

# **Análise de Regressão Linear Múltipla VIII**

## **Aula 11**

**Wooldridge - Capítulo 5**

**Heij *et al.*, 2004 – Seções 1.3.3 e 4.1**

# Introdução

- Nós já vimos que é possível derivar as distribuições exatas dos estimadores e das estatísticas de testes, sob certas suposições.
- Porém, tais suposições são bastante fortes; assim, na prática, é difícil de encontrar um caso onde todas elas sejam válidas.
- Por exemplo, é comum a suposição de normalidade multivariada do vetor de erros ser violada.

# Introdução

- Dessa forma, se uma ou várias das suposições (de 1 a 6) forem violadas, então não teremos mais a validade de algumas (ou todas) propriedades dos estimadores e das estatísticas de testes.
- Logo, seria bastante útil se conseguíssemos entender as propriedades dos estimadores e a convergência das estatísticas de testes, no caso em que pudéssemos obter um número ilimitado de observações.

# Introdução

- Isto é o que, essencialmente, denotamos como *teoria assintótica*.
- Sabemos que, na prática, trabalhamos com amostras finitas. Porém, será que não seria possível admitir como verdadeiras as propriedades assintóticas no caso de amostras suficientemente grandes?

# Consistência

## do Vetor de Estimadores de MQO

Wooldridge - Capítulo 5  
Heij *et al.*, 2004 – Seção 4.1

# Consistência do vetor de estimadores de MQO

$$\text{plim}_{\tilde{\cdot}}(\hat{\beta}) = \text{plim}_{\tilde{\cdot}}\left(\left(\tilde{X}'\tilde{X}\right)^{-1}\tilde{X}'\tilde{y}\right) = \text{plim}_{\tilde{\cdot}}\left(\left(\tilde{X}'\tilde{X}\right)^{-1}\tilde{X}'\left(\tilde{X}\tilde{\beta} + \tilde{\varepsilon}\right)\right) = \text{plim}_{\tilde{\cdot}}\left(\tilde{\beta} + \left(\tilde{X}'\tilde{X}\right)^{-1}\tilde{X}'\tilde{\varepsilon}\right)$$

$$= \text{plim}_{\tilde{\cdot}}(\tilde{\beta}) + \text{plim}_{\tilde{\cdot}}\left(\left(\tilde{X}'\tilde{X}\right)^{-1}\tilde{X}'\tilde{\varepsilon}\right) = \tilde{\beta} + \text{plim}_{\tilde{\cdot}}\left(\left(\tilde{X}'\tilde{X}\right)^{-1}\tilde{X}'\tilde{\varepsilon}\right) =$$

$$= \tilde{\beta} + \text{plim}_{\tilde{\cdot}}\left(n\left(\tilde{X}'\tilde{X}\right)^{-1}\frac{1}{n}\tilde{X}'\tilde{\varepsilon}\right) = \tilde{\beta} + \text{plim}_{\tilde{\cdot}}\left(\left(\frac{1}{n}\tilde{X}'\tilde{X}\right)^{-1}\left(\frac{1}{n}\tilde{X}'\tilde{\varepsilon}\right)\right) =$$

$$= \tilde{\beta} + \text{plim}_{\tilde{\cdot}}\left(\left(\frac{1}{n}\tilde{X}'\tilde{X}\right)^{-1}\right)\text{plim}_{\tilde{\cdot}}\left(\frac{1}{n}\tilde{X}'\tilde{\varepsilon}\right) = \tilde{\beta} + \left(\text{plim}_{\tilde{\cdot}}\left(\frac{1}{n}\tilde{X}'\tilde{X}\right)\right)^{-1}\text{plim}_{\tilde{\cdot}}\left(\frac{1}{n}\tilde{X}'\tilde{\varepsilon}\right) =$$

(façamos um breve parênteses...)

# Suposição Adicional

**MLR.3\*** - Estabilidade dos Regressores. Na amostra (e, portanto, na população) nenhum regressor é constante, não há relação linear PERFEITA entre os regressores e a probabilidade limite de  $n^{-1}X'X$  existe e é não-singular, isto é,  $\text{plim} \begin{pmatrix} 1 & & \\ & X' & X \\ n & \sim & \sim \end{pmatrix} = Q.$

(Para mais detalhes, vide Leitura Complementar I)

# Consistência do vetor de estimadores de MQO

(cont.)

