



**LISBOA  
SCHOOL OF  
ECONOMICS &  
MANAGEMENT**

## Econometria

### Qualidade do ajustamento e Propriedades do estimador OLS

Luís Silveira Santos

lsantos@iseg.ulisboa.pt

Licenciatura em Economia,  
Instituto Superior de Economia e Gestão – Universidade de Lisboa

21 de Abril de 2015

## Programa desta aula

- 1 Qualidade do ajustamento
- 2 Hipóteses do MRLM
- 3 Representação matricial do MRLM
- 4 Propriedades do estimador OLS
- 5 Estimação da variância do estimador OLS

## Qualidade do ajustamento

- Recorde-se que através Econometria conseguimos responder a duas questões-chave:
  - Previsão do valor da variável dependente (ou explicada), dados os valores das variáveis independentes (ou explicativas);
  - Quantificar a relação (ou relações) entre a variável dependente e as variáveis independentes
- Para tal, necessitamos de medir a qualidade do ajustamento, ou a “fiabilidade” do modelo estimado relativamente aos dados de que dispomos

## Qualidade do ajustamento (cont.)

- Considere-se a expressão do modelo de regressão linear múltipla:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

- Ao estimarmos o modelo acima vamos obter:

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k$$

sendo que  $\hat{u}_i = y_i - \hat{y}_i$

- Ou seja, podemos facilmente escrever  $y_i$  como uma combinação linear do valor previsto,  $\hat{y}_i$ , e do resíduo,  $\hat{u}_i$ , do modelo estimado:

$$y_i = \hat{y}_i + \hat{u}_i$$

## Qualidade do ajustamento (cont.)

- Consideremos agora a expressão da variação total de  $y_i$ :

$$\sum_{i=1}^n (y_i - \bar{y})^2$$

- Dado que  $y_i = \hat{y}_i + \hat{u}_i$ :

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n [\hat{y}_i + \hat{u}_i - (\bar{\hat{y}} + \bar{\hat{u}})]^2$$

- Como  $\bar{\hat{y}} = \bar{y}$  e  $\bar{\hat{u}} = 0$ :

$$\begin{aligned} \sum_{i=1}^n (y_i - \bar{y})^2 &= \sum_{i=1}^n [\hat{y}_i + \hat{u}_i - (\bar{\hat{y}} + \bar{\hat{u}})]^2 = \sum_{i=1}^n [(\hat{y}_i - \bar{y}) + \hat{u}_i]^2 = \\ &= \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 - 2 \times \sum_{i=1}^n \hat{u}_i (\hat{y}_i - \bar{y}) + \sum_{i=1}^n \hat{u}_i^2 \end{aligned}$$

## Qualidade do ajustamento (cont.)

- **PROBLEMA:**

$$\sum_{i=1}^n \hat{u}_i (\hat{y}_i - \bar{y}) = ?$$

- Sabemos que a covariância entre cada uma das variáveis independentes,  $\{x_1, x_2, \dots, x_k\}$ , e os resíduos OLS,  $\hat{u}_i$  é igual a zero
- Logo, como  $\hat{y}_i$  é combinação linear destas variáveis independentes, também a sua covariância entre os resíduos OLS,  $\hat{u}_i$ , será zero.
- Assim sendo,

$$\sum_{i=1}^n \hat{u}_i (\hat{y}_i - \bar{y}) = 0$$

## Qualidade do ajustamento (cont.)

- Por fim teremos que a variação total de  $y_i$  poderá ser reescrita da seguinte forma:

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n \hat{u}_i^2$$

- Ou analogamente,

$$\text{SQ Total} = \text{SQ Explicada} + \text{SQ dos Resíduos}$$

## Qualidade do ajustamento (cont.)

- O coeficiente que mede a qualidade do ajustamento do modelo estimado é designado por  $R^2$ , sendo dado por:

$$R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT}$$

- Ou seja, mede a proporção da variação total dos dados que é explicada pelo modelo estimado
- **PROPRIEDADES:**
  - 1  $0 \leq R^2 \leq 1$
  - 2 Aumenta sempre que adicionamos variáveis ao modelo (!!!)



