

# ACA228 - Modelos de Regressão e Previsão

## Regressão Linear Múltipla

Prof. Carlos Trucíos  
carlos.trucios@facc.ufrj.br  
ctruciosm.github.io

Faculdade de Administração e Ciências Contábeis,  
Universidade Federal do Rio de Janeiro

## Aula 7

Introdução

Regressão Linear Múltipla

Método MQO

Qualidade de ajuste

Propriedades do estimador MQO

MRLM: Desafios na prática

# Introdução

# Introdução

- ▶ Nas aulas 3 e 5 focamos em modelos do tipo  $Y = \beta_0 + \beta_1 X + u$

# Introdução

- ▶ Nas aulas 3 e 5 focamos em modelos do tipo  $Y = \beta_0 + \beta_1 X + u$
- ▶ Contudo, pensar que uma única variável  $X$  pode explicar  $Y$  é bastante ingênuo

# Introdução

- ▶ Nas aulas 3 e 5 focamos em modelos do tipo  $Y = \beta_0 + \beta_1 X + u$
- ▶ Contudo, pensar que uma única variável  $X$  pode explicar  $Y$  é bastante ingênuo
- ▶  $\mathbb{E}(u|X) = 0$  implica  $Cov(u, X) = 0$

# Introdução

- ▶ Nas aulas 3 e 5 focamos em modelos do tipo  $Y = \beta_0 + \beta_1 X + u$
- ▶ Contudo, pensar que uma única variável  $X$  pode explicar  $Y$  é bastante ingênuo
- ▶  $\mathbb{E}(u|X) = 0$  implica  $Cov(u, X) = 0$
- ▶ No contexto de RLS, dizer que todos os outros fatores que afetam  $Y$  (e incorporados em  $u$ ) são não correlacionados com  $X$  é bastante irrealista.

## Introdução

- ▶ Nas aulas 3 e 5 focamos em modelos do tipo  $Y = \beta_0 + \beta_1 X + u$
- ▶ Contudo, pensar que uma única variável  $X$  pode explicar  $Y$  é bastante ingênuo
- ▶  $\mathbb{E}(u|X) = 0$  implica  $Cov(u, X) = 0$
- ▶ No contexto de RLS, dizer que todos os outros fatores que afetam  $Y$  (e incorporados em  $u$ ) são não correlacionados com  $X$  é bastante irrealista.
- ▶ Um modelo que inclua mais do que uma variável explicativa parece ser bem mais razoável.



## Introdução

- ▶ Nas aulas 3 e 5 focamos em modelos do tipo  $Y = \beta_0 + \beta_1 X + u$
- ▶ Contudo, pensar que uma única variável  $X$  pode explicar  $Y$  é bastante ingênuo
- ▶  $\mathbb{E}(u|X) = 0$  implica  $Cov(u, X) = 0$
- ▶ No contexto de RLS, dizer que todos os outros fatores que afetam  $Y$  (e incorporados em  $u$ ) são não correlacionados com  $X$  é bastante irrealista.
- ▶ Um modelo que inclua mais do que uma variável explicativa parece ser bem mais razoável.
- ▶ Se incluirmos no nosso modelo mais variáveis que sejam úteis para explicar  $Y$ , esperamos que uma maior parte da variabilidade de  $Y$  seja explicada.

# Regressão Linear Múltipla

# Regressão Linear Multipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

# Regressão Linear Multipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

- ▶  $Y$  é a variável dependente

# Regressão Linear Multipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

- ▶  $Y$  é a variável dependente
- ▶  $X_1, \dots, X_k$  são as  $k$  variáveis explicativas

# Regressão Linear Multipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

- ▶  $Y$  é a variável dependente
- ▶  $X_1, \dots, X_k$  são as  $k$  variáveis explicativas
- ▶  $\beta = [\beta_0 \quad \beta_1 \quad \dots \quad \beta_k]'$  é o vetor de parâmetros

# Regressão Linear Múltipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

- ▶  $Y$  é a variável dependente
- ▶  $X_1, \dots, X_k$  são as  $k$  variáveis explicativas
- ▶  $\beta = [\beta_0, \beta_1, \dots, \beta_k]'$  é o vetor de parâmetros
- ▶  $u$  é o termo de erro.

# Regressão Linear Múltipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

- ▶  $Y$  é a variável dependente
- ▶  $X_1, \dots, X_k$  são as  $k$  variáveis explicativas
- ▶  $\beta = [\beta_0, \beta_1, \dots, \beta_k]'$  é o vetor de parâmetros
- ▶  $u$  é o termo de erro.



# Regressão Linear Múltipla

## MRLM

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_k X_k + u$$

- ▶  $Y$  é a variável dependente
- ▶  $X_1, \dots, X_k$  são as  $k$  variáveis explicativas
- ▶  $\beta = [\beta_0, \beta_1, \dots, \beta_k]'$  é o vetor de parâmetros
- ▶  $u$  é o termo de erro.

