



Lisbon School  
of Economics  
& Management  
Universidade de Lisboa

# Estatística II

Licenciatura em Gestão  
2.º Ano/1.º Semestre  
2023/2024

# Aulas Teóricas N.ºs 24 e 25 (Semana 13)

**Docente:** Elisabete Fernandes

**E-mail:** efernandes@iseg.ulisboa.pt



<https://doity.com.br/estatistica-aplicada-a-nutricao>



<https://basiccode.com.br/produto/informatica-basica/>

# Conteúdos Programáticos

Aulas Teóricas  
(Semanas 1 a 5)

- **Capítulo 1:** Estimação

Aulas Teóricas  
(Semanas 5 a 7)

- **Capítulo 2:** Testes de Hipóteses

Aulas Teóricas  
(Semanas 7 a 9)

- **Capítulo 3:** Modelo de Regressão Linear

Aulas Teóricas  
(Semanas 10 a 13)

- **Capítulo 4:** Complementos ao Modelo de Regressão Linear

**Material didático:** Exercícios do Livro Murteira et al (2015), Formulário e Tabelas Estatísticas

**Bibliografia:** B. Murteira, C. Silva Ribeiro, J. Andrade e Silva, C. Pimenta e F. Pimenta; *Introdução à Estatística*, 2ª ed., Escolar Editora, 2015.

<https://cas.iseg.ulisboa.pt>

### **8ª semana (07/11 e 09/11)**

T14 - Modelo de Regressão Linea (MRL)r

Interpretação dos parâmetros da regressão; exemplos; Resíduos MQ e regressão ajustada; Propriedades dos estimadores MQ dos coeficientes da regressão; Estimador não enviesado da variância da variável residual; Exemplo.

T15 - Modelo de regressão Linear

Coefficiente de determinação e sua interpretação. Hipótese adicional ( $H_6$ ) e inferência estatística sobre o modelo; Inferência sobre um parâmetro beta. Exemplos

### **9ª semana (14/11 e 16/11)**

T16 - Modelo de Regressão Linear

Mais exemplos de inferência sobre um parâmetro beta; Inferência sobre uma combinação linear de betas; exemplos.

T17 - Modelo de Regressão Linear

Teste de nulidade conjunta de vários coeficientes; exemplo; Teste F à significância global da regressão; Teste de um conjunto de restrições lineares; exemplo.

### **10ª semana (21/11 e 23/11)**

T18 - Complementos ao MRL

Variáveis artificiais: Introdução à modelação de fatores qualitativos, conceito de variável artificial, estimação e interpretação do modelo com variáveis artificiais; exemplos.

T19 - Complementos ao MRL



# Inferência na Regressão Linear Múltipla

Teste t para Combinações Lineares dos  
Coeficientes do MRLM

1

# Combinação Linear de Parâmetros

## Combinação linear dos parâmetros:

Dado o modelo de RLM:

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

Sob as premissas do Teorema de Gauss-Markov, temos que:

$$E(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta} \quad \text{e} \quad \text{Var}(\hat{\boldsymbol{\beta}}) = E[(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})^T] = (\mathbf{X}^T \mathbf{X})^{-1} \sigma^2$$

Uma combinação linear dos parâmetros, onde cada coeficiente  $\beta_j$  seja multiplicado por uma constante  $c_j$ , seria dado por:

$$c_0 \alpha + c_1 \beta_1 + \dots + c_k \beta_k = \begin{pmatrix} c_0 & c_1 & \dots & c_k \end{pmatrix} \begin{pmatrix} \alpha \\ \beta_1 \\ \dots \\ \beta_k \end{pmatrix} = \mathbf{c}^T \boldsymbol{\beta}$$

Não é difícil demonstrar que:

$$E(\mathbf{c}^T \hat{\boldsymbol{\beta}}) = \mathbf{c}^T E(\hat{\boldsymbol{\beta}}) = \mathbf{c}^T \boldsymbol{\beta} \quad \text{ou seja, uma função linear dos estimadores de MQO é um estimador não viesado da função linear dos parâmetros}$$

E:

$$\text{Var}(\mathbf{c}^T \hat{\boldsymbol{\beta}}) = E[(\mathbf{c}^T \hat{\boldsymbol{\beta}} - \mathbf{c}^T \boldsymbol{\beta})(\mathbf{c}^T \hat{\boldsymbol{\beta}} - \mathbf{c}^T \boldsymbol{\beta})^T] = \mathbf{c}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{c} \sigma^2 \quad \text{a variância da função linear será uma grandeza escalar.}$$

A combinação linear dos parâmetros pode ser utilizada em teste de hipóteses para combinações dos parâmetros ou intervalos de confiança para os valores previstos.