Dos *slides* anteriores, vem que

$$\text{plim}_{\sim} \left( \hat{\beta}_{\sim} \right) = \beta_{\sim} + \left( \text{plim}_{\sim} \left( \frac{1}{n} X' X \right) \right)^{-1} \text{plim}_{\sim} \left( \frac{1}{n} X' \varepsilon \right) = \beta_{\sim} + Q_{\sim}^{-1} \text{plim}_{\sim} \left( \frac{1}{n} X' \varepsilon \right)$$

Ainda, é fácil notar que o vetor de estimadores será consistente se, e somente se,

$$\text{plim}_{\sim} \left( \frac{1}{n} X' \varepsilon \right) = 0.$$

(Condição de ortogonalidade)



# Normalidade Assintótica

Wooldridge - Capítulo 5

Heij *et al.*, 2004 – Seção 4.1

## Normalidade Assintótica do vetor de estimadores de MQO

Para determinar a distribuição assintótica do vetor de estimadores do vetor de parâmetros  $\beta$ , é interessante utilizarmos a seguinte expressão:

$$\hat{\beta}_{\sim} = \left( X'_{\sim} X_{\sim} \right)^{-1} X'_{\sim} y_{\sim} = \left( X'_{\sim} X_{\sim} \right)^{-1} X_{\sim} \left( X_{\sim} \beta_{\sim} + \varepsilon_{\sim} \right) = \beta_{\sim} + \left( X'_{\sim} X_{\sim} \right)^{-1} X'_{\sim} \varepsilon_{\sim}$$

Ou seja,

$$\hat{\beta}_{\sim} - \beta_{\sim} = \left( X'_{\sim} X_{\sim} \right)^{-1} X'_{\sim} \varepsilon_{\sim}$$

# Normalidade Assintótica do vetor de estimadores de MQO

Por outro lado, o resultado anterior pode ser escrito como

$$\underset{\sim}{\hat{\beta}} - \underset{\sim}{\beta} = \left( \underset{\sim}{\frac{1}{n}} \underset{\sim}{X}' \underset{\sim}{X} \right)^{-1} \underset{\sim}{\frac{1}{n}} \underset{\sim}{X}' \underset{\sim}{\varepsilon}$$

Ou, ainda

$$\sqrt{n} \left( \underset{\sim}{\hat{\beta}} - \underset{\sim}{\beta} \right) = \left( \underset{\sim}{\frac{1}{n}} \underset{\sim}{X}' \underset{\sim}{X} \right)^{-1} \underset{\sim}{\frac{1}{\sqrt{n}}} \underset{\sim}{X}' \underset{\sim}{\varepsilon}$$

## Normalidade Assintótica do vetor de estimadores de MQO

Sob a suposição MLR.3\*, o fator  $\left( \frac{1}{n} \underset{\sim}{X}' \underset{\sim}{X} \right)^{-1}$  converge, em probabilidade, para a matriz  $\mathbf{Q}^{-1}$ .

Por outro lado, sob as suposições MLR.1 a MLR.5, além de algumas condições de regularidade, prova-se que

$$\frac{1}{\sqrt{n}} \underset{\sim}{X}' \underset{\sim}{\varepsilon} \xrightarrow{d} N_{k+1} \left( \underset{\sim}{0} ; \sigma^2 \underset{\sim}{Q} \right)$$

(Resultado baseado numa generalização do TLC (p. 50-51, HEIJ *et al.*)

# Normalidade Assintótica do vetor de estimadores de MQO

Dessa forma, assumindo que as suposições anteriores são válidas, temos que

$$\sqrt{n} \begin{pmatrix} \hat{\beta} - \beta \\ \sim \end{pmatrix} \xrightarrow{d} N_{k+1} \left( \begin{pmatrix} 0 \\ \sim \end{pmatrix} ; \sigma^2 \begin{pmatrix} Q^{-1} \\ \sim \end{pmatrix} \right)$$

# LEITURA COMPLEMENTAR I

*(MLR.3\*)*

Considere o seguinte modelo de regressão linear múltipla:

$$y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i, \quad i = 1, 2, \dots, n.$$

que pode ser escrito na forma matricial

$$\underset{\sim}{\mathbf{y}} = \underset{\sim}{\mathbf{X}} \underset{\sim}{\boldsymbol{\beta}} + \underset{\sim}{\boldsymbol{\varepsilon}}$$

em que

$$\underset{\sim}{\mathbf{X}} = \begin{pmatrix} 1 & x_{11} & x_{21} & \dots & x_{k1} \\ 1 & x_{12} & x_{22} & \dots & x_{k2} \\ 1 & x_{13} & x_{23} & \dots & x_{k3} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & x_{1n} & x_{2n} & \dots & x_{kn} \end{pmatrix}$$