Na prática, nunca conhecemos os  $\beta$ 's, então precisamos estimá-los utilizando os dados

# Método MQO

## Estimação

Sejam  $(y_1, x_{1,1}, \dots, x_{1,k}), \dots, (y_n, x_{n,1}, \dots, x_{n,k})$  uma a.a. de tamanho  $n$ .

## Estimação

Sejam  $(y_1, x_{1,1}, \dots, x_{1,k}), \dots (y_n, x_{n,1}, \dots, x_{n,k})$  uma a.a. de tamanho  $n$ .

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 x_{1,1} + \beta_2 x_{1,2} + \dots + \beta_k x_{1,k} + u_1 \\ &\vdots \\ y_n &= \beta_0 + \beta_1 x_{n,1} + \beta_2 x_{n,2} + \dots + \beta_k x_{n,k} + u_n \end{aligned} \tag{1}$$

## Estimação

Sejam  $(y_1, x_{1,1}, \dots, x_{1,k}), \dots (y_n, x_{n,1}, \dots, x_{n,k})$  uma a.a. de tamanho  $n$ .

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 x_{1,1} + \beta_2 x_{1,2} + \dots + \beta_k x_{1,k} + u_1 \\ &\vdots \\ y_n &= \beta_0 + \beta_1 x_{n,1} + \beta_2 x_{n,2} + \dots + \beta_k x_{n,k} + u_n \end{aligned} \tag{1}$$

$$\begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{1,1} & \dots & x_{1,k} \\ \vdots & \vdots & \dots & \vdots \\ 1 & x_{n,1} & \dots & x_{n,k} \end{bmatrix} \times \begin{bmatrix} \beta_0 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} u_1 \\ \vdots \\ u_n \end{bmatrix}$$

## Estimação

Sejam  $(y_1, x_{1,1}, \dots, x_{1,k}), \dots (y_n, x_{n,1}, \dots, x_{n,k})$  uma a.a. de tamanho  $n$ .

$$\begin{aligned} y_1 &= \beta_0 + \beta_1 x_{1,1} + \beta_2 x_{1,2} + \dots + \beta_k x_{1,k} + u_1 \\ &\vdots \\ y_n &= \beta_0 + \beta_1 x_{n,1} + \beta_2 x_{n,2} + \dots + \beta_k x_{n,k} + u_n \end{aligned} \tag{1}$$

$$\begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{1,1} & \dots & x_{1,k} \\ \vdots & \vdots & \dots & \vdots \\ 1 & x_{n,1} & \dots & x_{n,k} \end{bmatrix} \times \begin{bmatrix} \beta_0 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} u_1 \\ \vdots \\ u_n \end{bmatrix}$$

Em forma matricial

$$Y = X\beta + u$$

# Estimação

Queremos os  $b_0, b_1, \dots, b_k$  que minimizem

$$SQR = \sum_{i=1}^n \hat{u}_i^2$$

em que  $\hat{u}_i = y_i - \hat{y}_i$  com  $\hat{y}_i = b_0 + b_1x_{i,1} + \dots + b_kx_{i,k}$ .

# Estimação

Queremos os  $b_0, b_1, \dots, b_k$  que minimizem

$$SQR = \sum_{i=1}^n \hat{u}_i^2$$

em que  $\hat{u}_i = y_i - \hat{y}_i$  com  $\hat{y}_i = b_0 + b_1x_{i,1} + \dots + b_kx_{i,k}$ .

$$\begin{aligned} \hat{\beta} = [\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k]' &= \underset{b}{\operatorname{argmin}} \sum_{i=1}^n \hat{u}_i^2 \\ &= \underset{b}{\operatorname{argmin}} \sum_{i=1}^n \underbrace{(y_i - b_0 - b_1x_{i,1} - \dots - b_kx_{i,k})^2}_{\hat{u}_i} \quad (2) \end{aligned}$$



## Estimação

Equivalentemente, a equação (2) em forma matricial é dada por:

$$\hat{\beta} = \underset{b}{\operatorname{argmin}} \hat{u}'\hat{u} = \underset{b}{\operatorname{argmin}} (Y - \underbrace{Xb}_{\hat{Y}})'(Y - \underbrace{Xb}_{\hat{Y}})$$

## Estimação

Equivalentemente, a equação (2) em forma matricial é dada por:

$$\hat{\beta} = \underset{b}{\operatorname{argmin}} \hat{u}'\hat{u} = \underset{b}{\operatorname{argmin}} (Y - \underbrace{Xb}_{\hat{Y}})'(Y - \underbrace{Xb}_{\hat{Y}})$$

Para minimizar SQR, igualamos a primeira derivada a zero e depois verificamos se é ponto de mínimo (segunda derivada).

