

# Análise de Regressão Linear Múltipla III

## Aula 06

# Suposições e Propriedades

# Suposições e Propriedades

**MLR.1** – O modelo de regressão é linear nos parâmetros

O modelo na população pode ser escrito como

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

em que

$\beta_0, \beta_1, \dots, \beta_k$  – são parâmetros desconhecidos  
(constantes);

$\varepsilon$  – termo de erro aleatório não observável.

# Suposições e Propriedades

## MLR.2 – Amostragem Aleatória

Temos uma amostra aleatória de  $n$  observações

$$(x_{1i}, x_{2i}, \dots, x_{ki}, y_i), \quad i = 1, 2, \dots, n,$$

do modelo populacional descrito em MLR.1.

## MLR.3 – Ausência de Colinearidade Perfeita

Na amostra (e, portanto, na população) **nenhum regressor é constante e não há relação linear PERFEITA entre os regressores (a matriz  $X$  apresenta posto completo).**

# Suposições e Propriedades

## MLR.4 – Média Condicional Zero

O valor esperado do vetor de erro aleatório,  $\varepsilon$ , condicionado na matriz de explicação  $X$ , é igual a zero.

Ou seja,

$$E(\varepsilon | X) = 0.$$

**Teorema 1.** Sob as suposições MLR.1 a MLR.4, condicionado nos valores do regressores, os estimadores de MQO para os parâmetros do modelo de regressão múltipla são não-viesados, ou seja,  $E(\hat{\beta}_j) = \beta_j$ ,  $j = 0, 1, 2, \dots, k$ .

# Demonstração do Teorema 1

$$\begin{aligned}(i) \quad E\left(\hat{\boldsymbol{\beta}} \mid \mathbf{X}\right) &= E\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\mathbf{y} \mid \mathbf{X}\right] = E\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\left(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}\right) \mid \mathbf{X}\right] = \\ &= E\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\mathbf{X}\boldsymbol{\beta} + \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = \\ &= E\left[\boldsymbol{\beta} + \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = E\left[\boldsymbol{\beta} \mid \mathbf{X}\right] + E\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = \\ &= \boldsymbol{\beta} + \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}' E\left[\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = \boldsymbol{\beta}\end{aligned}$$

$$(ii) \quad E\left(\hat{\boldsymbol{\beta}}\right) \stackrel{\text{Lei das Expectativas Iteradas}}{=} E\left[E\left(\hat{\boldsymbol{\beta}} \mid \mathbf{X}\right)\right] \stackrel{\text{de (i)}}{=} E\left[\boldsymbol{\beta}\right] = \boldsymbol{\beta}$$

# Suposições e Propriedades

## SUPOSIÇÃO FUNDAMENTAL:

$$E(\varepsilon | X) = 0.$$

Ou seja, todos os fatores contidos em  $\varepsilon$  devem ser não correlacionados com as variáveis explicativas, e deve ter sido usada a forma funcional correta.

# Suposições e Propriedades

## SUPOSIÇÃO FUNDAMENTAL: (cont)

Como pode falhar?

- *Omissão de variável explicativa importante, correlacionada com  $x_1, x_2, \dots$  ou  $x_k$ ;*
- *Forma funcional especificada incorretamente;*
- *Erro de medida em  $x_1, x_2, \dots$  ou  $x_k$ ;*
- *Simultaneidade entre  $y$  e  $x_1, x_2, \dots$  ou  $x_k$ ;*



# Inclusão e Exclusão de Regressores

## ANÁLISE DE DOIS CASOS ESPECIAIS:

### A) Inclusão de variável irrelevante

⇒ não prejudica a propriedade de ausência de viés

### B) Omissão de variável relevante

⇒ modelo correto tem  $k = 2$ , mas usamos  $k = 1$

**Resultado:**

$$E(\tilde{\beta}_1) = \beta_1 + \beta_2 \frac{\sum (x_{i1} - \bar{x}_1)x_{i2}}{\sum (x_{i1} - \bar{x}_1)^2} \neq \beta_1$$

# Inclusão e Exclusão de Regressores

## Direção do Viés

	$\text{Corr}(x_1, x_2) > 0$	$\text{Corr}(x_1, x_2) < 0$
$\beta_2 > 0$	Viés Positivo	Viés Negativo
$\beta_2 < 0$	Viés Negativo	Viés Positivo

# Inclusão e Exclusão de Regressores

## Observações

- ⇒ viés depende tanto dos sinais quanto das magnitudes;
- ⇒ em geral, se  $k > 1$ , omissão de qualquer variável relevante faz com que todos os estimadores de mínimos quadrados sejam viesados;
- ⇒ a menos que a variável omitida seja irrelevante ou não-correlacionada com as demais variáveis explicativas presentes no modelo, os estimadores de mínimos quadrados serão viesados.