# Teste t para uma Combinação Linear

Seja o ajuste de MQ:

$$Y_i = \hat{\alpha} + \hat{\beta}_1 X_{1_i} + \hat{\beta}_2 X_{2_i} + \dots + \hat{\beta}_k X_{k_i} + \hat{\epsilon}_i$$

Suponha as seguintes hipóteses para os parâmetros  $\beta_1$  e  $\beta_2$  do modelo:

$$\begin{cases} H_0: \beta_1 = \beta_2 \\ H_1: \beta_1 \neq \beta_2 \end{cases}$$

Testar a hipótese nula que  $\beta_1 = \beta_2$  é o mesmo que testar a combinação:

$$(0)\alpha + (1)\beta_1 + (-1)\beta_2 + \dots + (0)\beta_k = 0$$

ou, matricialmente:  $(0 \ 1 \ -1 \ 0 \ \dots \ 0) \begin{pmatrix} \alpha \\ \beta_1 \\ \dots \\ \beta_k \end{pmatrix} = \mathbf{c}^T \boldsymbol{\beta} = 0$

A estatística t

$$(0 \ 1 \ -1 \ 0 \ \dots \ 0) \begin{pmatrix} \hat{\alpha} \\ \hat{\beta}_1 \\ \dots \\ \hat{\beta}_k \end{pmatrix} = \mathbf{c}^T \hat{\boldsymbol{\beta}}$$

Como combinação linear de v.a.s normais é também uma normal, teremos:  $\mathbf{c}^T \hat{\boldsymbol{\beta}} \sim N(\mathbf{c}^T \boldsymbol{\beta}, \sigma_{\mathbf{c}^T \hat{\boldsymbol{\beta}}}^2)$

Onde:  $\sigma_{\mathbf{c}^T \hat{\boldsymbol{\beta}}}^2 = \mathbf{c}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{c} \sigma^2$


# Teste t para uma Combinação Linear

Finalmente, para resolver o teste de hipóteses:


$$\begin{cases} H_0: \beta_1 = \beta_2 \\ H_1: \beta_1 \neq \beta_2 \end{cases}$$

Rejeito  $H_0$  quando o valor p, probabilidade de erro ao rejeitar  $H_0$ , for suficientemente pequeno.

$$\mathbf{c}^T \hat{\boldsymbol{\beta}} \sim N(0, \sigma_{\mathbf{c}^T \hat{\boldsymbol{\beta}}}^2)$$



$$t = \frac{\mathbf{c}^T \hat{\boldsymbol{\beta}} - 0}{\sqrt{\mathbf{c}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{c} \hat{\sigma}^2}}$$



7/10

Slide 1 (unicamp.br)



# Teste t para uma Combinação Linear: Exemplo

Sejam os dados da relação entre renda familiar ( $Y$ ), anos de estudo ( $X_1$ ) e idade ( $X_2$ ) do responsável pela família:

$$Y_i = 1,9 + 1X_{1i} + 0,06X_{2i} + \hat{e}_i$$

Há evidências de que o efeito dos anos de estudo seja maior que o da idade?

$$\begin{cases} H_0: \beta_1 = \beta_2 \\ H_1: \beta_1 > \beta_2 \end{cases}$$

Testar a hipótese nula que  $\beta_1 = \beta_2$  é o mesmo que testar a combinação:

$$(0)\alpha + (1)\beta_1 + (-1)\beta_2 = 0$$

$$\text{ou, matricialmente: } (0 \ 1 \ -1) \begin{pmatrix} \alpha \\ \beta_1 \\ \beta_2 \end{pmatrix} = \mathbf{c}^T \boldsymbol{\beta} = 0$$

$$\text{E a estatística } t : \mathbf{c}^T \hat{\boldsymbol{\beta}} = (0 \ 1 \ -1) \begin{pmatrix} \hat{\alpha} \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{pmatrix} = (0 \ 1 \ -1) \begin{pmatrix} 1,9 \\ 1 \\ 0,06 \end{pmatrix} = 0,94$$