## Exemplos

- ① Salário do CEO:

$$\widehat{\text{salário}}_i = 964 + 19 \text{RCP}_i;$$

$$n = 210, R^2 = 0.01$$

- ② Média final de Licenciatura:

$$\widehat{\text{colGPA}}_i = 1.3 + 0.5 \text{hsGPA}_i + 0.01 \text{ACT}_i;$$

$$n = 140, R^2 = 0.18$$

## Hipóteses do MRLM

### Hipótese MLR.1 – Linearidade nos parâmetros

O modelo na população pode ser escrito como

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

onde  $\beta_0, \beta_1, \dots, \beta_k$  são parâmetros desconhecidos constantes de interesse e  $u$  é um erro aleatório não observado.

- Sob esta hipótese são admitidos os seguintes modelos:

①  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_2^2 + u$

②  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 \sqrt{x_2} + u$

- Não são admitidos os seguintes modelos:

③  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3^2 x_3 + u$

④  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \sqrt{\beta_3} x_3 + u$

## Hipóteses do MRLM (cont.)

### Hipótese MLR.2 – Amostragem aleatória

Temos uma amostra aleatória com  $n$  observações,

$$\{(x_{i1}, x_{i2}, \dots, x_{ik}, y_i) : i = 1, 2, \dots, n\}$$

segundo o modelo populacional da hipótese MLR.1

## Hipóteses do MRLM (cont.)

### Hipótese MLR.3 – Ausência de colinearidade perfeita

Na amostra (tal como na população), nenhuma das variáveis independentes é constante e não existem relações lineares exactas entre as variáveis independentes

- Esta hipótese admite que exista correlação entre as diferentes variáveis independentes, ou regressores
- Porém, existem dois casos em que esta hipótese é violada:
  - 1  $|Cov(x_p, x_q)| = 1, \forall p \neq q$
  - 2 Se  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + u$ , com  $x_1 = x_2 + x_3$

## Hipóteses do MRLM (cont.)

### Hipótese MLR.4 – Média condicional igual a zero

O erro  $u$  tem valor esperado igual a zero, dados quaisquer valores das variáveis independentes:

$$E(u \mid x_1, x_2, \dots, x_k) = 0$$

- Esta hipótese será violada se omitirmos propositadamente do modelo uma variável relevante para explicar  $y$  e que esteja correlacionada com alguma das variáveis independentes,  $x_k$
- **EXEMPLO** – vamos omitir propositadamente  $x_3$  do modelo:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + u, \quad u = \delta_3 x_3 + v$$

onde  $v$  é o novo termo de erro.

Assim,  $E(u \mid x_1, x_2, \dots, x_k) = \delta_3 x_3 + \underbrace{E(v \mid x_1, x_2, \dots, x_k)}_{=0, \text{ pela hipótese MLR.4}} \neq 0$


## Hipóteses do MRLM (cont.)

### Hipótese MLR.5 – Homocedasticidade

O erro  $u$  apresenta a mesma variância, dados quaisquer valores das variáveis independentes:

$$\text{Var}(u \mid x_1, x_2, \dots, x_k) = \sigma^2$$

- Exemplo:



## Representação matricial do MRLM

- Por forma a deduzir algumas propriedades do estimador OLS é substancialmente mais fácil utilizar a notação vectorial e matricial. O modelo inicial,

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + u$$

poderá ser reescrito como,

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$$

## Representação matricial do MRLM (cont.)

- Notação matricial:

$$\mathbf{y}_{n \times 1} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}$$

$$\mathbf{u}_{n \times 1} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}$$

$$\mathbf{X}_{n \times (k+1)} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix}$$

$$\boldsymbol{\beta}_{(k+1) \times 1} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix}$$



## Representação matricial do MRLM (cont.)

- As estimativas para os elementos do vector  $\beta$  são aquelas que minimizam a Soma Quadrática dos Resíduos (SQR):

$$\text{SQR} = \sum_{i=1}^n \hat{u}_i^2 = \hat{\mathbf{u}}' \hat{\mathbf{u}} = (\mathbf{y} - \mathbf{X}\hat{\beta}) (\mathbf{y} - \mathbf{X}\hat{\beta})'$$