# Suposições e Propriedades

## MLR.5 – Homocedasticidade

A variância do vetor de erro aleatório, condicional na matriz de explicação, é diagonal (com todos os elementos da diagonal iguais a  $\sigma^2$ ).

Ou seja,

$$\text{Var}\left(\underset{\sim}{\boldsymbol{\varepsilon}} \mid \underset{\sim}{\mathbf{X}}\right) = E\left(\underset{\sim}{\boldsymbol{\varepsilon}} \underset{\sim}{\boldsymbol{\varepsilon}}' \mid \underset{\sim}{\mathbf{X}}\right) = \begin{pmatrix} \sigma^2 & 0 & 0 & \dots & 0 \\ 0 & \sigma^2 & 0 & \dots & 0 \\ 0 & 0 & \sigma^2 & & \vdots \\ 0 & 0 & 0 & \ddots & 0 \\ 0 & 0 & \dots & 0 & \sigma^2 \end{pmatrix} = \underset{\sim}{\sigma^2 \mathbf{I}_n}$$

(matriz de variâncias e covariâncias associada ao vetor de erros)

# Observação 1

As suposições MLR.1 a MLR.5 conjuntamente são conhecidas como suposições de Gauss-Markov.

# Sob as suposições MLR.1 a MLR.5:

$$\begin{aligned} (iii) \operatorname{Var}\left(\hat{\boldsymbol{\beta}} \mid \mathbf{X}\right) &= \operatorname{Var}\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\mathbf{y} \mid \mathbf{X}\right] = \operatorname{Var}\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\left(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}\right) \mid \mathbf{X}\right] = \\ &= \operatorname{Var}\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\mathbf{X}\boldsymbol{\beta} + \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = \operatorname{Var}\left[\boldsymbol{\beta} + \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = \\ &= \operatorname{Var}\left[\left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}'\boldsymbol{\varepsilon} \mid \mathbf{X}\right] = \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}' \operatorname{Var}\left[\boldsymbol{\varepsilon} \mid \mathbf{X}\right] \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}' = \\ &= \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}' \sigma^2 \mathbf{I}_n \mathbf{X} \left(\mathbf{X}'\mathbf{X}\right)^{-1} = \sigma^2 \left(\mathbf{X}'\mathbf{X}\right)^{-1} \mathbf{X}' \mathbf{I}_n \mathbf{X} \left(\mathbf{X}'\mathbf{X}\right)^{-1} = \\ &= \sigma^2 \left(\mathbf{X}'\mathbf{X}\right)^{-1} \end{aligned}$$

# Observação 2

De (iii), se

$$\left( \underset{\sim}{\mathbf{X}}' \underset{\sim}{\mathbf{X}} \right)^{-1} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1k} \\ a_{21} & a_{22} & & a_{2k} \\ \vdots & & \ddots & \\ a_{k1} & a_{k2} & & a_{kk} \end{pmatrix}$$

então

$$Var(\hat{\beta}_j) = a_{jj} \sigma^2 \quad \mathbf{e} \quad Cov(\hat{\beta}_i, \hat{\beta}_j) = a_{ij} \sigma^2$$

# Variância dos Estimadores de MQO

**Teorema 2.** Sob as suposições MLR.1 a MLR.5, condicionadas aos valores amostrais das variáveis explicativas

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SQT_{x_j} (1 - R_{x_j}^2)}, \quad j = 0, 1, \dots, k$$

em que

$\sigma^2$  = variância do erro;

$SQT_{x_j}$  = SQT do  $j$ -ésimo regressor na amostra;

$R_{x_j}^2$  =  $R^2$  da regressão de  $x_j$  contra todas as outras variáveis explicativas (incluindo um intercepto).



# Componentes da Variância dos Estimadores de Mínimos Quadrados

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SQT_{x_j} (1 - R_{x_j}^2)}$$

- ⇒ Variância da v.a.  $u$ :  $\sigma^2$  alto implica num estimador de mínimos quadrados com alta variância;
- ⇒  $SQT_{x_j}$ : se a  $j$ -ésima variável explicativa apresentar uma variação total alta, então, a variância do  $i$ -ésimo estimador, associado à esta variável explicativa, será pequena;

# Componentes da Variância dos Estimadores de Mínimos Quadrados

$$\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{SQT_{x_j} (1 - R_{x_j}^2)}$$

- ⇒ Relações lineares entre as variáveis explicativas: altos valores de  $R_{x_j}^2$  implicam numa alta variância para os estimadores.
- ⇒  $1/(1-R_{x_j}^2)$  – conhecido como fator de inflação de variância ou, **VIF**, em inglês.
- ⇒ Inclusão de variável irrelevante geralmente aumenta as variâncias dos demais estimadores de MQO

# Estimação de $\sigma^2$

Como  $\sigma^2$  em geral é desconhecida, utilizaremos o estimador:

$$\hat{\sigma}^2 = MSR = \frac{SSR}{n-(k+1)}$$

**MSR (Quadrado Médio devido aos Resíduos)**

SSR perde  $k+1$  graus de liberdade, devido às  $k+1$  restrições impostas pelas condições de primeira ordem de MQO.