## Estimação

Equivalentemente, a equação (2) em forma matricial é dada por:

$$\hat{\beta} = \underset{b}{\operatorname{argmin}} \hat{u}'\hat{u} = \underset{b}{\operatorname{argmin}} (Y - \underbrace{Xb}_{\hat{Y}})'(Y - \underbrace{Xb}_{\hat{Y}})$$

Para minimizar SQR, igualamos a primeira derivada a zero e depois verificamos se é ponto de mínimo (segunda derivada).

$$\text{SQR} = \hat{u}'\hat{u} \tag{3}$$

$$= (Y - Xb)'(Y - Xb) \tag{4}$$

$$= (Y' - b'X')(Y - Xb) \tag{5}$$

$$= Y'Y - b'X'Y - Y'Xb + b'X'Xb \tag{6}$$

# Estimação

Regras de derivação para matrizes/vetores:

Sejam  $a_{n \times 1}$ ,  $b_{n \times 1}$  e  $A_{n \times n}$

$$\frac{\partial b'Ab}{\partial b} = (A + A')b; \quad \frac{\partial Ab}{\partial b'} = A; \quad \frac{\partial a'b}{\partial b} = \frac{\partial b'a}{\partial b} = a$$

# Estimação

Regras de derivação para matrizes/vetores:

Sejam  $a_{n \times 1}$ ,  $b_{n \times 1}$  e  $A_{n \times n}$

$$\frac{\partial b'Ab}{\partial b} = (A + A')b; \quad \frac{\partial Ab}{\partial b'} = A; \quad \frac{\partial a'b}{\partial b} = \frac{\partial b'a}{\partial b} = a$$

$$\frac{\partial SQR}{\partial b} = \frac{\partial (Y'Y - b'X'Y - Y'Xb + b'X'Xb)}{\partial b} \quad (7)$$

$$= \frac{\partial Y'Y}{\partial b} - \frac{\partial b'X'Y}{\partial b} - \frac{\partial Y'Xb}{\partial b} + \frac{\partial b'X'Xb}{\partial b} \quad (8)$$

$$= 0 - X'Y - (Y'X)' + (X'X + X'X)b \quad (9)$$

$$= -2X'Y + 2X'Xb \quad (10)$$

## Estimação

$$\frac{\partial SQR}{\partial b} = -2X'Y + 2X'Xb$$

## Estimação

$$\frac{\partial SQR}{\partial b} = -2X'Y + 2X'Xb$$

Igualando a zero e cancelando o  $-2$  , temos

$$X'Y = X'X\hat{\beta} \quad \text{ou equivalentemente} \quad \underbrace{(X'X)^{-1}X'X}_I \hat{\beta} = (X'X)^{-1}X'Y$$

## Estimação

$$\frac{\partial SQR}{\partial b} = -2X'Y + 2X'Xb$$

Igualando a zero e cancelando o  $-2$  , temos

$$X'Y = X'X\hat{\beta} \quad \text{ou equivalentemente} \quad \underbrace{(X'X)^{-1}X'X}_I \hat{\beta} = (X'X)^{-1}X'Y$$

**Será que é ponto de mínimo?** (Segundas derivadas...)



## Estimação

$$\frac{\partial SQR}{\partial b} = -2X'Y + 2X'Xb$$

Igualando a zero e cancelando o  $-2$ , temos

$$X'Y = X'X\hat{\beta} \quad \text{ou equivalentemente} \quad \underbrace{(X'X)^{-1}X'X}_I \hat{\beta} = (X'X)^{-1}X'Y$$

**Será que é ponto de mínimo?** (Segundas derivadas...)

$$\frac{\partial}{\partial b'} \left( \frac{\partial SQR}{\partial b} \right) = \frac{\partial^2 SQR}{\partial b \partial b'} = \frac{\partial(-2X'Y + 2X'Xb)}{\partial b'} = 2X'X \geq 0,$$

então  $\hat{\beta}$  é ponto de mínimo.

# Estimação

## Estimador MQO

$$\hat{\beta} = [X'X]^{-1}X'Y$$

# Estimação

## Estimador MQO

$$\hat{\beta} = [X'X]^{-1}X'Y$$

Note que,

$$\begin{aligned}\hat{\beta} &= [X'X]^{-1}X'Y = \\ &= [X'X]^{-1}X'\underbrace{(X\beta + u)}_Y \\ &= \underbrace{[X'X]^{-1}X'X}_I \beta + [X'X]^{-1}X'u \\ &= \beta + [X'X]^{-1}X'u\end{aligned}\tag{11}$$

# Estimação

```
library(wooldridge)
modelo <- lm(log(wage) ~ educ + exper + tenure, data = wage1)
coef(modelo)
```

```
## (Intercept)          educ          exper          tenure
## 0.284359555 0.092028987 0.004121109 0.022067217
```

# Estimação

```
library(wooldridge)
modelo <- lm(log(wage) ~ educ + exper + tenure, data = wage1)
coef(modelo)
```

```
## (Intercept)          educ          exper          tenure
## 0.284359555 0.092028987 0.004121109 0.022067217
```

- ▶ Mantendo os fatores *exper* e *tenure* fixos, quando *educ* (anos de educação formal) aumenta em 1, espera-se que o salário aumente em  $9.2\%(100 \times 0.092028987)$

# Qualidade de ajuste

## RLM: Qualidade de ajuste - R<sup>2</sup>

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

R<sup>2</sup>

$$R^2 = 1 - SQR/SQT = SQE/SQT$$

## RLM: Qualidade de ajuste - R2

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

R2

$$R^2 = 1 - SQR/SQT = SQE/SQT$$

- ▶  $R^2$  já foi introduzido na RLS.