Que estará normalmente distribuída e a estimativa de sua variância será:


$$S_{\mathbf{c}^T \hat{\boldsymbol{\beta}}}^2 = \mathbf{c}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{c} \hat{\sigma}^2 = (0 \ 1 \ -1) \begin{pmatrix} 8,95 & 2,5 & -0,57 \\ 2,5 & 1 & -0,2 \\ -0,57 & -0,2 & 0,042 \end{pmatrix} \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix} 0,2 = 0,2884$$

# Teste t para uma Combinação Linear: Exemplo


$$\begin{cases} H_0: \beta_1 = \beta_2 \\ H_1: \beta_1 > \beta_2 \end{cases}$$

Se afirmarmos que o efeito isolado dos anos de escolaridade é superior ao da idade estaremos sujeitos a um erro de 16,5%

$$c^T \hat{\beta} \sim N(0, \sigma_{c^T \hat{\beta}}^2)$$



$$t = \frac{0,94 - 0}{\sqrt{0,2884}}$$



8/10

Slide 1 (unicamp.br)

Seja a equação de regressão múltipla,

$$\text{salário} = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{produtividade} + \varepsilon$$

Verifique, a partir da formulação e construção de um teste de hipóteses, se a variável *educ* apresenta um impacto superior ao da variável *produtividade* na variável resposta. Nesse exemplo, utilize o banco de dados *TEMCPROD.wf1*.



# Resolução do Exercício

## Modelo

$$\text{salário} = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{produtividade} + \varepsilon$$

## Hipóteses

$$H_0 : \beta_1 = \beta_2 \Leftrightarrow \beta_1 - \beta_2 = 0$$

$$H_A : \beta_1 > \beta_2$$

# Testes de Hipóteses para uma Combinação Linear de Parâmetros

Sejam as hipóteses

$$H_0 : \beta_i = \beta_j \Leftrightarrow \beta_i - \beta_j = 0$$

$$H_A : \beta_i \neq \beta_j \text{ (} \beta_i < \beta_j \text{ ou } \beta_i > \beta_j \text{)}$$

Estatística do teste

$$t = \frac{(\hat{\beta}_i - \hat{\beta}_j) - 0}{se(\hat{\beta}_i - \hat{\beta}_j)}$$

$$se(\hat{\beta}_i - \hat{\beta}_j) = \sqrt{[se(\hat{\beta}_i)]^2 + [se(\hat{\beta}_j)]^2 - 2Cov(\hat{\beta}_i, \hat{\beta}_j)}$$

# Testes de Hipóteses para uma Combinação Linear de Parâmetros

## ALTERNATIVAS DE SOLUÇÃO

A) Calcular todos os componentes do erro padrão (o *software Eviews* gera a matriz de variâncias e covariâncias para os estimadores dos parâmetros do modelo de regressão. Lembra onde está?).

$$se(\hat{\beta}_i - \hat{\beta}_j) = \sqrt{[se(\hat{\beta}_i)]^2 + [se(\hat{\beta}_j)]^2 - 2C\hat{o}v(\hat{\beta}_i, \hat{\beta}_j)}$$

# Testes de Hipóteses para uma Combinação Linear de Parâmetros

**B) Trabalhar com um modelo transformado para obter o resultado diretamente**

**Seja**

$$\theta = \beta_i - \beta_j,$$

por exemplo,  $\beta_j$  pode ser escrito como  $\beta_j = \beta_i - \theta$  e, substituindo este resultado na equação de regressão múltipla, podemos testar  $H_0: \theta = 0$ , contra uma alternativa apropriada.

# Resolução do Exercício

Modelo **(solução B)**

$$\text{salário} = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{produtividade} + \varepsilon$$

Hipóteses

$$H_0 : \beta_1 = \beta_2 \Leftrightarrow \beta_1 - \beta_2 = 0$$

$$H_A : \beta_1 > \beta_2$$

Escrevendo  $\theta = \beta_1 - \beta_2$ , vem que

$$H_0 : \theta = 0$$

$$H_A : \theta > 0$$



## Resolução do Exercício

Mas,  $\theta = \beta_1 - \beta_2 \Leftrightarrow \beta_1 = \theta + \beta_2$ , e substituindo este resultado no modelo proposto, vem que

$$\text{salário} = \beta_0 + \beta_1 \text{educ} + \beta_2 \text{produtividade} + \varepsilon$$



$$\text{salário} = \beta_0 + (\theta + \beta_2) \text{educ} + \beta_2 \text{produtividade} + \varepsilon$$



$$\text{salário} = \beta_0 + \theta \text{educ} + \beta_2 \text{educ} + \beta_2 \text{produtividade} + \varepsilon$$



$$\text{salário} = \beta_0 + \theta \text{educ} + \beta_2 (\text{educ} + \text{produtividade}) + \varepsilon$$