Assim, a matriz  $X'X$  é escrita como

$$\underset{\sim}{X}' \underset{\sim}{X} = \begin{pmatrix} n & \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{2i} & \dots & \sum_{i=1}^n x_{ki} \\ \sum_{i=1}^n x_{1i} & \sum_{i=1}^n x_{1i}^2 & \sum_{i=1}^n (x_{1i} x_{2i}) & \dots & \sum_{i=1}^n (x_{1i} x_{ki}) \\ \sum_{i=1}^n x_{2i} & \sum_{i=1}^n (x_{2i} x_{1i}) & \sum_{i=1}^n x_{2i}^2 & \dots & \sum_{i=1}^n (x_{2i} x_{ki}) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n x_{ki} & \sum_{i=1}^n (x_{ki} x_{1i}) & \sum_{i=1}^n (x_{ki} x_{2i}) & \dots & \sum_{i=1}^n x_{ki}^2 \end{pmatrix}$$



Ainda,

$$\frac{1}{n} X' X = \begin{pmatrix} 1 & \bar{x}_1 & \bar{x}_2 & \dots & \bar{x}_k \\ \bar{x}_1 & \frac{\sum_{i=1}^n x_{1i}^2}{n} & \frac{\sum_{i=1}^n (x_{1i} x_{2i})}{n} & \dots & \frac{\sum_{i=1}^n (x_{1i} x_{ki})}{n} \\ \bar{x}_2 & \frac{\sum_{i=1}^n (x_{2i} x_{1i})}{n} & \frac{\sum_{i=1}^n x_{2i}^2}{n} & \dots & \frac{\sum_{i=1}^n (x_{2i} x_{ki})}{n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \bar{x}_k & \frac{\sum_{i=1}^n (x_{ki} x_{1i})}{n} & \frac{\sum_{i=1}^n (x_{ki} x_{2i})}{n} & \dots & \frac{\sum_{i=1}^n x_{ki}^2}{n} \end{pmatrix}$$

# Suposição MLR.3\*

Usando o  $\text{plim}(\cdot)$ , vem que

$$\text{plim}\left(\frac{1}{n} \begin{matrix} X' \\ \sim \\ X \end{matrix}\right) = \text{plim} \begin{pmatrix} 1 & \bar{x}_1 & \bar{x}_2 & \dots & \bar{x}_k \\ \bar{x}_1 & \frac{\sum_{i=1}^n x_{1i}^2}{n} & \frac{\sum_{i=1}^n (x_{1i}x_{2i})}{n} & \dots & \frac{\sum_{i=1}^n (x_{1i}x_{ki})}{n} \\ \bar{x}_2 & \frac{\sum_{i=1}^n (x_{2i}x_{1i})}{n} & \frac{\sum_{i=1}^n x_{2i}^2}{n} & \dots & \frac{\sum_{i=1}^n (x_{2i}x_{ki})}{n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \bar{x}_k & \frac{\sum_{i=1}^n (x_{ki}x_{1i})}{n} & \frac{\sum_{i=1}^n (x_{ki}x_{2i})}{n} & \dots & \frac{\sum_{i=1}^n x_{ki}^2}{n} \end{pmatrix}$$

# Suposição MLR.3\*

Logo,

$$p \lim \left( \frac{1}{n} X' X \right) = \begin{pmatrix} 1 & p \lim(\bar{x}_1) & p \lim(\bar{x}_2) & \dots & p \lim(\bar{x}_k) \\ p \lim(\bar{x}_1) & p \lim \left( \frac{\sum_{i=1}^n x_{1i}^2}{n} \right) & p \lim \left( \frac{\sum_{i=1}^n (x_{1i} x_{2i})}{n} \right) & \dots & p \lim \left( \frac{\sum_{i=1}^n (x_{1i} x_{ki})}{n} \right) \\ p \lim(\bar{x}_2) & p \lim \left( \frac{\sum_{i=1}^n (x_{2i} x_{1i})}{n} \right) & p \lim \left( \frac{\sum_{i=1}^n x_{2i}^2}{n} \right) & \dots & p \lim \left( \frac{\sum_{i=1}^n (x_{2i} x_{ki})}{n} \right) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ p \lim(\bar{x}_k) & p \lim \left( \frac{\sum_{i=1}^n (x_{ki} x_{1i})}{n} \right) & p \lim \left( \frac{\sum_{i=1}^n (x_{ki} x_{2i})}{n} \right) & \dots & p \lim \left( \frac{\sum_{i=1}^n x_{ki}^2}{n} \right) \end{pmatrix}$$

