

# Análise de Regressão Linear Simples III

## Aula 03

*Gujarati e Porter – Capítulos 4 e 5*

*Wooldridge – Seção 2.5*

# Suposições, Propriedades e Teste t

# Suposições e Propriedades

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

No modelo populacional, a variável resposta  $y$  está relacionada ao regressor  $x$  e ao erro  $\varepsilon$  como

$$y = \beta_0 + \beta_1 x_1 + \varepsilon$$

em que

$\beta_0$  – parâmetro de intercepto populacional (constante);

$\beta_1$  – parâmetro de inclinação populacional (constante);

$\varepsilon$  – erro aleatório não observável.

# Suposições e Propriedades

## RLS.2 – Amostragem Aleatória

Temos uma amostra aleatória de  $n$  observações

$$(x_i, y_i), \quad i = 1, 2, \dots, n,$$

proveniente do modelo populacional descrito em RLS.1.

## RLS.3 – Variação amostral no regressor

Os resultados amostrais em  $x$ , ou seja,  $\{x_i, i = 1, 2, \dots, n\}$  não são todos de mesmo valor.

# Suposições e Propriedades

## RLS.4 – Média Condicional Zero

O termo de erro aleatório,  $\varepsilon$ , tem valor esperado igual a zero, dado qualquer valor do regressor. Ou seja,

$$E(\varepsilon \mid \mathbf{x}) = 0.$$

**Teorema 1.** Sob as suposições RLS.1 a RLS.4, condicional aos valores amostrais do regressor, os estimadores de MQO dos parâmetros do modelo de regressão linear simples são não-viesados, ou seja,  $E(\hat{\beta}_j) = \beta_j$ ,  $j = 0, 1$ . (Exercício:PROVE!)

# Observação

**SUPOSIÇÃO FUNDAMENTAL:**

$$E(\varepsilon \mid x) = 0$$

**Ou seja, todos os fatores contidos em  $\varepsilon$  devem ser não correlacionados com o regressor. Além disso, deve ter sido usada a forma funcional correta.**

# Observação (cont.)

## SUPOSIÇÃO FUNDAMENTAL: (cont)

Como pode falhar?

- *Omissão de regressor relevante, correlacionado com  $x$ ;*
- *Forma funcional especificada incorretamente;*
- *Erro de medida em  $x$ ;*
- *Simultaneidade entre  $y$  e  $x$ ;*

# Suposições e Propriedades

## RLS.5 – Homocedasticidade

O termo de erro aleatório  $\varepsilon$  tem a mesma variância dado qualquer valor do regressor. Ou seja,

$$\text{Var}(\varepsilon \mid x) = \sigma^2.$$

### Observação

De RLS.4 e RLS.5 temos que  $E(\varepsilon^2 \mid x) = \sigma^2$ , o que significa que  $\sigma^2$  também é a expectativa incondicional de  $\varepsilon^2$ . Dessa forma,  $\text{Var}(\varepsilon) = \sigma^2$  (variância do erro).



# Variância dos Estimadores de MQO

**Teorema 2.** Sob as suposições RLS.1 a RLS.5, condicionadas aos valores amostrais da variável explicativa, prova-se que

$$\text{Var}(\hat{\beta}_0) = \sigma^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right),$$

e

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sigma^2}{SST_x}.$$

# Covariância entre os Estimadores de MQO

## Exercício

Mostre que a covariância entre os estimadores para os parâmetros  $\beta_0$  e  $\beta_1$  é dada por

$$\text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = -\bar{x} \text{Var}(\hat{\beta}_1)$$

# Melhores estimadores lineares não-viesados (BLUE)

- Sob as suposições RLS.1 a RLS.5, os estimadores de MQO para os parâmetros  $\beta_0$  e  $\beta_1$  são os melhores dentre todos os estimadores da classe dos lineares não-viesados.
- Isto quer dizer que além de serem não-viesados, tais estimadores apresentam a menor variância dentre os demais estimadores não-viesados, gerando estimadores com menor erro quadrático médio dentre os lineares.

Vide demonstração em Gujarati e Porter (2011, p. 115)

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

## RLS.6 – Normalidade

O erro populacional  $\varepsilon$  é *independente* do regressor  $x$  e é normalmente distribuído, com média zero e variância  $\sigma^2$ . Ou seja,

$$\varepsilon \sim N(0; \sigma^2)$$

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

**Teorema 3** – Sob as suposições RLS.1 a RLS.6, condicionado aos valores amostrais do regressor,

$$\hat{\beta}_j \sim N\left(\beta_j, \text{Var}\left(\hat{\beta}_j\right)\right)$$

## **Observação**

Tais estimadores são normalmente distribuídos, pois, são combinações lineares dos  $y$ 's, que são independentes e normalmente distribuídos.

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

Do teorema anterior vem que,

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\text{Var}(\hat{\beta}_j)}} \sim N(0,1)$$

Do *slide* 9, vimos que as expressões das variâncias dos estimadores dos parâmetros envolvem  $\sigma^2$ , que é um parâmetro desconhecido. Dessa forma, deveremos procurar um estimador para tal parâmetro. Ainda, um estudo da distribuição de probabilidades da nova v.a. gerada deverá ser feito.

