro de medida será negativo. No mínimo,  $e_1$  não pode ter média zero, e  $e_1$  e  $educ^*$  provavelmente são correlacionados.

**QUESTÃO 9.4**

A decisão de um candidato de não concorrer pode estar sistematicamente relacionada com o que ele, ou ela, espera fazer na eleição. Portanto, podemos apenas ter uma amostra de candidatos que, na média, sejam mais fortes que todos os demais possíveis candidatos que poderiam concorrer. Isso resulta em um problema de seleção de amostra se a população de interesse incluir todos os candidatos. Se estivermos apenas interessados nos efeitos dos gastos de campanha sobre os resultados eleitorais dos concorrentes que estão tentando a reeleição, não haverá problema de seleção de amostra.

## CAPÍTULO 10

---

### QUESTÃO 10.1

A propensão de impacto é 0,48, enquanto a propensão de longo prazo é  $0,48 - 0,15 + 0,32 = 0,65$ .

### QUESTÃO 10.2

As variáveis explicativas são  $x_{t1} = z_t$  e  $x_{t2} = z_{t-1}$ . A ausência de colinearidade perfeita significa que elas não podem ser constantes, e não pode haver uma relação linear perfeita entre elas na amostra. Isso elimina a possibilidade de que todos os  $z_1, \dots, z_n$  assumam o mesmo valor ou que  $z_0, z_1, \dots, z_{n-1}$  assumam o mesmo valor. Mas isso também elimina outros padrões. Por exemplo, se  $z_t = a + bt$  para as constantes  $a$  e  $b$ , então,  $z_{t-1} = a + b(t-1) = (a + bt) - b = z_t - b$ , que é uma função linear perfeita de  $z_t$ .

### QUESTÃO 10.3

Se  $\{z_t\}$  estiver se movendo lentamente ao longo do tempo — como no caso dos níveis ou logs de muitas séries temporais econômicas —, então,  $z_t$  e  $z_{t-1}$  poderão ser altamente correlacionados. Por exemplo, a correlação entre  $desemp_t$  e  $desemp_{t-1}$  do arquivo PHILLIPS.RAW é 0,74.

### QUESTÃO 10.4

Não, pois uma tendência linear com  $\alpha_1 < 0$  se tornará cada vez mais negativa conforme  $t$  aumenta. Como  $tgf$  não pode ser negativo, uma tendência temporal linear com um coeficiente de tendência negativo não poderá representar  $tgf$  em todos os futuros períodos de tempo.

### QUESTÃO 10.5

O intercepto de março é  $\beta_0 + \delta_2$ . Variáveis *dummy* sazonais são estritamente exógenas porque elas seguem um padrão determinista. Por exemplo, os meses não se alteram se as variáveis explicativas ou a variável dependente se alterarem.

## CAPÍTULO 11

---

### QUESTÃO 11.1

(i) Não, pois  $E(y_t) = \delta_0 + \delta_1 t$  depende de  $t$ . (ii) Sim, pois  $y_t - E(y_t) = e_t$  é uma seqüência i.i.d.

### QUESTÃO 11.2

Agregamos  $inf_t^e = (1/2)inf_{t-1} + (1/2)inf_{t-2}$  em  $inf_t - inf_t^e = \beta_1(desemp_t - \mu_0) + e_t$  e reorganizamos:  $inf_t - (1/2)(inf_{t-1} + inf_{t-2}) = \beta_0 + \beta_1 desemp_t + e_t$ , onde  $\beta_0 = -\beta_1 \mu_0$ , como antes. Portanto, faríamos a regressão de  $y_t$  sobre  $desemp_t$ , onde  $y_t = inf_t - (1/2)(inf_{t-1} + inf_{t-2})$ . Observe que perdemos as primeiras duas observações na construção de  $y_t$ .