## RLM: Qualidade de ajuste - R2

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

R2

$$R^2 = 1 - SQR/SQT = SQE/SQT$$

- ▶  $R^2$  já foi introduzido na RLS.
- ▶  $R^2$  : proporção da variabilidade de  $y$  que é explicada pelo modelo.

## RLM: Qualidade de ajuste - R2

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

R2


$$R^2 = 1 - SQR/SQT = SQE/SQT$$

- ▶  $R^2$  já foi introduzido na RLS.
- ▶  $R^2$  : proporção da variabilidade de  $y$  que é explicada pelo modelo.
- ▶  $100 \times R^2$  : porcentagem da variabilidade de  $y$  que é explicada pelo modelo.

## RLM: Qualidade de ajuste - R2

```
modelo1 = lm(log(wage)~educ,data = wage1)
modelo2 = lm(log(wage)~educ+exper,data = wage1)
modelo3 = lm(log(wage)~educ+exper+tenure,data = wage1)
modelo4 = lm(log(wage)~educ+exper+tenure+nonwhite,data = wage1)
modelo5 = lm(log(wage)~educ+exper+tenure+nonwhite
              +female,data = wage1)
modelo6 = lm(log(wage)~educ+exper+tenure+nonwhite
              +female + married,data = wage1)
modelo7 = lm(log(wage)~educ+exper+tenure+nonwhite+female
              +married+numdep,data = wage1)
```

## RLM: Qualidade de ajuste - R2



## RLM: Qualidade de ajuste -R2 ajustado

- ▶  $R^2$  tem a desvantagem que nunca diminui quando incluímos uma nova variável no modelo (mesmo se a variável não for importante)

## RLM: Qualidade de ajuste - $R^2$ ajustado

- ▶  $R^2$  tem a desvantagem que nunca diminui quando incluímos uma nova variável no modelo (mesmo se a variável não for importante)
- ▶ Uma alternativa é usar uma nova medida de qualidade de ajuste.

## RLM: Qualidade de ajuste - $R^2$ ajustado

- ▶  $R^2$  tem a desvantagem que nunca diminui quando incluímos uma nova variável no modelo (mesmo se a variável não for importante)
- ▶ Uma alternativa é usar uma nova medida de qualidade de ajuste.

## RLM: Qualidade de ajuste -R2 ajustado

- ▶  $R^2$  tem a desvantagem que nunca diminui quando incluímos uma nova variável no modelo (mesmo se a variável não for importante)
- ▶ Uma alternativa é usar uma nova medida de qualidade de ajuste.

### R2-Ajustado

$$R_A^2 = 1 - \frac{n-1}{n-(k+1)}(1 - R^2)$$



## RLM: Qualidade de ajuste -R2 ajustado

- ▶  $R^2$  tem a desvantagem que nunca diminui quando incluímos uma nova variável no modelo (mesmo se a variável não for importante)
- ▶ Uma alternativa é usar uma nova medida de qualidade de ajuste.

### R2-Ajustado

$$R_A^2 = 1 - \frac{n-1}{n-(k+1)}(1-R^2)$$

$R^2$ -Ajustado penaliza o número de variáveis incluídas no modelo.

## RLM: Qualidade de ajuste -R2 ajustado

- ▶  $R^2$  tem a desvantagem que nunca diminui quando incluímos uma nova variável no modelo (mesmo se a variável não for importante)
- ▶ Uma alternativa é usar uma nova medida de qualidade de ajuste.

### R2-Ajustado

$$R_A^2 = 1 - \frac{n-1}{n-(k+1)}(1 - R^2)$$

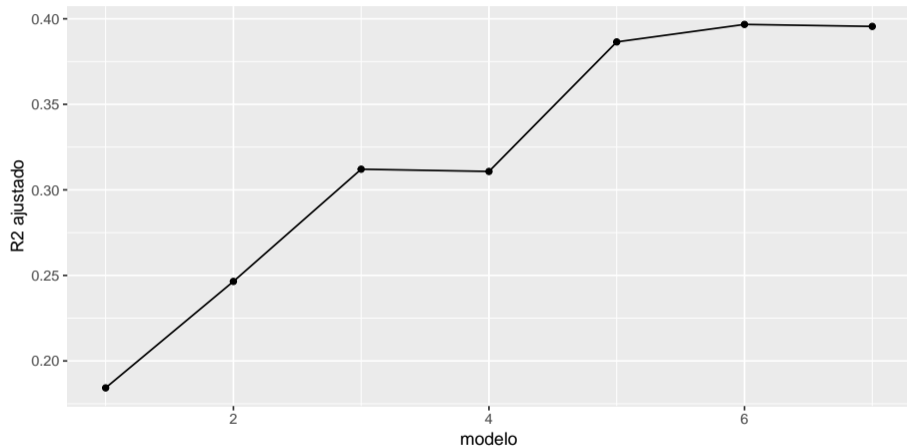
$R^2$ -Ajustado penaliza o número de variáveis incluídas no modelo.