# Estimação de $\sigma^2$

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

$$\hat{\sigma}^2 = MSR = \frac{SSR}{n-2}$$

**em que**

$$SSR = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i)^2$$

**SSR perde 2 graus de liberdade, pelas 2 restrições impostas pelas condições de primeira ordem de MQO.**

# Estimação de $\sigma^2$

**Teorema 4.** Sob as suposições RLS.1 a RLS.5

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

## **Observação**

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



# Erro Padrão dos Estimadores de MQO

Substituindo MSR (que é um estimador não viesado para  $\sigma^2$ ) nas expressões provenientes do Teorema 2, teremos que

$$\widehat{Var}(\hat{\beta}_0) = \hat{\sigma}^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{SST_x} \right),$$

e

$$\widehat{Var}(\hat{\beta}_1) = \frac{\hat{\sigma}^2}{SST_x}.$$

em que

$$SST_x = \sum_{i=1}^n (x_i - \bar{x})^2$$

# Erro Padrão dos Estimadores de MQO

À raiz quadrada das duas quantidades anteriores damos o nome de erro-padrão associado ao estimador de mínimos quadrados do *i*-ésimo parâmetro do modelo de regressão. A notação comumente utilizada é a seguinte:

$$\hat{\sigma}_{\hat{\beta}_0} = \hat{\sigma} \sqrt{\left( \frac{1}{n} + \frac{\bar{x}^2}{SST_x} \right)}$$

e

$$\hat{\sigma}_{\hat{\beta}_1} = \frac{\hat{\sigma}}{\sqrt{SST_x}}$$

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

**Teorema 5.** Sob as suposições RLS.1 a RLS.6,

$$\frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim t_{(n-2)}$$

Vale ressaltar que a v.a. anteriormente obtida não pode ser considerada como uma estatística de teste, uma vez que depende do parâmetro  $\beta_j$ .

# INFERÊNCIA

# Teste de Hipóteses

Para testar as hipóteses

$H_0: \beta_j = b$  (em particular  $b = 0$ )

$H_A: \beta_j \neq b$  ( $H_A: \beta_j < b$  ou  $H_A: \beta_j > b$ ),

utilizaremos o fato que, sob  $H_0$  e sob o Teorema 5,

$$\frac{\hat{\beta}_j - b}{\hat{\sigma}_{\hat{\beta}_j}} \sim t_{(n-2)}$$

# Intervalo de Confiança para $\beta_j$

Também, do Teorema 5, não é difícil provar que:

$$IC[\beta_j; \gamma] = \left( \hat{\beta}_j \pm t_{(n-2)}^{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j} \right)$$

(I.C. para  $\beta_j$  com coeficiente  $\gamma = 1 - \alpha$  de confiança)

# Retornando ao Exemplo do RH

- a) Os formuladores do exame acreditam que a nota média seja uma variável relevante para explicar o desempenho. Assim sendo, conduza um teste de hipóteses que seja capaz de verificar a veracidade da afirmação feita pelos formuladores do exame. Para tanto, adote  $\alpha = 5\%$ .
- b) A partir da construção de um intervalo de confiança para o parâmetro intercepto, o que podemos afirmar sobre a significância estatística do mesmo? Adote  $\alpha = 5\%$ .

# Resultados - Excel

**Coefficiente de correlação linear de Pearson**

Estatística de regressão	
R múltiplo	0,7621
R-Quadrado	0,5808
R-quadrado ajustado	0,5721
Erro padrão	6,3332
Observações	50

$R^2$

n

ANOVA

	gl	SQ	MQ	F	F de significação
Regressão	1	2667,85	2667,85	66,51	1,28284E-10
Resíduo	48	1925,27	40,11		
Total	49	4593,12			

	Coefficientes	Erro padrão	Stat t	valor-P	Inferior 95,0%	Superior 95,0%
Interseção	68,51	3,75	18,25	3,10574E-23	60,96	76,06
Variável X 1	1,81	0,22	8,16	1,28284E-10	1,36	2,26

$\hat{\beta}_0$

$\hat{\beta}_1$

**Modelo Estimado:**

$$desempenho = 68,51 + 1,81nota$$




# Leitura Complementar

## Retornando ao Exemplo do RH

**A partir de um teste de hipóteses adequado, verifique se o modelo de regressão proposto é significativo. Adote um nível de significância de 5% ( $\alpha = 0,05$ ).**