### QUESTÃO 11.3

Não, pois  $u_t$  e  $u_{t-1}$  são correlacionados. Em particular,  $Cov(u_t, u_{t-1}) = E[(e_t + \alpha_1 e_{t-1})(e_{t-1} + \alpha_1 e_{t-2})] = \alpha_1 E(e_{t-1}^2) = \alpha_1 \sigma_e^2 \neq 0$  se  $\alpha_1 \neq 0$ . Se os erros forem serialmente correlacionados, o modelo não poderá ser dinamicamente completo.

## CAPÍTULO 12

### QUESTÃO 12.1

Usamos a equação (12.4). Agora, somente termos adjacentes são correlacionados. Em particular, a covariância entre  $x_t u_t$  e  $x_{t+1} u_{t+1}$  é  $x_t x_{t+1} \text{Cov}(u_t, u_{t+1}) = x_t x_{t+1} \alpha \sigma_e^2$ . Portanto, a fórmula é

$$\begin{aligned} \text{Var}(\hat{\beta}_1) &= \text{SQT}_x^{-2} \left( \sum_{t=1}^n x_t^2 \text{Var}(u_t) + 2 \sum_{t=1}^{n-1} x_t x_{t+1} \text{E}(u_t u_{t+1}) \right) \\ &= \sigma^2 / \text{SQT}_x + (2 / \text{SQT}_x^2) \sum_{t=1}^{n-1} \alpha \sigma_e^2 x_t x_{t+1} \\ &= \sigma^2 / \text{SQT}_x + \alpha \sigma_e^2 (2 / \text{SQT}_x^2) \sum_{t=1}^{n-1} x_t x_{t+1}, \end{aligned}$$

onde  $\sigma^2 = \text{Var}(u_t) = \sigma_e^2 + \alpha_1^2 \sigma_e^2 = \sigma_e^2(1 + \alpha_1^2)$ . A menos que  $x_t$  e  $x_{t+1}$  sejam não-correlacionados na amostra, o segundo termo será diferente de zero sempre que  $\alpha \neq 0$ . Observe que, se  $x_t$  e  $x_{t+1}$  forem positivamente correlacionadas e  $\alpha < 0$ , a verdadeira variância será efetivamente *menor* que a variância habitual. Quando a equação estiver em níveis (em oposição a estar diferenciada), o caso geral será  $\alpha > 0$ , com correlação positiva entre  $x_t$  e  $x_{t+1}$ .

### QUESTÃO 12.2

$\hat{\rho} \pm 1,96 \text{ep}(\hat{\rho})$ , onde  $\text{ep}(\hat{\rho})$  é o erro-padrão informado na regressão. Ou poderíamos usar os erros-padrão robustos em relação à heteroscedasticidade. É complicado mostrar que isso é assintoticamente válido porque os resíduos MQO dependem de  $\hat{\beta}_j$ , mas isso pode ser feito.

### QUESTÃO 12.3

O modelo que temos em mente é  $u_t = \rho_1 u_{t-1} + \rho_4 u_{t-4} + e_t$ , e queremos testar  $H_0: \rho_1 = 0, \rho_4 = 0$  contra a alternativa de que  $H_0$  é falsa. Computaríamos a regressão de  $\hat{u}_t$  sobre  $\hat{u}_{t-1}$  e  $\hat{u}_{t-4}$  para obter a estatística  $F$  habitual para a significância conjunta das duas defasagens. (Estamos testando duas restrições.)

### QUESTÃO 12.4

Provavelmente estimaríamos a equação utilizando primeiras diferenças, já que  $\hat{\rho} = 0,92$  está suficientemente próximo de 1 para levantar questionamentos sobre a regressão em níveis. Veja mais explicações no Capítulo 18.

### QUESTÃO 12.5

Como existe somente uma variável explicativa, o teste de White é fácil de ser computado. Simplesmente regressamos  $\hat{u}_t^2$  sobre  $\text{retorno}_{t-1}$  e  $\text{retorno}_{t-1}^2$  (com um intercepto, como sempre) e computamos o teste  $F$  para a significância conjunta de  $\text{retorno}_{t-1}$  e  $\text{retorno}_{t-1}^2$ . Se elas forem conjuntamente significantes a um nível de significância suficientemente pequeno, rejeitamos a hipótese nula da homoscedasticidade.