No R:

```
summary(modelo1)$adj.r.squared
```

```
## [1] 0.1842527
```

## RLM: Qualidade de ajuste -R2 ajustado



## RLM: Qualidade de ajuste - $R^2$ ajustado

### Comparando $R^2$ com $R^2$ -ajustado

```
#R2
```

```
round(R2,4)
```

```
## [1] 0.1858 0.2493 0.3160 0.3160 0.3923 0.4036 0.4036
```

```
#R2-Ajustado
```

```
round(R2adj,4)
```

```
## [1] 0.1843 0.2465 0.3121 0.3108 0.3865 0.3967 0.3956
```

## RLM: Qualidade de ajuste - $R^2$ ajustado

### Comparando $R^2$ com $R^2$ -ajustado

*#R2*

```
round(R2,4)
```

```
## [1] 0.1858 0.2493 0.3160 0.3160 0.3923 0.4036 0.4036
```

*#R2-Ajustado*

```
round(R2adj,4)
```

```
## [1] 0.1843 0.2465 0.3121 0.3108 0.3865 0.3967 0.3956
```

$R^2$  ou  $R^2$ -ajustado? Prefere-se o  $R^2$ -ajustado.

# Propriedades do estimador MQO

# Propriedades

## HRLM1: Linear nos parâmetros

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + u \quad (12)$$

# Propriedades

## HRLM1: Linear nos parâmetros

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + u \quad (12)$$

## HRLM2: Amostragem aleatória

$(y_1, x_{1,1}, \dots, x_{1,k}), \dots, (y_n, x_{n,1}, \dots, x_{n,k})$  constituem uma a.a. de tamanho  $n$  do modelo populacional (12)



# Propriedades

## HRLM1: Linear nos parâmetros

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + u \quad (12)$$

## HRLM2: Amostragem aleatória

$(y_1, x_{1,1}, \dots, x_{1,k}), \dots, (y_n, x_{n,1}, \dots, x_{n,k})$  constituem uma a.a. de tamanho  $n$  do modelo populacional (12)

## HRLM3: Colinearidade não perfeita

Não há relações lineares exatas entre as variáveis independentes e nenhuma das variáveis independentes é constante.

# RLM: Propriedades

HRLM4: Média condicional zero

$$\mathbb{E}(u|X) = 0$$

# RLM: Propriedades

HRLM4: Média condicional zero

$$\mathbb{E}(u|X) = 0$$

Teorema: Inexistência do viés MQO

Sob HRLM1–HRLM4,

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

## RLM: Propriedades

### Prova

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

## RLM: Propriedades

### Prova

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

$$\mathbb{E}(\hat{\beta}|X) = \mathbb{E}(\beta + (X'X)^{-1}X'u|X) \quad (13)$$

$$= \underbrace{\mathbb{E}(\beta|X)}_{\beta} + \underbrace{\mathbb{E}((X'X)^{-1}X'u|X)}_{(X'X)^{-1}X' \underbrace{\mathbb{E}(u|X)}_0} \quad (14)$$

$$= \beta + \mathbf{0} = \beta \quad (15)$$

## RLM: Propriedades

### Prova

$$\hat{\beta} = (X'X)^{-1}X'Y = (X'X)^{-1}X'(X\beta + u) = \underbrace{(X'X)^{-1}X'X}_{I}\beta + (X'X)^{-1}X'u$$

$$\mathbb{E}(\hat{\beta}|X) = \mathbb{E}(\beta + (X'X)^{-1}X'u|X) \quad (13)$$

$$= \underbrace{\mathbb{E}(\beta|X)}_{\beta} + \underbrace{\mathbb{E}((X'X)^{-1}X'u|X)}_{(X'X)^{-1}X' \underbrace{\mathbb{E}(u|X)}_0} \quad (14)$$

$$= \beta + 0 = \beta \quad (15)$$

Aplicando  $\mathbb{E}(\cdot)$  em ambos os lados

$$\underbrace{\mathbb{E}[\mathbb{E}(\hat{\beta}|X)]}_{\mathbb{E}(\hat{\beta})} = \mathbb{E}[\beta] = \beta$$