- A condição de primeira ordem será dada por:

$$\begin{aligned} \frac{\partial \text{SQR}}{\partial \hat{\beta}} \equiv \mathbf{0} &\Leftrightarrow \mathbf{X}' (\mathbf{y} - \mathbf{X}\hat{\beta}) \equiv \mathbf{0} \Leftrightarrow \\ &\Leftrightarrow \mathbf{X}'\mathbf{X}\hat{\beta} = \mathbf{X}'\mathbf{y} \Leftrightarrow \hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \end{aligned}$$

se  $\mathbf{X}'\mathbf{X}$  for não singular.

## Observações

- Note-se que  $\mathbf{X}$  não é matriz quadrada, logo

$$(\mathbf{X}'\mathbf{X})^{-1} \neq \mathbf{X}^{-1} (\mathbf{X}')^{-1}$$

- O vector de valores ajustados é dado por:

$$\hat{\mathbf{u}} = \mathbf{y} - \hat{\mathbf{y}}$$

- Pela condição de primeira ordem, podemos verificar que matricialmente os resíduos também não deverão estar correlacionados com os regressores, i.e.

$$\mathbf{X}'\hat{\mathbf{u}} = \mathbf{0}$$

- Todas as hipóteses do MRLM já vistas podem rapidamente ser generalizadas para o caso matricial. Atente-se apenas à hipótese MLR.3, implicando que característica da matriz  $\mathbf{X}$  seja igual a  $k + 1$

## O estimador OLS é centrado

### Teorema 1

Sob as hipóteses MLR.1 a MLR.4,

$$E(\hat{\beta}) = \beta$$

para quaisquer valores do parâmetro  $\beta_j$ , na população. Isto é, o estimador OLS é centrado nos parâmetros populacionais.

- **DEMONSTRAÇÃO:**

Sob as hipóteses MLR.1 a MLR.3 sabemos que

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'(\mathbf{X}\beta + \mathbf{u}) = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u}$$

O valor esperado virá

$$E(\hat{\beta} | \mathbf{X}) = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'E(\mathbf{u} | \mathbf{X}) = \beta$$

pois sob MLR.4,  $E(\mathbf{u} | \mathbf{X}) = \mathbf{0}$

## O estimador OLS é centrado (cont.)

- Note-se que o teorema 1 também pode ser visto como:

$$E(\hat{\beta}) = E \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \\ \vdots \\ \hat{\beta}_k \end{bmatrix} = \begin{bmatrix} E(\hat{\beta}_0) \\ E(\hat{\beta}_1) \\ E(\hat{\beta}_2) \\ \vdots \\ E(\hat{\beta}_k) \end{bmatrix} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix} = \beta$$

## Variância do estimador OLS

- No contexto matricial vamos utilizar a hipótese MLR.5 alargada:

Hipótese MLR.5 alargada – Homocedasticidade e ausência de autocorrelação

- $Var(u_j | x_1, x_2, \dots, x_k) = \sigma^2$
- $Cov(u_p, u_q | x_1, x_2, \dots, x_k) = 0, \forall p \neq q$  (para diferentes momentos de tempo, a correlação entre os erros é nula)

Matricialmente teremos,

$$Var(\mathbf{u} | \mathbf{X}) = \sigma^2 \mathbf{I}_n$$

onde  $\mathbf{I}_n$  é a matriz identidade de dimensão  $n \times n$

## Variância do estimador OLS (cont.)

- Note-se que a hipótese MLR.5 alargada também pode ser vista como:

$$\begin{aligned} \text{Var}(\mathbf{u} \mid \mathbf{X}) &= \begin{bmatrix} \text{Var}(u_1) & \text{Cov}(u_1, u_2) & \dots & \text{Cov}(u_1, u_n) \\ \text{Cov}(u_2, u_1) & \text{Var}(u_2) & \dots & \text{Cov}(u_2, u_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_n, u_1) & \text{Cov}(u_n, u_2) & \dots & \text{Var}(u_n) \end{bmatrix} = \\ &= \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix} = \sigma^2 \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix} \end{aligned}$$