## CAPÍTULO 13

---

### QUESTÃO 13.1

Sim, supondo que tenhamos controlado todos os fatores relevantes. O coeficiente de *negro* é 1,076 e, com um erro-padrão de 0,174, ele não é estatisticamente diferente de um. O intervalo de confiança de 95% está entre 0,735 e 1,417.

### QUESTÃO 13.2

O coeficiente de *altrend* mostra que, na ausência de qualquer alteração no limite dos ganhos, os trabalhadores com renda mais elevada passam muito mais tempo — cerca de 29,2%, em média [pois  $\exp(0,256) - 1 \approx 0,292$ ] — recebendo remuneração por conta de indenização trabalhista.

### QUESTÃO 13.3

Primeiro,  $E(v_{i1}) = E(a_i + u_{i1}) = E(a_i) + E(u_{i1}) = 0$ . De forma semelhante,  $E(v_{i2}) = 0$ . Portanto, a covariância entre  $v_{i1}$  e  $v_{i2}$  é simplesmente  $E(v_{i1}v_{i2}) = E[(a_i + u_{i1})(a_i + u_{i2})] = E(a_i^2) + E(a_i u_{i1}) + E(a_i u_{i2}) + E(u_{i1}u_{i2}) = E(a_i^2)$ , pois todos os termos da covariância são zero por hipótese. Contudo,  $E(a_i^2) = \text{Var}(a_i)$ , pois  $E(a_i) = 0$ . Isso causa correlação serial positiva nos erros ao longo do tempo no interior de cada  $i$ , que produz viés nos erros-padrão MQO habituais em uma regressão MQO agrupada.

### QUESTÃO 13.4

Como  $\Delta \text{admin} = \text{admin}_{90} - \text{admin}_{85}$  é a diferença nos indicadores binários, ela poderá ser  $-1$  se, e somente se,  $\text{admin}_{90} = 0$  e  $\text{admin}_{85} = 1$ . Em outras palavras, o estado de Washington tinha uma lei administrativa propriamente dita em 1985, mas ela foi revogada em 1990.

### QUESTÃO 13.5

Não, da mesma forma em que ela não causa viés e inconsistência em uma regressão de série temporal com variáveis explicativas estritamente exógenas. Há duas razões para ela ser preocupante. Primeira, a correlação serial nos erros em qualquer equação geralmente causa viés nos erros-padrão MQO e nas estatísticas de testes usuais. Segunda, ela significa que o MQO agrupado não é tão eficiente quanto os estimadores que levam em conta a correlação serial (como no Capítulo 12).

## CAPÍTULO 14

---

### QUESTÃO 14.1

Quer usemos a primeira diferenciação ou a transformação interna, teremos problema com a estimativa do coeficiente de  $kids_{it}$ . Por exemplo, usando a transformação interna, se  $kids_{it}$  não variar para a família  $i$ , então,  $\ddot{kids}_{it} = kids_{it} - kids_i = 0$  para  $t = 1, 2, 3$ . Desde que algumas famílias apresentem variação em  $kids_{it}$ , então, poderemos computar o estimador de efeitos fixos, mas o coeficiente de  $kids$  poderá ser estimado de modo muito impreciso. Essa é uma forma de multicolinearidade na estimação de efeitos fixos (ou na estimação de primeira diferenciação).

### QUESTÃO 14.2

Se uma firma não recebeu um subsídio no primeiro ano, ela poderá ou não receber um subsídio no segundo ano. Entretanto, se uma firma efetivamente recebeu um subsídio no primeiro ano, ela não poderá obter outro subsídio no segundo ano. Isto é, se  $subs_{-1} = 1$ , então,  $subs = 0$ . Isso induz uma correlação negativa entre  $subs$  e  $subs_{-1}$ . Podemos verificar isso fazendo a regressão de  $subs$  sobre

$subs_{-1}$ , usando os dados contidos no arquivo JTRAIN.RAW de 1989. Se usarmos todas as firmas da amostra, teremos

$$\begin{aligned} \hat{s}ubs &= 0,248 - 0,248 \, subs_{-1} \\ &\quad (0,035) \quad (0,072) \\ n &= 157, R^2 = 0,070. \end{aligned}$$

O coeficiente de  $subs_{-1}$  deve ser o negativo do intercepto, pois  $\hat{s}ubs = 0$  quando  $subs_{-1} = 1$ .