# Suposição MLR.3\*

Finalmente,

$$p \lim \left( \frac{1}{n} X' X \right) = \begin{pmatrix} 1 & \mu_{x_1} & \mu_{x_2} & \dots & \mu_{x_k} \\ \mu_{x_1} & \sigma_{x_1}^2 + (\mu_{x_1})^2 & \sigma_{x_1 x_2} + \mu_{x_1} \mu_{x_2} & \dots & \sigma_{x_1 x_k} + \mu_{x_1} \mu_{x_k} \\ \mu_{x_2} & \sigma_{x_2 x_1} + \mu_{x_2} \mu_{x_1} & \sigma_{x_2}^2 + (\mu_{x_2})^2 & \dots & \sigma_{x_2 x_k} + \mu_{x_2} \mu_{x_k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \mu_{x_k} & \sigma_{x_k x_1} + \mu_{x_k} \mu_{x_1} & \sigma_{x_k x_2} + \mu_{x_k} \mu_{x_2} & \dots & \sigma_{x_k}^2 + (\mu_{x_k})^2 \end{pmatrix} = Q$$

em que

$$\mu_{x_j} = E(X_j), \quad j = 1, 2, \dots, k$$

$$\sigma_{x_j}^2 = \text{Var}(X_j), \quad j = 1, 2, \dots, k$$

$$\sigma_{x_c x_l} = \text{Cov}(X_c, X_l), \quad c = 1, 2, \dots, k; \quad l = 1, 2, \dots, k; \quad c \neq l$$

# LEITURA COMPLEMENTAR II

*(Revisão: Estatística II)*

Heij *et al.*, 2004 – Seções 1.3.3 e 4.1

# Consistência

Seja  $\theta$  um parâmetro de interesse e considere  $\hat{\theta}_n$  um estimador de  $\theta$ . Nós estamos interessados nas propriedades deste estimador quando, teoricamente,  $n \rightarrow \infty$ , sob a suposição de que os dados foram gerados por um processo com parâmetro  $\theta_0$ . O estimador será dito consistente se ele convergir em probabilidade para  $\theta_0$ . Ou seja, se para todo  $\varepsilon > 0$ , a expressão

$$\lim_{n \rightarrow \infty} P\left(|\hat{\theta}_n - \theta_0| < \varepsilon\right) = 1$$

for válida, então, teremos um estimador consistente para  $\theta$ .

# Consistência

Neste caso,  $\theta_0$  é chamado de limite de probabilidade de  $\hat{\theta}_n$  e pode ser representado pela seguinte expressão:

$$\text{plim}(\hat{\theta}_n) = \theta_0$$

# Consistência

## Propriedades do plim

Suponha que  $y_n$  e  $z_n$  sejam duas seqüências de variáveis aleatórias com  $\text{plim}(y_n) = c_1$  e  $\text{plim}(z_n) = c_2$ , então, podemos demonstrar que:

$$(1) \text{plim}(y_n + z_n) = \text{plim}(y_n) + \text{plim}(z_n) = c_1 + c_2;$$

$$(2) \text{plim}(y_n z_n) = \text{plim}(y_n) \text{plim}(z_n) = c_1 c_2;$$

$$(3) \text{plim}(y_n / z_n) = \text{plim}(y_n) / \text{plim}(z_n) = c_1 / c_2 \quad (c_2 \neq 0).$$



# Consistência

## Propriedades do plim

Suponha que  $g(\cdot)$  seja uma função contínua e que não dependa de  $n$ , assim,

$$(4) \text{plim}(g(y_n)) = g(\text{plim}(y_n)) = g(c_1).$$

Este resultado implica que, se um estimador for consistente, então, qualquer função baseada nele também será consistente, mantidas as condições do enunciado.

# Consistência

## Propriedades do plim

### Observações

- 1) Resultados similares podem ser obtidos para vetores e matrizes constituídos por variáveis aleatórias.
- 2) Para mais detalhes, vide, por exemplo, seção 1.3.3 de Heij *et al.* (2004).