# Resolução do Exercício

Dependent Variable: SALARIO

Method: Least Squares

Date: 09/06/10 Time: 17:24

Sample: 1 46

Included observations: 46

SALARIO=C(1)+C(2)\*EDUC+C(3)\*(EDUC+PRODUTIVIDADE)

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	12281.96	3944.548	3.113654	0.0033
C(2)	1255.717	591.9782	2.121222	0.0397
C(3)	470.0954	132.2545	3.554476	0.0009
R-squared	0.693710	Mean dependent var		39827.39
Adjusted R-squared	0.679464	S.D. dependent var		10999.24
S.E. of regression	6227.324	Akaike info criterion		20.37427
Sum squared resid	1.67E+09	Schwarz criterion		20.49353
Log likelihood	-465.6083	Hannan-Quinn criter.		20.41895
F-statistic	48.69484	Durbin-Watson stat		1.198179
Prob(F-statistic)	0.000000			

# Resolução do Exercício: Decisão

## (solução B)

### Hipoteses

$$H_0 : \theta = 0$$

$$H_A : \theta > 0$$

### Sob $H_0$

$$t_{obs} = \frac{1255,717 - 0}{591,978} = 2,121222$$

$$t_{crítico} = t_{n-k}^{\alpha} = t_{43}^{0,05} = @qtdist(0.95,43) = 1,681$$

$$p\text{-valor} = 1 - @ctdist(2.121222,43) = 0,01985$$



# Inferência na Regressão Linear Múltipla

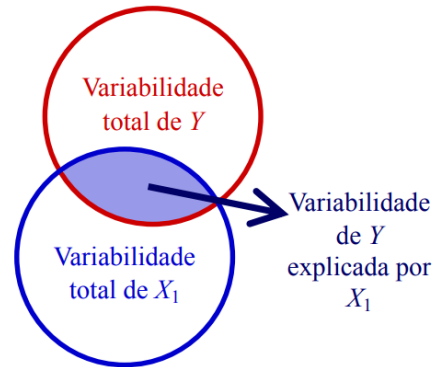
Teste para Restrições dos Coeficientes do MRLM

# 2

# Contribuição Marginal

Seja o modelo de RLS:

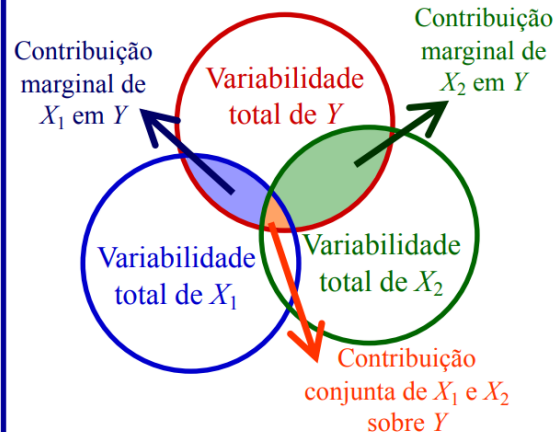
$$Y = \alpha + \beta_1 X_1 + e$$



O grau de relacionamento linear entre  $X_1$  e  $Y$  determinará a parcela da variabilidade de  $Y$  explicada unicamente por  $X_1$ .

Seja o modelo de RLM:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + e$$



Qual a parcela da variabilidade de  $Y$  explicada isoladamente por  $X_2$ ?

Em outras palavras, qual a contribuição marginal de  $X_2$ , depois de considerada a contribuição de  $X_1$ ?


# Contribuição Marginal (q=1)

## SQReg devido a $X_1$ e $X_2$ (Irrestrito):

$$SQReg(Y / X_1 \text{ e } X_2) \text{ ou } SQReg_{ir}$$

Variabilidade de  $Y$  explicada pelo conjunto das variáveis  $X_1$  e  $X_2$ .

