

Esta aula

▶ Plano

- ▶ Inclusão de Variáveis Irrelevantes
- ▶ Omissão de Variáveis Relevantes
- ▶ Revisão: Formas Funcionais
- ▶ Testes de Especificação Funcional
- ▶ Variáveis Proxy

▶ Bibliografia

- ▶ Wooldridge, J. M. *Introductory Econometrics: A modern Approach*, 6th Ed.

Inclusão de Variáveis Irrelevantes

Variáveis Irrelevantes

- Considere o seguinte modelo populacional:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + u,$$

Com $\beta_3 = 0$

- Se estimarmos os parâmetros, obtemos:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$$

- Essas são estimativas não-enviesadas dos verdadeiros parâmetros populacionais.

Variáveis Irrelevantes

- Porém lembre-se que:

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SST_j(1 - R_j^2)}$$

- Dessa forma, se a variável irrelevante for correlacionada com as demais variáveis explicativas do modelo, aumentará a variância ou imprecisão na estimação dos parâmetros. Os testes de hipótese tenderão a rejeitar a significância de parâmetros relevantes com maior probabilidade.

Omissão de Variáveis Relevantes

Omissão de Variáveis Relevantes

- Considere o seguinte modelo populacional:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u$$

- Porém, por falta de conhecimento ou de dados, estima-se:

$$\tilde{y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1$$

- Obtemos uma estimativa não-enviesada do impacto de x_1 em y ?

Omissão de Variáveis Relevantes

- A seguinte relação se verifica:

$$\tilde{\beta}_1 = \hat{\beta}_1 + \hat{\beta}_2 \tilde{\delta}_1$$

- Em que δ_1 é o impacto de x_1 em x_2 em uma regressão de x_2 contra x_1

- Portanto, tem-se:

$$\begin{aligned} E(\tilde{\beta}_1) &= E(\hat{\beta}_1 + \hat{\beta}_2 \tilde{\delta}_1) = E(\hat{\beta}_1) + E(\hat{\beta}_2) \tilde{\delta}_1 \\ &= \beta_1 + \beta_2 \tilde{\delta}_1, \end{aligned}$$

- E o Viés é dado por: $\text{Bias}(\tilde{\beta}_1) = E(\tilde{\beta}_1) - \beta_1 = \beta_2 \tilde{\delta}_1$.

Omissão de Variáveis Relevantes

TABLE 3.2 Summary of Bias in $\tilde{\beta}_1$ when x_2 Is Omitted in Estimating Equation (3.40)

	Corr(x_1, x_2) > 0	Corr(x_1, x_2) < 0
$\beta_2 > 0$	Positive bias	Negative bias
$\beta_2 < 0$	Negative bias	Positive bias

Omissão de Variáveis Relevantes

- Caso Geral - Considere o seguinte modelo populacional:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + u$$

- Porém, por falta de conhecimento ou de dados, estima-se:

$$\tilde{y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \tilde{\beta}_2 x_2.$$

- Obtemos uma estimativa não-enviesada do impacto de x_1 em y ?

Omissão de Variáveis Relevantes

➤ Se x_1 e x_2 não forem correlacionadas, tem-se:

$$E(\tilde{\beta}_1) = \beta_1 + \beta_3 \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)x_{i3}}{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2}$$

Revisão: Formas Funcionais

Linearidade

- ▶ Até agora, consideramos o modelo linear:

$$y = \beta_0 + \beta_1 x + u$$

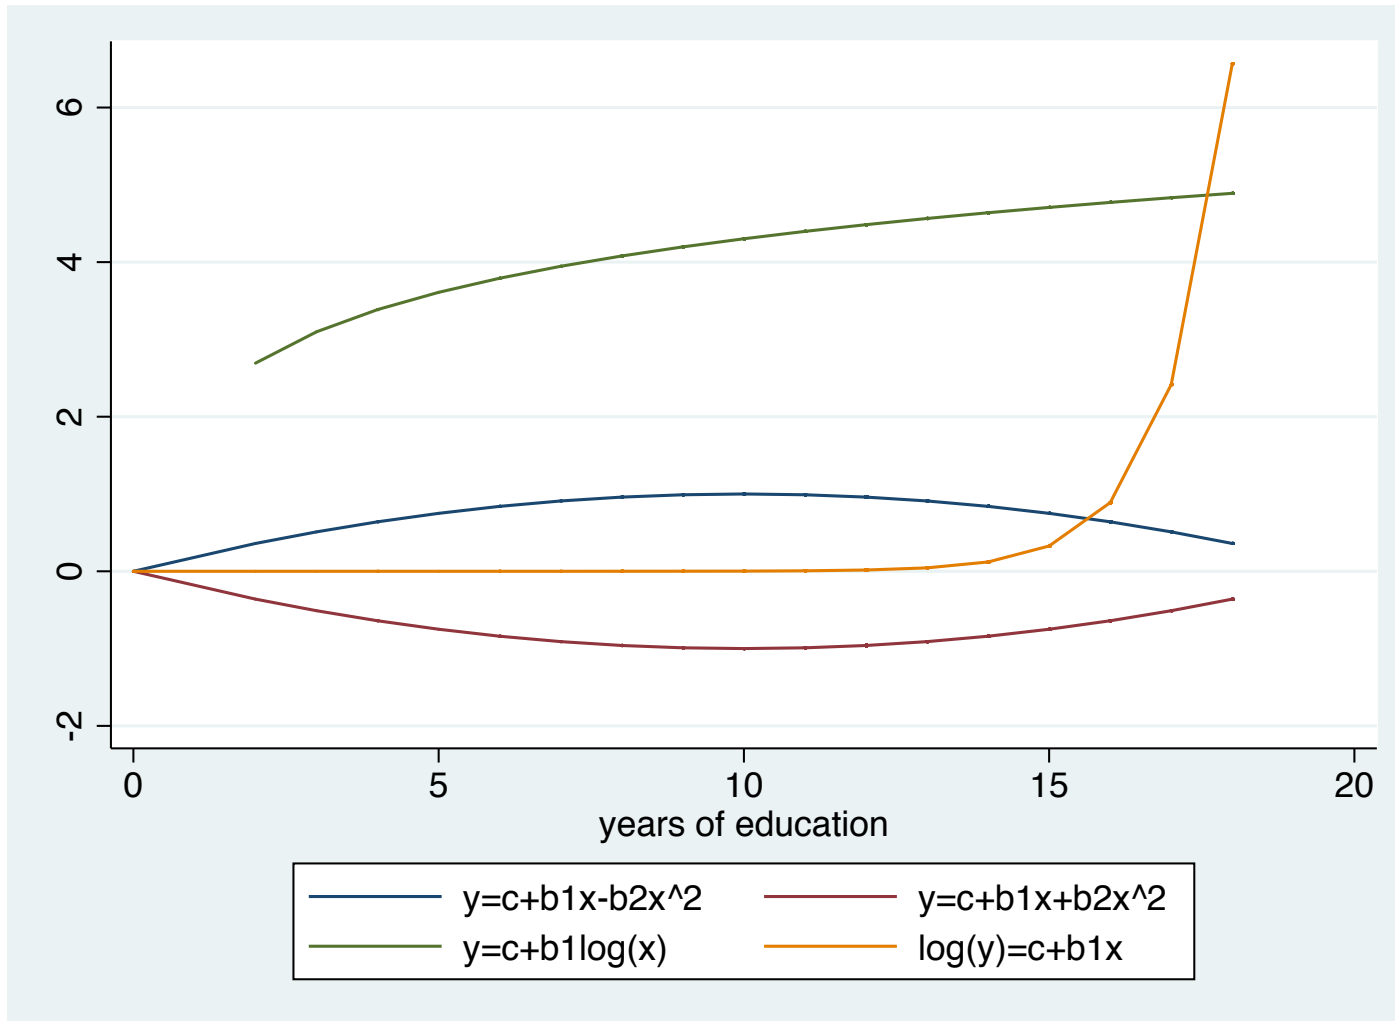
- ▶ Esse modelo preve um impacto constante β_1 , também chamado de efeito marginal de x em y , que independe do valor inicial de x : $\Delta y = \beta_1 \Delta x$

- ▶ Em: $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2$.

$$\Delta y = \beta_1 \Delta x_1 \text{ if } \Delta x_2 = 0$$


- ▶ β_1 é chamado de efeito parcial de x_1 em y

Linearidade



Linearidade

- ▶ É comum fazer-se a regressão de $\log(y)$ contra x . A interpretação do modelo faz mais sentido para muitos problemas em ciências sociais. Em nosso exemplo anterior, teríamos: $\log(wage) = \beta_0 + \beta_1 educ + u$.



Linearidade

- ▶ Utilizando cálculo, é possível demonstrar que:

$$\log(x_1) - \log(x_0) \approx (x_1 - x_0)/x_0 = \Delta x/x_0$$

- ▶ Em $\log(wage) = \beta_0 + \beta_1 educ + u$,


, multiplicando-se por 100 tem-se:

$$\% \Delta wage \approx (100 \cdot \beta_1) \Delta educ.$$

Linearidade

- ▶ Nesse caso, tem-se:

$$\% \Delta wage \approx (100 \cdot \beta_1) \Delta educ.$$




Linearidade

► Função quadrática:

$$y = \beta_0 + \beta_1 x + \beta_2 x^2,$$

FIGURE A.3 Graph of $y = 6 + 8x - 2x^2$.