# Tabela de Análise de Variâncias (ANOVA)



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

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

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

**SST:** soma de quadrados total

**SSR:** soma de quadrados devido aos resíduos

**SSE:** soma de quadrados devido à explicação (modelo de regressão)

# Tabela de Análise de Variâncias (ANOVA)

SSR, SSE e SST são v.a. e, sob certas condições, é possível provar que:

$$1. \frac{SSR}{\sigma^2} \sim \chi_{(n-2)}^2;$$

$$2. \text{ Se } \beta_1 = 0, \frac{SSE}{\sigma^2} \sim \chi_{(1)}^2;$$

3. SSR e SSE são independentes.

# Tabela de Análise de Variâncias (ANOVA)

## Consequências:

$$(a) \quad E\left(\frac{SSR}{\sigma^2}\right) = n - 2 \Rightarrow E\left(\frac{SSR}{n - 2}\right) = E(MSR) = \sigma^2$$

Logo, MSR é um estimador não-viesado de  $\sigma^2$ ;

$$(b) \quad E(SSE) = \sigma^2 + \beta_1^2 \sum (x_i - \bar{x})^2$$

Se  $\beta_1 = 0$ , então  $SSE / 1 = MSE$  é um estimador não-viesado de  $\sigma^2$ ;

# Tabela de Análise de Variâncias (ANOVA)

## Consequências (cont.):

(c) Se  $\beta_1 = 0$ ,

$$\begin{aligned} E(\text{SST}) &= E(\text{SSR}) + E(\text{SSE}) = \\ &= (n - 2)\sigma^2 + \sigma^2 = (n - 1)\sigma^2 \end{aligned}$$

**Logo,  $\text{SST}/(n-1)$  é estimador não-viesado de  $\sigma^2$  ;**

# Tabela de Análise de Variâncias (ANOVA)

## Consequências (cont.):

(d) Se  $\beta_1 = 0$ ,

$$F_{\text{obs}} = \frac{\frac{\text{SSE}/\sigma^2}{1}}{\frac{\text{SSR}/\sigma^2}{(n-2)}} = \frac{\text{MSE}}{\text{MSR}} \sim F_{[1, n-2]}$$

# Tabela de Análise de Variâncias (ANOVA)

Os resultados descritos em (d) podem ser colocados numa tabela conhecida como ANOVA (Análise de Variâncias)

Regressão	1	SSE	MSE	MSE/MSR
Resíduo	n-2	SSR	MSR	
Total	n - 1	SST		

em que

$$\hat{\sigma}^2 = MSR = \frac{SSR}{n - 2}$$

$$MSE = \frac{SSE}{1}$$



# Teste F

Devido ao item (d), para testarmos

$$H_0: \beta_1 = 0 \text{ vs } H_A: \beta_1 \neq 0$$

rejeitamos  $H_0$  a um nível  $\alpha$  de significância se

$$F_{\text{obs}} \geq F_{[1; n-2]}^{(\alpha)}$$

## Retornando ao Exemplo do RH

**A partir de um teste de hipóteses adequado, verifique se o modelo de regressão proposto é significativo. Adote um nível de significância de 5% ( $\alpha = 0,05$ ).**

# Resultados - Excel

## Modelo Estimado:

$$desempenho = 68,51 + 1,81nota$$

### Estadística de regressão


R múltiplo	0,7621
R-Quadrado	0,5808
R-quadrado ajustado	0,5721
Erro padrão	6,3332
Observações	50

F<sub>obs</sub>

Valor-p

### ANOVA


	gl	SQ	MQ	F	F de significação
Regressão	1	2667,85	2667,85	66,51	1,28284E-10
Resíduo	48	1925,27	40,11		
Total	49	4593,12			



	Coefficientes	Erro padrão	Stat t	valor-P	Inferior 95,0%	Superior 95,0%
Interseção	68,51	3,75	18,25	3,10574E-23	60,96	76,06
Variável X 1	1,81	0,22	8,16	1,28284E-10	1,36	2,26

# Observações Finais

- i. Se não rejeitarmos a hipótese nula de que  $\beta_1 = 0$ , estaremos admitindo que  $E(Y|X=x) = \beta_0$ , cuja representação gráfica é dada por:



neste caso, o modelo de regressão estimado será dado por  $\hat{y} = \bar{y}$

# Observações Finais

De (i), temos que a não rejeição de  $H_0$  fará com que adotemos o modelo

$$\hat{y} = \bar{y}$$

Por outro lado, a rejeição de  $H_0$  fará com que adotemos o modelo

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 \mathbf{x}$$

# Observações Finais

- ii. É importante salientar que a **rejeição de  $H_0$**  não garante a **adequabilidade do modelo**  $\hat{\mathbf{y}} = \hat{\beta}_0 + \hat{\beta}_1 \mathbf{x}$ . Por outro lado, a **rejeição de  $H_0$**  pode ser interpretada como um indicativo de superioridade do modelo  $\hat{\mathbf{y}} = \hat{\beta}_0 + \hat{\beta}_1 \mathbf{x}$  em relação ao modelo  $\hat{\mathbf{y}} = \bar{\mathbf{y}}$ .
- iii. Para verificarmos se o modelo adotado é adequado devemos fazer uma **análise de resíduos**. Desta forma, a **adoção definitiva do modelo**  $\hat{\mathbf{y}} = \hat{\beta}_0 + \hat{\beta}_1 \mathbf{x}$  deve estar **sujeita ainda a análises posteriores**.