### QUESTÃO 14.3

Isso sugere que o efeito não observado  $a_i$  é positivamente correlacionado com  $sindicato_{it}$ . Lembre-se, o MQO agrupado deixa  $a_i$  no termo erro, enquanto os efeitos fixos removem  $a_i$ . Por definição,  $a_i$  tem um efeito positivo sobre  $\log(salário)$ . Pela análise padrão de variáveis omitidas (veja o Capítulo 3), o MQO tem um viés para cima quando a variável explicativa ( $sindicato$ ) for positivamente correlacionada com a variável omitida ( $a_i$ ). Assim, o fato de pertencer a um sindicato parece ser positivamente relacionado com fatores não observados, constantes no tempo, que afetam o salário.

### QUESTÃO 14.4

Não, se todas as irmãs de uma mesma família tiverem a mesma mãe e o mesmo pai. Então, como as variáveis referentes à raça dos pais não variarão por irmã, elas seriam eliminadas pela diferenciação em (14.13).

## CAPÍTULO 15

---

### QUESTÃO 15.1

Provavelmente, não. Na equação simples (15.18), anos de escolaridade é parte do termo erro. Se alguns dos homens que receberam números baixos no sorteio militar obtivessem maior escolaridade, então, os números do sorteio militar e a educação seriam negativamente correlacionados, o que violaria o primeiro requisito de uma variável instrumental na equação (15.4).

### QUESTÃO 15.2

(i) Para (15.27), precisamos de que os efeitos do grupo de colegas do ensino médio se estenda para a faculdade. Quer dizer, para uma determinada nota  $sat$ , um estudante que frequentou uma escola de ensino médio onde fumar maconha era mais comum, fumaria mais maconha na faculdade. Mesmo que a condição de identificação (15.27) se mantenha, a ligação pode ser fraca.

(ii) Temos que assumir que a porcentagem de estudantes que fumava maconha em uma escola de ensino médio não está correlacionada com fatores não observados que afetam a nota média no curso superior. Embora estejamos, até certo ponto, controlando a qualidade do ensino médio ao incluirmos  $sat$  na equação, isso pode não ser suficiente. Talvez as escolas de ensino médio que tenham feito um melhor trabalho na preparação dos estudantes para a universidade também tenham tido um menor número de alunos que fumavam maconha. Ou, o uso de maconha poderia estar correlacionado com os níveis médios de renda. Naturalmente, essas são questões empíricas que podem ou não ser respondidas.

**QUESTÃO 15.3**

Embora a predominância da *National Rifle Association* e os assinantes de revistas sobre armas estejam provavelmente correlacionados com a presença de leis de controle de armas, não é óbvio que eles sejam não-correlacionados com outros fatores não observados que afetem a taxa de crimes violentos. De fato, podemos argumentar que uma população interessada em armas seja um reflexo das elevadas taxas de criminalidade, e que o controle de variáveis econômicas e demográficas não seja suficiente para capturar esse aspecto. Seria difícil sustentar de forma persuasiva que elas são realmente exógenas na equação de crimes violentos.

**QUESTÃO 15.4**

Como sempre, existem dois requisitos. Primeiro, poderia ser o caso de que o crescimento dos gastos governamentais esteja sistematicamente relacionado ao partido do presidente, após a remoção da taxa de investimento e o crescimento da força de trabalho. Em outras palavras, a variável instrumental deve ser parcialmente correlacionada com a variável explicativa endógena. Embora possamos imaginar que os gastos governamentais cresçam mais lentamente em governos com presidentes Republicanos, isso certamente não tem sido sempre verdade nos Estados Unidos e teria que ser testado usando a estatística  $t$  de  $REP_{t-1}$  na forma reduzida  $cGOV_t = \pi_0 + \pi_1 REP_{t-1} + \pi_2 RAZINV_t + \pi_3 TRAB_t + v_t$ . Devemos assumir que o partido do presidente não tem efeito separado sobre  $cPIB$ . Isso seria violado se, por exemplo, a política monetária diferisse sistematicamente por partido presidencial e tivesse um efeito separado sobre o crescimento do PIB.