# Estimação de $\sigma^2$

**Teorema 3.** Sob as suposições de Gauss-Markov (MLR.1 a MLR.5),

$$E(\hat{\sigma}^2) = E(MSR) = \sigma^2.$$

## **Observação**

$\hat{\sigma} = \sqrt{MSR}$  : erro padrão da regressão.

# Erro Padrão dos Estimadores de MQO

Dessa forma, o erro-padrão dos estimadores de mínimos quadrados podem ser obtidos através da expressão

$$\hat{\sigma}_{\hat{\beta}_j} = \sqrt{\frac{\hat{\sigma}^2}{SQT_{x_j} (1 - R_{x_j}^2)}}$$

# Eficiência dos Estimadores de MQO

## Teorema 4. (TEOREMA DE GAUSS-MARKOV)

Sob as suposições MLR.1 a MLR.5,

$$\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$$

são os melhores estimadores, na classe dos lineares não-viesados (BLUE) para  $\beta_0, \beta_1, \dots, \beta_k$ , respectivamente.

# Eficiência dos Estimadores de MQO

- ⇒ Restringindo a classe de estimadores não viesados a todos os estimadores lineares em  $y$ , o teorema de Gauss-Markov prova que o estimador de mínimos quadrados é o “melhor” (no sentido em que apresenta variância mínima)
- ⇒ Diz-se que, sob as suposições MLR.1 a MLR.5, os estimadores de mínimos quadrados são BLUEs (*best linear unbiased estimators*)

# Suposições e Propriedades

**MLR.6** – O vetor de erro estocástico  $\varepsilon$  é independente dos regressores e segue uma distribuição normal multivariada, com vetor de médias igual a zero e matriz de variâncias e covariâncias igual a  $\sigma^2 \mathbf{I}_n$ .



# Suposições e Propriedades

## Observações

- 1) Para aplicações de regressão com dados do tipo *cross-sectional*, as suposições MLR.1 a MLR.6 são conhecidas como suposições do modelo linear clássico (suposições CLM).
- 2) Uma maneira sucinta de resumir as suposições CLM na população é
$$y | (x_1, x_2, \dots, x_k) \sim N(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k; \sigma^2).$$
- 3) Sob as suposições CLM os estimadores de mínimos quadrados são estimadores não-viesados de variância mínima.

# Propriedades dos Estimadores

*(iv) Sob as suposições clássicas do modelo de regressão linear e, também, sabendo que  $\hat{\beta}$  é linear em  $y$  temos que*

$$\hat{\beta} \sim N_k \left( \beta; \sigma^2 \left( \mathbf{X}' \mathbf{X} \right)^{-1} \right)$$

**Observação:** O vetor de estimadores é normalmente distribuído devido ao fato de ser formado por uma combinação linear dos elementos do vetor resposta, que são normais e independentes, uma vez que os erros assim o são.

# Propriedades dos Estimadores

Desta maneira, cada um dos componentes de  $\hat{\beta}$ , tem a seguinte distribuição

$$\hat{\beta}_j \sim N(\beta_j; \sigma^2 a_{jj}),$$

em que

$a_{jj}$  é o  $j$ -ésimo elemento da diagonal da matriz  $(\tilde{\mathbf{X}}'\tilde{\mathbf{X}})^{-1}$ .

# Distribuição amostral de $\hat{\beta}_j$

**Teorema 4.1** – Sob as suposições CLM (MLR.1 a MLR.6), condicionado nos valores amostrais das variáveis explicativas,

$$\hat{\beta}_j \sim N \left( \beta_j; \frac{\sigma^2}{SQT_{x_j} (1 - R_{x_j}^2)} \right)$$

# Distribuição amostral de $\hat{\beta}_j$

Do teorema anterior segue que,

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\frac{\sigma^2}{SQT_{x_j} (1 - R_{x_j}^2)}}} \sim N(0; 1)$$

***Como  $\sigma^2$  é um parâmetro desconhecido, então será proposto um estimador para tal parâmetro. Dessa maneira, será necessário estudar a distribuição de probabilidades da nova v.a. que será gerada.***