**Graus de liberdade: 2** *coeficientes angulares do modelo*  
 $Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + e$ .




## SQReg devido exclusivamente a $X_1$ (Restrito):

$$SQReg(Y / X_1) \text{ ou } SQReg_r$$

Variabilidade de  $Y$  explicada exclusivamente por  $X_1$ .

**Graus de liberdade: 1** *coeficiente angular do modelo*  
 $Y = \alpha + \beta_1 X_1 + e$ .




## SQReg devido ao acréscimo de $X_2$ :

$$\text{Contribuição } X_2 = SQReg_{ir} - SQReg_r$$

Variabilidade de  $Y$  explicada por  $X_2$  após considerada a variabilidade explicada por  $X_1$ .

**Graus de liberdade: 1** *novo coeficiente angular incorporado no modelo ( $\beta_2$ ).*




# Contribuição Marginal (q=2)

**SQReg devido a  $X_1$ ,  $X_2$  e  $X_3$  (Irrestrito):**

$$SQReg(Y / X_1, X_2, X_3) \text{ ou } SQReg_{ir}$$

Variabilidade de  $Y$  explicada pelo conjunto das variáveis  $X_1$ ,  $X_2$  e  $X_3$ :

**Graus de liberdade: 3** *coeficientes angulares do modelo*  
 $Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + e$




**SQReg devido exclusivamente a  $X_1$  (Restrito):**

$$SQReg(Y / X_1) \text{ ou } SQReg_r$$

Variabilidade de  $Y$  explicada exclusivamente por  $X_1$

**Graus de liberdade: 1** *coeficiente angular do modelo*  $Y = \alpha + \beta_1 X_1 + e$ .




**SQReg devido ao acréscimo de  $X_2$  e  $X_3$ :**

$$\text{Contribuição de } X_2 \text{ e } X_3 = SQReg_{ir} - SQReg_r$$

Variabilidade de  $Y$  explicada por  $X_2$  e  $X_3$  após considerada a variabilidade explicada por  $X_1$

**Graus de liberdade: 2** *novos coeficientes angulares incorporados no modelo ( $\beta_2$  e  $\beta_3$ ).*



# Teste de Restrição aos Parâmetros

Seja o modelo *irrestrito* de RLM:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + e$$

Para verificarmos se a contribuição de um grupo de  $q$  variáveis independentes é significativa no modelo irrestrito devemos, primeiro, elaborar um modelo com restrição aos parâmetros. Suponha que, por simplicidade, as  $q$  variáveis que desejamos testar são as últimas das  $k$  variáveis do modelo irrestrito (a ordem, obviamente, não faz importância). Nosso modelo *restrito* seria:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_{k-q} X_{k-q} + e$$

Em outras palavras, estaríamos interessados em testar a hipótese nula de que os  $q$  coeficientes do modelo irrestrito são nulos:

$$H_0 : \beta_{k-q+1} = 0, \dots, \beta_k = 0 \quad \text{e} \quad H_1 : \text{pelo menos um } \beta_{k-q+j} \neq 0$$

O teste estatístico para restrição aos parâmetros consiste em verificar se a contribuição marginal dessas  $q$  variáveis é significativa. A estatística  $F$  será dada por:

$$F = \frac{(SQRe_{g_{ir}} - SQRe_{g_r})/q}{SQRe_{s_{ir}}/(n-k-1)} \quad \text{ou} \quad F = \frac{(SQRe_{s_r} - SQRe_{s_{ir}})/q}{SQRe_{s_{ir}}/(n-k-1)}$$

Onde  $SQRe_{g_{ir}}$  e  $SQRe_{g_r}$  são, respectivamente, a soma dos quadrados da regressão sem e com restrição nos parâmetros,  $SQRe_{s_{ir}}$  é a soma dos quadrados dos resíduos da regressão sem restrição.

A soma dos quadrados de regressão SSR dos dois modelos são comparados!!

A soma dos quadrados dos resíduos SSE dos dois modelos são comparados!!