## Variância do estimador OLS (cont.)

### Teorema 2

Sob as hipóteses MLR.1 a MLR.5 alargada,

$$\text{Var}(\hat{\beta} | \mathbf{X}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

- **DEMONSTRAÇÃO:**

$$\hat{\beta} = \beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u}$$

A variância virá

$$\begin{aligned} \text{Var}(\hat{\beta} | \mathbf{X}) &= \text{Var}\left[(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{u} | \mathbf{X}\right] = \\ &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \text{Var}(\mathbf{u} | \mathbf{X}) \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \end{aligned}$$

pois sob MLR.5 alargada,  $\text{Var}(\mathbf{u} | \mathbf{X}) = \sigma^2 \mathbf{I}_n$

## Teorema de Gauss-Markov

### Teorema de Gauss-Markov

Sob as hipóteses MLR.1 a MLR.5,  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$  são os melhores estimadores não enviesados, dentro da classe de todos os estimadores lineares, para os parâmetros  $\beta_0, \beta_1, \dots, \beta_k$ . Por outras palavras, o estimador OLS é “**BLUE**”, **B**est **L**inear **U**nbiased **E**stimator

- Sob as hipóteses MLR.1 a MLR.4, qualquer estimador linear será centrado
- São os melhores estimadores, uma vez que, dentro da classe dos estimadores lineares e centrados, o estimador OLS é aquele que apresenta a variância mais baixa
- Naturalmente o estimador OLS deixará de ser o melhor, em termos de variância, no caso em que MLR.5 não se verifique



## Observações

- Em termos escalares, o teorema 1 resume-se a

$$E(\hat{\beta}_j) = \beta_j$$

- Quanto ao teorema 2, este virá

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

onde  $\text{SQT}_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2$  e  $R_j^2$  é o  $R^2$  da regressão entre  $x_j$  e todas as outras variáveis independentes (incluindo a constante).

- É importante discutir, no contexto do teorema 2, os efeitos do mau ajustamento do modelo aos dados ( $\uparrow \sigma^2$ ) e ainda o efeito da multicolinearidade ( $R_j^2 \rightarrow 1$ )

## Estimação da variância do estimador OLS

- Como sabemos, a variância do estimador OLS é dada por:

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

- Porém desconhecemos  $\sigma^2$  uma vez que não observamos o erro aleatório  $u$ . Um estimador “natural” seria:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n u_i^2$$

uma vez que,

$$E(\hat{\sigma}^2) = \frac{1}{n} E\left(\sum_{i=1}^n u_i^2\right) = \frac{1}{n} \sum_{i=1}^n E(u_i^2) = \sigma^2$$

recordemos que  $E(u_i) = 0$

## Estimação da variância do estimador OLS (cont.)

- Como não observamos  $u$  mas sim  $\hat{u}$ , vamos obter o seguinte resultado:

$$E \left( \sum_{i=1}^n \hat{u}_i^2 \mid x_1, x_2, \dots, x_k \right) = (n - k - 1) \sigma^2$$

- Intuitivamente, este resultado decorre do facto de termos estimado  $k + 1$  coeficientes,  $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$
- Assim sendo, um “candidato” a estimador de  $\sigma^2$ , utilizando  $\hat{u}$  em vez de  $u$ , será

$$\hat{\sigma}^2 = \frac{1}{n - k - 1} \sum_{i=1}^n \hat{u}_i^2$$

## Estimação da variância do estimador OLS (cont.)

- Resta-nos referir um último teorema, que nos garante o não enviesamento de  $\hat{\sigma}^2$ :

### Teorema 3

Sob as hipóteses MLR.1 a MLR.5,  $E(\hat{\sigma}^2) = \sigma^2$

- A partir deste momento estamos em condições de estimar a variância do estimador OLS, substituindo  $\sigma^2$  pela sua estimativa  $\hat{\sigma}^2$ :

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