**CAPÍTULO 16**

---

**QUESTÃO 16.1**

Provavelmente, não. É pelo fato de as empresas escolherem preços e gastos com publicidade de forma conjunta que não estamos interessados no experimento no qual, digamos, a publicidade é alterada de forma exógena e queremos saber o efeito sobre o preço. Em vez disso, modelaríamos preço e publicidade cada um como uma função de variáveis de demanda e custo. Isso é o que resulta da teoria econômica.

**QUESTÃO 16.2**

Devemos assumir duas coisas. Primeiro, o crescimento da oferta de moeda deve aparecer na equação (16.22), de forma a ser parcialmente correlacionado com  $inf$ . Segundo, devemos assumir que o crescimento da oferta de moeda não aparece na equação (16.23). Se entendermos que devemos incluir o crescimento da oferta de moeda na equação (16.23), então, ainda nos faltará uma variável instrumental de  $inf$ . Naturalmente, a hipótese de que o crescimento da oferta de moeda é exógeno também poderá ser questionada.

**QUESTÃO 16.3**

Use o teste de Hausman do Capítulo 15. Em particular, defina  $\hat{v}_2$  como os resíduos MQO da forma reduzida da regressão de *abertura* sobre  $\log(rendpc)$  e sobre  $\log(\acute{a}rea)$ . Depois, use uma regressão por MQO de  $inf$  sobre *abertura*,  $\log(rendpc)$  e  $\hat{v}_2$ , e compute a estatística  $t$  para a significância de  $\hat{v}_2$ . Se  $\hat{v}_2$  for significativo, as estimativas MQ2E e MQO serão estatisticamente diferentes.

**QUESTÃO 16.4**

A equação da demanda se parecerá com

$$\log(\text{peixe}_t) = \beta_0 + \beta_1 \log(\text{prpeixe}_t) + \beta_2 \log(\text{renda}_t) \\ + \beta_3 \log(\text{prfrango}_t) + \beta_4 \log(\text{prcarne}_t) + u_{t1},$$

onde os logaritmos são usados de forma a tornar todas as elasticidades constantes. Por hipótese, a função de demanda não contém sazonalidade, de modo que a equação não contém variáveis *dummy* mensais (digamos,  $\text{fev}_t, \text{mar}_t, \dots, \text{dez}_t$ , com janeiro como o mês base). Também por hipótese, a oferta de peixe é sazonal, o que significa que a função de oferta depende de pelo menos algumas das variáveis *dummy* mensais. Mesmo sem solucionar a forma reduzida de  $\log(\text{prpeixe})$ , concluímos que ela depende das variáveis *dummy* mensais. Como elas são exógenas, poderão ser usadas como instrumentais de  $\log(\text{prpeixe})$  na equação de demanda. Portanto, podemos estimar a equação de demanda por peixe usando as *dummies* mensais como VIs de  $\log(\text{prpeixe})$ . A identificação exige que pelo menos uma variável *dummy* mensal apareça com um coeficiente diferente de zero na forma reduzida de  $\log(\text{prpeixe})$ .

## CAPÍTULO 17

---

### QUESTÃO 17.1

$H_0: \beta_4 = \beta_5 = \beta_6 = 0$ , de forma que existem três restrições e, portanto, três *gl* na *RV* ou no teste de Wald.