Formulário

Testes de restrições lineares sobre os coeficientes de regressão

Caso geral ( $m$  restrições lineares):  $F = \frac{(VR_0 - VR_1)/m}{VR_1/(n-k)} \sim F(m, n-k)$

$VR_0$  = Variação residual do modelo com as  $m$  restrições lineares;

$VR_1$  = Variação residual do modelo sem restrições



# Testes de Hipóteses para Restrições

## Testes de restrições lineares sobre os coeficientes de regressão

Caso geral ( $m$  restrições lineares):  $F = \frac{(VR_0 - VR_1)/m}{VR_1/(n-k)} \sim F(m, n-k)$

$VR_0$  = Variação residual do modelo com as  $m$  restrições lineares;

$VR_1$  = Variação residual do modelo sem restrições

## Casos particulares

- Uma única restrição ( $m=1$ ):  $t_{\hat{\delta}} = \frac{\hat{\delta} - \delta}{s_{\hat{\delta}}} \sim t(n-k)$  em que  $s_{\hat{\delta}}$  é o erro padrão de  $\hat{\delta} = cb$ .
- Nulidade conjunta:  $F = \frac{R^2/(k-1)}{(1-R^2)/(n-k)} = \frac{VE/(k-1)}{VR/(n-k)} \sim F(k-1, n-k)$
- Nulidade de um subconjunto ( $m$ )

$$F = \frac{(VR_0 - VR_1)/m}{VR_1/(n-k)} \sim F(m, n-k) \text{ ou } F = \frac{(R^2 - R_0^2)/m}{(1-R^2)/(n-k)} \sim F(m, n-k)$$

$VR_1$  = Variação residual do modelo sem restrições;

$VR_0$  = Variação residual do modelo com restrições

$R_0$  = Coeficiente de determinação do modelo com restrições

# O Teste F para a Contribuição Marginal

Seja o modelo de RLM:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + e$$


Para testarmos a contribuição marginal de um grupo de  $q$  variáveis, teremos as hipóteses:

$$\begin{cases} H_0: \beta_{k-q+1} = \dots = \beta_k = 0 \text{ (não contribui)} \\ H_1: \text{Pelo menos um } \beta_j \neq 0 \text{ (contribui)} \end{cases}$$

A estatística de teste será

$$F = \frac{(SQReg_{ir} - SQReg_r)/q}{SQRes_{ir}/(n-k-1)}$$

Considerando  $H_0$  verdadeiro, a distribuição de  $F$  será...



Rejeitar  $H_0$  significa afirmar que o grupo de  $q$  variáveis contribui para explicar  $Y$ , ou seja, há relação significativa entre pelo menos uma destas variáveis explicativas e a variável dependente.


A soma dos quadrados de regressão SSR dos dois modelos são comparados!!

# O Teste F para a Contribuição Marginal: Exemplo

Na relação entre renda familiar ( $Y$ ), anos de estudo ( $X_1$ ) e idade ( $X_2$ ) do responsável pela família, a contribuição marginal da idade é significativa?


**Modelo Irrestrito:**  $Y_i = 1,9 + 1X_{1i} + 0,06X_{2i} + \hat{\varepsilon}_i$

**Modelo Restrito:**  $Y_i = 2,714 + 1,286X_{1i} + \hat{\varepsilon}_i$



Fonte	gl	Soma dos Quadrados	Quadrados Médios	F
Regressão Restrita	1	34,714	34,714	$F = 0,086/0,2 = 0,43$
Contribuição Marginal	1	0,086	0,086	0,430
Regressão Irrestrita	2	34,800	17,400	87,000
Resíduos	1	0,200	0,200	
Total	3	35,000		

$$\frac{SQ_{Regr_{cont}}/1}{SQ_{Res}/1} \sim F_{1,1}$$



Não há evidências para afirmar que a contribuição marginal da idade sobre a variabilidade da renda familiar seja significativa. A probabilidade de erro ao fazermos tal afirmação é muito alta, de aproximadamente 63%.

# Anova para a Contribuição Marginal

Fonte	gl	Soma dos Quadrados	Quadrados Médios	F
Regressão Restrita	$k - q$	$SQReg_r$	$SQReg_r / (k - q)$	
Contribuição	$q$	$SQReg_{ir} - SQReg_r$	$\frac{(SQReg_{ir} - SQReg_r)}{q}$	$F = \frac{QMReg_{contribuição}}{QMRes_{ir}}$
Regressão Irrestrita	$k$	$SQReg_{ir}$	$SQReg_{ir} / k$	$F = \frac{QMReg_{ir}}{QMRes_{ir}}$
Resíduos	$n - (k + 1)$	$SQRes_{ir}$	$SQRes_{ir} / (n - k - 1)$	
Total	$n - 1$	$STQ$		