## RLM: Propriedades

HRLM5: Variância constante (Homocedasticidade)

$$\mathbb{V}(u|X) = \mathbb{E}[uu'|X] = \sigma^2 I$$

# RLM: Propriedades

HRLM5: Variância constante (Homocedasticidade)

$$\mathbb{V}(u|X) = \mathbb{E}[uu'|X] = \sigma^2 I$$

Variância dos EMQO

Sob HRLM1–HRLM5,

$$\mathbb{V}(\hat{\beta}|X) = \sigma^2 (X'X)^{-1} \tag{16}$$



## RLM: Propriedades

### Prova

Sabemos que  $\hat{\beta} = \beta + [X'X]^{-1}X'u \longrightarrow \hat{\beta} - \beta = [X'X]^{-1}X'u$

## RLM: Propriedades

### Prova

Sabemos que  $\hat{\beta} = \beta + [X'X]^{-1}X'u \longrightarrow \hat{\beta} - \beta = [X'X]^{-1}X'u$

$$\begin{aligned}\mathbb{V}(\hat{\beta}|X) &= \mathbb{E}[(\hat{\beta} - \beta)(\hat{\beta} - \beta)'|X] \\ &= \mathbb{E}\left[([X'X]^{-1}X'u)([X'X]^{-1}X'u)'|X\right] \\ &= \mathbb{E}\left[[X'X]^{-1}X'uu'X[X'X]^{-1}|X\right] \\ &= [X'X]^{-1}X' \underbrace{\mathbb{E}[uu'|X]}_{\sigma^2 I} X[X'X]^{-1} \\ &= \sigma^2 \underbrace{[X'X]^{-1}X'X[X'X]^{-1}}_I \\ &= \sigma^2 [X'X]^{-1}\end{aligned}\tag{17}$$

## RLM: Propriedades

- ▶ Na prática,  $\sigma^2$  não é conhecido, então precisamos estima-lo

## RLM: Propriedades

- ▶ Na prática,  $\sigma^2$  não é conhecido, então precisamos estima-lo
- ▶ 
$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n \hat{u}_i^2}{n - (k + 1)}$$

## RLM: Propriedades

- ▶ Na prática,  $\sigma^2$  não é conhecido, então precisamos estima-lo
- ▶ 
$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n \hat{u}_i^2}{n - (k + 1)}$$
- ▶ Pode-se mostrar que, sob HRLM1–HRLM5<sup>1</sup>,  $\mathbb{E}(\hat{\sigma}^2) = \sigma^2$

---

<sup>1</sup>As hipóteses HRLM1–HRLM5 são conhecidas como Hipóteses de Gauss-Markov

# Teorema de Gauss-Markov

## Teorema de Gauss-Markov

Sob as hipóteses HRLM1–HRLM5,  $\hat{\beta}$  é o melhor estimador linear não viesado (Best Linear Unbiased Estimator –BLUE) de  $\beta$ .

# Teorema de Gauss-Markov

## Teorema de Gauss-Markov

Sob as hipóteses HRLM1–HRLM5,  $\hat{\beta}$  é o melhor estimador linear não viesado (Best Linear Unbiased Estimator –BLUE) de  $\beta$ .

- ▶  $\tilde{\beta}$  é **linear** se  $\tilde{\beta} = A'Y$ , onde  $A_{n \times (k+1)}$  função de  $X$

# Teorema de Gauss-Markov

## Teorema de Gauss-Markov

Sob as hipóteses HRLM1–HRLM5,  $\hat{\beta}$  é o melhor estimador linear não viesado (Best Linear Unbiased Estimator –BLUE) de  $\beta$ .

- ▶  $\tilde{\beta}$  é **linear** se  $\tilde{\beta} = A'Y$ , onde  $A_{n \times (k+1)}$  função de  $X$
- ▶ **Melhor:** menor variância.  $V(\hat{\beta}|X) \leq V(\tilde{\beta}|X)$ , para qualquer estimador linear não viesado  $\tilde{\beta}$



## MRLM: Desafíos na prática

## Incluir variáveis irrelevantes

Incluir mais variáveis das que deveríamos.

## Incluir variáveis irrelevantes

Incluir mais variáveis das que deveríamos.

Suponha que o modelo populacional seja

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + u$$

mas estimamos

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \hat{\beta}_3 X_3$$

**Qual é o efeito de incluir a variável irrelevante  $x_3$ ?**

- ▶ Em termos da inexistência do viés não há efeito nenhum  
 $E(\hat{\beta}) = [\beta_0, \beta_1, \beta_2, 0]'$

## Incluir variáveis irrelevantes

Incluir mais variáveis das que deveríamos.

Suponha que o modelo populacional seja

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + u$$

mas estimamos

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \hat{\beta}_3 X_3$$

**Qual é o efeito de incluir a variável irrelevante  $x_3$ ?**

- ▶ Em termos da inexistência do viés não há efeito nenhum  
 $E(\hat{\beta}) = [\beta_0, \beta_1, \beta_2, 0]'$
- ▶ Contudo, incluir variáveis irrelevantes pode ter efeitos indesejáveis nas variâncias dos estimadores MQO.