### QUESTÃO 17.2

Precisamos da derivada parcial de  $\Phi(\hat{\beta}_0 + \hat{\beta}_1 \text{nesprend} + \hat{\beta}_2 \text{educ} + \hat{\beta}_3 \text{exper} + \hat{\beta}_4 \text{exper}^2 + \dots)$  em relação a *exper*, que é  $\phi(\cdot)(\hat{\beta}_3 + 2\hat{\beta}_4 \text{exper})$ , onde  $\phi(\cdot)$  é avaliada nos valores dados e no nível inicial de experiência. Portanto, precisamos avaliar a densidade de probabilidade normal padrão em  $0,270 - 0,012(20,13) + 0,131(12,3) + 0,123(10) - 0,0019(10^2) - 0,053(42,5) - 0,868(0) + 0,036(1) \approx 0,463$ , onde agregamos o nível inicial de experiência (10). Contudo,  $\phi(0,463) = (2\pi)^{-1/2} \exp[-(0,463^2)/2] \approx 0,358$ . Em seguida, multiplicamos isso por  $\hat{\beta}_3 + 2\hat{\beta}_4 \text{exper}$ , que é avaliada em *exper* = 10. O efeito parcial usando a aproximação do cálculo é  $0,358[0,123 - 2(0,0019)(10)] \approx 0,030$ . Em outras palavras, nos valores dados das variáveis explicativas e começando com *exper* = 10, o próximo ano de experiência aumentará a probabilidade de participação na força de trabalho em cerca de 0,03.

### QUESTÃO 17.3

Não. O número de casos extraconjugais é um inteiro não negativo, que presumivelmente assume o valor zero ou números baixos para uma fração substancial da população. Não seria realista usar um modelo Tobit que, embora possibilite um acúmulo de zeros, trata *y* como continuamente distribuída sobre valores positivos. Formalmente, supondo que  $y = \max(0, y^*)$ , onde  $y^*$  é normalmente distribuído, isso estará em desacordo com a natureza discreta do número de casos extraconjugais quando  $y > 0$ .

### QUESTÃO 17.4

Os erros-padrão ajustados são os erros-padrão habituais da EMV de Poisson multiplicados por  $\hat{\sigma} = \sqrt{2} \approx 1,41$ , de modo que os erros-padrão ajustados serão cerca de 41% mais elevados. A estatística quase-*RV* é a estatística *RV* usual dividida por  $\hat{\sigma}^2$  e, portanto, ela será a metade da estatística *RV* habitual.

### QUESTÃO 17.5

Por hipótese,  $\text{vmp}_i = \beta_0 + \mathbf{x}_i \boldsymbol{\beta} + u_i$ , onde, como sempre,  $\mathbf{x}_i \boldsymbol{\beta}$  representa uma função linear das variáveis exógenas. Agora, o salário observado é o maior entre o salário mínimo e o valor do produto mar-

ginal, de forma que  $salário_t = \max(salmín_t, vpm_t)$ , o que é muito semelhante à equação (17.34), exceto pelo fato de que o operador  $\max$  substituiu o operador  $\min$ .

## CAPÍTULO 18

### QUESTÃO 18.1

Podemos agregar esses valores diretamente na equação (18.1) e considerarmos as expectativas. Primeiro, porque  $z_s = 0$ , para todo  $s < 0$ ,  $y_{-1} = \alpha + u_{-1}$ . Então,  $z_0 = 1$  e, portanto,  $y_0 = \alpha + \delta_0 + u_0$ . Para  $h \geq 1$ ,  $y_h = \alpha + \delta_{h-1} + \delta_h + u_h$ . Como os erros têm zeros como valores esperados,  $E(y_{-1}) = \alpha$ ,  $E(y_0) = \alpha + \delta_0$  e  $E(y_h) = \alpha + \delta_{h-1} + \delta_h$ , para todo  $h \geq 1$ . Conforme  $h \rightarrow \infty$ ,  $\delta_h \rightarrow 0$ . Por conseguinte,  $E(y_h) \rightarrow \alpha$  conforme  $h \rightarrow \infty$ , isto é, o valor esperado de  $y_h$  retorna ao valor esperado antes do aumento de  $z$ , no momento zero. Isso faz sentido: embora o aumento de  $z$  tenha durado dois períodos, ele ainda é um aumento temporário.