# Coefficiente de Correlação Parcial

Seja o modelo de RLM:

$$Y_i = \alpha + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + e_i$$

Da mesma forma que análise de variância permite considerar a contribuição marginal de uma variável explanatória, podemos estender o conceito de correlação simples para ver em que medida a variável dependente e uma das variáveis independentes estão relacionadas, depois de isolados os efeitos das demais variáveis explanatórias do modelo:

$$r_{Y1.23\dots k}$$

O  $r_{Y1.23\dots k}$  é a correlação parcial entre  $Y$  e  $X_1$ , mantendo-se constantes os efeitos das  $k-1$  variáveis independentes restantes. Seu quadrado,  $r^2_{Y1.23\dots k}$  é o respectivo coeficiente de determinação parcial.

O respectivo coeficiente de determinação parcial, que mede a parcela da variabilidade de  $Y$  não associada aos demais regressores que é explicada exclusivamente por  $X_1$  será representado por

$$r^2_{Y1.23\dots k}$$

# Coeficiente de Correlação Parcial


Seja o modelo de RLM:  $Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + e$

Para calcularmos  $r_{Y1.2}$ , poderíamos seguir os seguintes passos:

**Passo 1)** Estimar resíduos do ajuste:  $Y = \hat{\delta}_0 + \hat{\delta}_1 X_2 + \hat{e}_{y2}$   
 $\hat{e}_{y2}$  contém a parcela de  $Y$  não associada a  $X_2$ .

**Passo 2)** Estimar resíduos da relação:  $X_1 = \hat{\gamma}_0 + \hat{\gamma}_1 X_2 + \hat{e}_{12}$   
 $\hat{e}_{12}$  contém a parcela de  $X_1$  não associada a  $X_2$ .

**Passo 3)** Estimar correlação entre os resíduos dos dois modelos:  $r_{Y1.2} = r_{\hat{e}_{y2}\hat{e}_{12}}$



# Coefficiente de Correlação Parcial

## Coefficiente de Correlação Parcial

No caso de duas variáveis independentes:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + e$$

Então a correlação parcial poderá ser diretamente obtida por:

$$r_{Y1.2} = \frac{r_{Y1} - r_{Y2}r_{12}}{\sqrt{(1-r_{12}^2)(1-r_{Y2}^2)}} \quad \text{e} \quad r_{Y2.1} = \frac{r_{Y2} - r_{Y1}r_{12}}{\sqrt{(1-r_{12}^2)(1-r_{Y1}^2)}}$$

Analogamente, o coeficiente de determinação parcial será dado por:

$$r^2_{Y1.2} = \frac{R^2 - r_{Y2}^2}{1 - r_{Y2}^2}$$

## Coefficiente de Correlação Parcial: Exemplo

Vamos considerar a relação para a renda ( $Y$ ) como função dos anos de estudo ( $X_1$ ) e idade ( $X_2$ ).



$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + e \quad \Rightarrow \quad Y_i = 1,9 + 1X_{1i} + 0,06X_{2i} + \hat{e}_i$$

Para calcularmos a correlação parcial entre renda e anos de estudo ( $r_{Y1.2}$ ), podemos seguir os seguintes passos:


**Passo 1)** Estimar resíduos do ajuste:  $Y = 2,714 + 1,286X_2 + \hat{e}_{y2}$

**Passo 2)** Estimar resíduos da relação:  $X_1 = -2,5 + 0,2X_2 + \hat{e}_{12}$

**Passo 3)** Estimar correlação entre os resíduos dos dois modelos:  $r_{Y1.2} = r_{\hat{e}_{y2}\hat{e}_{12}} = 0,913$



$$r^2_{y1.2} = 0,833$$





## Coeficiente de Correlação Parcial: Exemplo

Vamos considerar a relação para a renda ( $Y$ ) como função dos anos de estudo ( $X_1$ ) e idade ( $X_2$ ).