## Incluir variáveis irrelevantes

$$\underbrace{Y = 2 + 1.2X_1 + u}_{\text{Modelo Verdadeiro}}$$

$$\underbrace{\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2}_{\text{Modelo Estimado}}$$

## Incluir variáveis irrelevantes

$$\underbrace{Y = 2 + 1.2X_1 + u}_{\text{Modelo Verdadeiro}} \quad \underbrace{\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2}_{\text{Modelo Estimado}}$$

```
dados_sim <- simular_dados_ir(n = 1000, rho = 0,  
                             betas = c(2, 1.2))  
summary(lm(y~x1, data = dados_sim))$coefficients
```

```
##              Estimate Std. Error  t value Pr(>|t|)  
## (Intercept) 1.995151 0.02203071 90.56229      0  
## x1          1.202188 0.02218742 54.18333      0
```

```
summary(lm(y~x1+x2, data = dados_sim))$coefficients
```

```
##              Estimate Std. Error  t value  Pr(>|t|)  
## (Intercept) 1.99557544 0.02205083 90.498900 0.0000000  
## x1          1.20206971 0.02219281 54.164836 0.0000000  
## x2          -0.01091434 0.02161174 -0.505019 0.6136012
```


# Incluir variáveis irrelevantes

$$Y = 2 + 1.2X_1 + u$$

Modelo Verdadeiro

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2$$

Modelo Estimado



# Omissão de variáveis

Considerar menos variáveis do que deveríamos.



## Omissão de variáveis

Considerar menos variáveis do que deveríamos.

Suponha que o modelo populacional seja

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

mas estimamos

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2$$

**Qual é o efeito de omitir a variável  $X_3$ ?**

## Omissão de variáveis

Considerar menos variáveis do que deveríamos.

Suponha que o modelo populacional seja

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

mas estimamos

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2$$

**Qual é o efeito de omitir a variável  $X_3$ ?**

- ▶ Em geral, produz estimadores viesados

## Omissão de variáveis

$$\underbrace{Y = 2 + 0.5X_1 + 1.2X_2 + u}_{\text{Modelo Verdadeiro}}$$

$$\underbrace{\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1}_{\text{Modelo Estimado}}$$

## Omissão de variáveis

$$\underbrace{Y = 2 + 0.5X_1 + 1.2X_2 + u}_{\text{Modelo Verdadeiro}} \quad \underbrace{\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1}_{\text{Modelo Estimado}}$$

```
dados_sim <- simular_dados_om(n = 1000, rho = 0.7,  
                              betas = c(2, 0.5, 1.2))  
coef(lm(y ~ x1 + x2, data = dados_sim))
```

```
## (Intercept)          x1          x2  
##    2.0342043    0.4791449    1.1564827
```

```
coef(lm(y ~ x1, data = dados_sim))
```

```
## (Intercept)          x1  
##    2.032879    1.312008
```

## Omissão de variáveis

$$\underbrace{Y = 2 + 0.5X_1 + 1.2X_2 + u}_{\text{Modelo Verdadeiro}}$$

$$\underbrace{\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1}_{\text{Modelo Estimado}}$$


# Omissão de variáveis

$$Y = 2 + 0.5X_1 + 1.2X_2 + u$$

Modelo Verdadeiro

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1$$

Modelo Estimado



# Multicolinearidade

- ▶ A HRLM3 nos diz que não existe colinearidade perfeita entre as variáveis independentes

# Multicolinearidade

- ▶ A HRLM3 nos diz que não existe colinearidade perfeita entre as variáveis independentes
- ▶ Contudo, na prática podemos ter variáveis explicativas fortemente correlacionadas (mas  $\neq \pm 1$ )



# Multilinearidade

- ▶ A HRLM3 nos diz que não existe colinearidade perfeita entre as variáveis independentes
- ▶ Contudo, na prática podemos ter variáveis explicativas fortemente correlacionadas (mas  $\neq \pm 1$ )
- ▶ Este fenômeno é conhecido na literatura como **multicolinearidade**

# Multilinearidade

- ▶ A HRLM3 nos diz que não existe colinearidade perfeita entre as variáveis independentes
- ▶ Contudo, na prática podemos ter variáveis explicativas fortemente correlacionadas (mas  $\neq \pm 1$ )
- ▶ Este fenômeno é conhecido na literatura como **multicolinearidade**
- ▶ Multicolinearidade tem consequências tanto na estimação dos parâmetros quanto na estimação das suas respectivas variâncias.


# Multicolinearidade

$$Y = 2 + 0.5X_1 + 0.2X_2 + u$$

Modelo Verdadeiro

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2$$

Modelo Estimado



## Multicolinearidade: VIF

O Fator de Inflação de Variância (**V**ariance **I**nflation **F**actor –VIF) é um critério para identificar se estamos com problema de multicolineariedade.