### QUESTÃO 18.2

Sob a estrutura descrita,  $\Delta y_t$  e  $\Delta x_t$  são seqüências i.i.d. independentes entre si. Particularmente,  $\Delta y_t$  e  $\Delta x_t$  são não-correlacionados. Se  $\hat{\gamma}_1$  é o coeficiente de inclinação da regressão de  $\Delta y_t$  sobre  $\Delta x_t$ ,  $t = 1, 2, \dots, n$ , então,  $\text{plim } \hat{\gamma}_1 = 0$ . Esse resultado é o que deveria ser, já que estamos fazendo a regressão de um processo  $I(0)$  sobre outro processo  $I(0)$ , e eles são não-correlacionados. Escrevemos a equação  $\Delta y_t = \gamma_0 + \gamma_1 \Delta x_t + e_t$ , onde  $\gamma_0 = \gamma_1 = 0$ . Como  $\{e_t\}$  é independente de  $\{\Delta x_t\}$ , a hipótese de exogeneidade estrita se mantém. Além disso,  $\{e_t\}$  é serialmente não-correlacionado e homoscedástico. Pelo Teorema 11.2 do Capítulo 12, a estatística  $t$  para  $\hat{\gamma}_1$  tem uma distribuição normal padrão aproximada. Se  $e_t$  for normalmente distribuído, as hipóteses do modelo linear clássico se manterão, e a estatística  $t$  terá uma distribuição exata.

### QUESTÃO 18.3

Escreva  $x_t = x_{t-1} + a_t$ , onde  $\{a_t\}$  é  $I(0)$ . Por hipótese, existe uma combinação linear, digamos,  $s_t = y_t - \beta x_t$ , que é  $I(0)$ . Agora,  $y_t - \beta x_{t-1} = y_t - \beta(x_t - a_t) = s_t + \beta a_t$ . Como  $s_t$  e  $a_t$  são  $I(0)$  por hipótese,  $s_t + \beta a_t$  também será  $I(0)$ .

### QUESTÃO 18.4

Simplemente use a forma da soma dos resíduos quadrados do teste  $F$  e assuma homoscedasticidade. A SQR restrita é obtida regredindo  $\Delta hy_6t - \Delta hy_3t_{-1} + (hy_6t_{-1} - hy_3t_{-2})$  sobre uma constante. Observe que  $\alpha_0$  é o único parâmetro a ser estimado em  $\Delta hy_6t = \alpha_0 + \gamma_0 \Delta hy_3t_{-1} + \delta(hy_6t_{-1} - hy_3t_{-2})$ , quando as restrições são impostas. A soma dos resíduos quadrados irrestrita é obtida pela equação (18.39).

### QUESTÃO 18.5

Estamos ajustando duas equações:  $\hat{y}_t = \hat{\alpha} + \hat{\beta}t$  e  $\hat{y}_t = \hat{\gamma} + \hat{\delta}ano_t$ . Podemos obter a relação entre os parâmetros observando que  $ano_t = t + 49$ . Agregando essa informação na segunda equação, produz  $\hat{y}_t = \hat{\gamma} + \hat{\delta}(t + 49) = (\hat{\gamma} + 49\hat{\delta}) + \hat{\delta}t$ . A compatibilização da inclinação e do intercepto com a primeira equação produz  $\hat{\delta} = \hat{\beta}$  — de forma que as inclinações de  $t$  e de  $ano_t$  são idênticas — e  $\hat{\alpha} = \hat{\gamma} + 49\hat{\delta}$ . Geralmente, quando usamos  $ano$  em lugar de  $t$ , o intercepto é alterado, mas a inclinação, não. (Você poderá verificar isso usando um dos conjuntos de dados de séries temporais, como as contidas nos arquivos HSEINV.RAW ou INVEN.RAW.) O uso de  $t$  ou de outro indicador de ano não alterará os valores ajustados e, naturalmente, não alterará as previsões de valores futuros. O intercepto simplesmente se ajustará apropriadamente aos diferentes meios de inclusão de uma tendência na regressão.