© Pearson Learning 2013

Linearidade

- ▶ Portanto, em

$$\log(y) = \beta_0 + \beta_1 \log(x)$$

- ▶ $\beta_1 = \partial \log(y) / \partial \log(x)$, sendo aproximadamente a elasticidade de y com relação x

Linearidade

- ▶ Elasticidade de y com relação a x é definida pela variação percentual de y dividida pela variação percentual de x :

$$\frac{\Delta y}{\Delta x} \cdot \frac{x}{y} = \frac{\% \Delta y}{\% \Delta x}$$

- ▶ (Cálculo) A elasticidade pode ser aproximada por:

$$\Delta \log(y) / \Delta \log(x)$$

Linearidade

► Nesse caso, tem-se:

TABLE 2.3 Summary of Functional Forms Involving Logarithms

Model	Dependent Variable	Independent Variable	Interpretation of β_1
Level-level	y	x	$\Delta y = \beta_1 \Delta x$
Level-log	y	$\log(x)$	$\Delta y = (\beta_1/100)\% \Delta x$
Log-level	$\log(y)$	x	$\% \Delta y = (100\beta_1) \Delta x$
Log-log	$\log(y)$	$\log(x)$	$\% \Delta y = \beta_1 \% \Delta x$

Testes de Especificação Funcional

Testes de Especificação Funcional

- Regression Especification Error Test (RESET) – Ramsey's (1969)
- Considere o seguinte modelo sob H_0 :

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$$

- Queremos testar se o quadrado das variáveis explicativas e produtos cruzados deveriam ser incluídos no modelo.
- Considere o seguinte modelo alternativo, sob H_1 :

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + \delta_1 \hat{y}^2 + \delta_2 \hat{y}^3 + \textit{error}.$$

Testes de Especificação Funcional

- Ramsey's (1969) RESET consiste no teste F de H_1 contra H_0 :

$$H_0: \delta_1 = \delta_2 = 0$$

H_1 : H_0 não é verdadeira

Considerar o valor crítico considerando-se a distribuição

$$F_{2, n-k-1-2}$$

Teste de Hipótese

▶ As etapas do teste são:

1. Escrever as hipóteses alternativas e nulas
2. Escolher o nível de significância do teste α
3. Calcular a estatística F , conhecida como a **estatística do teste**
4. Encontrar o **valor crítico** do teste F^* ,
5. Decidir: Se o valor de F for maior do que o de F^* , rejeitar H_0 com um nível de confiança de $1-\alpha$

Testes de Especificação Funcional

- Testes de Nonnested Models
- Considere o seguinte modelo sob H_0 :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u$$

- Considere agora o seguinte modelo alternativo, sob H_1 :

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

- Uma possibilidade seria agrupar todas as variáveis em um único modelo:

$$y = \gamma_0 + \gamma_1 x_1 + \gamma_2 x_2 + \gamma_3 \log(x_1) + \gamma_4 \log(x_2) + u.$$

Testes de Especificação Funcional

➤ Mizon e Richard (1968) Test consiste no teste F:

$$H_0: \gamma_3 = \gamma_4 = 0$$

$H_1: H_0$ não é verdadeira

Se trocarmos o modelo sob H_0 pelo modelo sob H_1 ,
poderíamos teríamos as hipóteses:

$$H_0: \gamma_1 = \gamma_2 = 0$$

$H_1: H_0$ não é verdadeira

Testes de Especificação Funcional

- Considere novamente o seguinte modelo sob H_0 :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u$$

E o seguinte modelo alternativo, sob H_1 :

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

- Tome os valores estimados \hat{y} sob H_1 . Davidson e MacKinnon propuseram o seguinte teste t nessa variável:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \theta_1 \hat{y} + error.$$

$$H_0: \theta_1 = 0$$

$$H_1: H_0 \text{ não é verdadeira}$$

Variável Proxy

- Suponha que o modelo populacional seja:

$$\log(\text{wage}) = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{exper} + \beta_3 \text{abil} + u.$$

Sendo ability sendo não-observável

- De uma forma geral, considere o seguinte modelo populacional:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3^* + u.$$

Sendo x_3^* não-observável.

Variável Proxy

➤ Se x_3^* puder ser escrita como uma função da variável x_3 :

$$x_3^* = \delta_0 + \delta_3 x_3 + v_3.$$

E substituindo-se dentro do modelo populacional, obtém-se:

$$y = (\beta_0 + \beta_3 \delta_0) + \beta_1 x_1 + \beta_2 x_2 + \beta_3 \delta_3 x_3 + u + \beta_3 v_3.$$

Ou, reescrevendo-se:

$$y = \alpha_0 + \beta_1 x_1 + \beta_2 x_2 + \alpha_3 x_3 + e.$$

Variável Proxy

- Se x_3^* for uma função de todas as variáveis explicativas, tem-se:

$$x_3^* = \delta_0 + \delta_1 x_1 + \delta_2 x_2 + \delta_3 x_3 + v_3.$$

Nesse caso, substituindo-se dentro do modelo populacional, obtém-se:

$$y = (\beta_0 + \beta_3 \delta_0) + (\beta_1 + \beta_3 \delta_1) x_1 + (\beta_2 + \beta_3 \delta_2) x_2 + \beta_3 \delta_3 x_3 + u + \beta_3 v_3,$$

Variável Proxy

- ▶ Em trabalhos empíricos, é comum utilizar-se a primeira defasagem da variável dependente como variável proxy:

$$crime = \beta_0 + \beta_1 unem + \beta_2 expend + \beta_3 crime_{-1} + u,$$



Obrigada!