## Multicolinearidade: VIF

O Fator de Inflação de Variância (**V**ariance **I**nflation **F**actor –VIF) é um critério para identificar se estamos com problema de multicolineariedade.

### VIF

$$VIF_j = \frac{1}{1 - R_j^2}$$

onde  $R_j^2$  é o  $R^2$  da regressão da  $j$ -ésima variável ( $x_j$ ) sobre as outras variáveis regressoras.

## Multilinearidade: VIF

O Fator de Inflação de Variância (**V**ariance **I**nflation **F**actor –VIF) é um critério para identificar se estamos com problema de multicolineariedade.

### VIF

$$VIF_j = \frac{1}{1 - R_j^2}$$

onde  $R_j^2$  é o  $R^2$  da regressão da  $j$ -ésima variável ( $x_j$ ) sobre as outras variáveis regressoras.

- ▶ Valores grandes de  $VIF_j$  podem indicar multicolinearidade

## Multilinearidade: VIF

O Fator de Inflação de Variância (**V**ariance **I**nflation **F**actor –VIF) é um critério para identificar se estamos com problema de multicolineariedade.

### VIF

$$VIF_j = \frac{1}{1 - R_j^2}$$

onde  $R_j^2$  é o  $R^2$  da regressão da  $j$ -ésima variável ( $x_j$ ) sobre as outras variáveis regressoras.

- ▶ Valores grandes de  $VIF_j$  podem indicar multicolinearidade
- ▶ **Quanto é grande?** Algumas vezes 10 é considerado grande, mas não existe uma regra (10 representaria um  $R_j^2 = 0.9$ )

## Multicolinearidade: VIF

```
library(car)
dados_sim <-simular_dados_mul(n = 1000,
                             rho = 0.995,
                             betas = c(2,0.5,0.2))
modelo <- lm(y~x1+x2, data = dados)
vif(modelo)
```

```
##          x1          x2
## 9.857007 9.857007
```



## Multilinearidade: VIF

```
modelo = lm(log(wage) ~ educ + exper + tenure, data = wage1)
vif(modelo)
```

```
##      educ      exper      tenure
## 1.112771 1.477618 1.349296
```

## O que fazer?

- ▶ Se tivermos evidencia de multicolineariedade, devemos excluir as variáveis que causam a multicolineariedade, ou formar novas variáveis que sejam uma combinação das variáveis originais (por exemplo: utilizar *análise de componentes principais*)

## O que fazer?

- ▶ Se tivermos evidencia de multicolineariedade, devemos excluir as variáveis que causam a multicolineariedade, ou formar novas variáveis que sejam uma combinação das variáveis originais (por exemplo: utilizar *análise de componentes principais*)
- ▶ Variáveis irrelevantes causam um problema maior se as variáveis irrelevantes incluídas forem altamente correlacionada. Podemos calcular a matriz de correlação, verificar se existem variáveis altamente correlacionadas e excluí-las da análise. Podemos também utilizar o VIF para verificar se a inclusão de alguma variável causa problemas de multicolineariedade

## O que fazer?

- ▶ Se tivermos evidencia de multicolineariedade, devemos excluir as variáveis que causam a multicolineariedade, ou formar novas variáveis que sejam uma combinação das variáveis originais (por exemplo: utilizar *análise de componentes principais*)
- ▶ Variáveis irrelevantes causam um problema maior se as variáveis irrelevantes incluídas forem altamente correlacionada. Podemos calcular a matriz de correlação, verificar se existem variáveis altamente correlacionadas e excluí-las da análise. Podemos também utilizar o VIF para verificar se a inclusão de alguma variável causa problemas de multicolineariedade
- ▶ O problema de variáveis omitidas é mais complicado de resolver, pois muitas vezes está além do nosso alcance. Podemos tentar incluir novas variáveis no modelo (se tivermos).

## O que fazer?

- ▶ Se tivermos evidencia de multicolineariedade, devemos excluir as variáveis que causam a multicolineariedade, ou formar novas variáveis que sejam uma combinação das variáveis originais (por exemplo: utilizar *análise de componentes principais*)
- ▶ Variáveis irrelevantes causam um problema maior se as variáveis irrelevantes incluídas forem altamente correlacionada. Podemos calcular a matriz de correlação, verificar se existem variáveis altamente correlacionadas e excluí-las da análise. Podemos também utilizar o VIF para verificar se a inclusão de alguma variável causa problemas de multicolineariedade
- ▶ O problema de variáveis omitidas é mais complicado de resolver, pois muitas vezes está além do nosso alcance. Podemos tentar incluir novas variáveis no modelo (se tivermos).
- ▶ Para evitar o problema de variáveis omitidas é importante pensar (antes mesmo de obter os dados) nas variáveis que podem ser importantes (por isso é importante conhecermos o problema com que

# Leituras recomendadas

## Leituras recomendadas

- ▶ Wooldridge, Jeffrey M. *Introdução à Econometria: Uma abordagem moderna*. (2016). Cengage Learning. – **Cap 3**