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + e \quad \Rightarrow \quad Y_i = 1,9 + 1X_{1i} + 0,06X_{2i} + \hat{e}_i$$

Podemos ainda calcular a correlação parcial entre renda e anos de estudo ( $r_{Y1.2}$ ) diretamente por:


$$r_{Y1.2} = \frac{r_{Y1} - r_{Y2}r_{12}}{\sqrt{(1-r_{12}^2)(1-r_{Y2}^2)}} = \frac{(0,9959) - (0,9827)(-0,9757)}{\sqrt{[1 - (0,9759)^2][1 - (0,9827)^2]}} = 0,913$$

Onde:

$$r_{Y1} = \frac{\sum_{i=1}^n x_{1i} y_i}{\sqrt{\sum_{i=1}^n x_{1i}^2 \sum_{i=1}^n y_i^2}} = \frac{27}{\sqrt{(21)(35)}} = 0,9959$$

$$r_{Y2} = \frac{\sum_{i=1}^n x_{2i} y_i}{\sqrt{\sum_{i=1}^n x_{2i}^2 \sum_{i=1}^n y_i^2}} = \frac{130}{\sqrt{(500)(35)}} = 0,9827$$

$$r_{12} = \frac{\sum_{i=1}^n x_{1i} x_{2i}}{\sqrt{\sum_{i=1}^n x_{1i}^2 \sum_{i=1}^n x_{2i}^2}} = \frac{100}{\sqrt{(21)(500)}} = 0,9759$$



# Variáveis Artificiais

Complementos ao Modelo de Regressão Linear Múltipla

# 3

# Variáveis Binárias: Definição

- 1) Escala Nominal:** Valores representam categorias (*nomes*). Não se pode falar que um seja maior que o outro. Exemplo: sexo.
- 2) Escala Ordinal:** Valores representam uma hierarquia de posições. Não se pode, entretanto, falar quão maior é um valor em relação a outro. Exemplo: classe social.
- 3) Escala Intervalar:** Valores representam ordem e é possível mensurar intervalo entre eles. Não se pode, entretanto, dizer quantas vezes um é maior que outro. Exemplo: ano.
- 4) Escala de razão:** Valores representam ordem, é possível mensurar intervalo entre eles e quantificar grandezas em uma escala de razão. Exemplo: renda.

## Variável Binária

Uma variável binária (variável *dummy*) pode representar dois estados possíveis::

$$X \begin{cases} 0, \text{ ausência da característica de interesse (Fracasso)} \\ 1, \text{ presença da característica de interesse (Sucesso)} \end{cases}$$

Podemos, assim, estimar a influência de variáveis explicativas (independentes) nominais ou ordinais em modelo de regressão, da mesma maneira que fazemos com variáveis quantitativas de escala intervalar ou de razão.

## Variáveis Dummy

Uma forma de introduzir características qualitativas em modelos econométricos consiste na utilização de **variáveis dummy** (fictícia, postiça), frequentemente chamadas de **variáveis binárias ou dicotômicas**, uma vez que assumem apenas um de dois valores – em geral 0 ou 1 – para indicar a presença ou ausência de determinada característica.

## Variáveis Dummy

Vale lembrar que a **variável *dummy*** representa estados ou níveis de fatores, ou seja representa algo que **não possui valores numéricos** ou, caso possua, estes valores não têm realmente um significado numérico.

Assim, uma **variável *dummy*,  $D$** , pode ser descrita da seguinte maneira:

$$D = \begin{cases} 0, & \text{se a característica não estiver presente} \\ 1, & \text{se a característica estiver presente} \end{cases}$$


## Duas Categorias Nominais

- Para representar duas categorias nominais (A e B) em um modelo de regressão, é necessária apenas uma variável binária ( $D$ );
- A categoria de referência (ou referência de análise) é aquela em que  $D=0$ ;

$$Y_i = \alpha + \beta_1 X_i + \beta_2 D_i + e_i$$

O coeficiente  $\beta_2$  indicaria quanto  $Y$  seria, em média, maior (ou menor) para a categoria A ( $D=1$ ) que a categoria de referência B ( $D=0$ ), independente do valor de  $X$ .

Categoria	$D_i$
A	1
B	0



Para A:  $Y_i = (\alpha + \beta_2) + \beta_1 X_i + e_i$

Para B:  $Y_i = \alpha + \beta_1 X_i + e_i$


# Múltiplas Categorias Nominais

- Para representar  $k$  categorias nominais, são necessárias  $k-1$  variáveis binárias  $D$ 's.
- A referência da análise será a categoria em que todas as variáveis binárias assumem 0 simultaneamente. Exemplo, supondo  $k=3$ :

$$Y_i = \alpha + \beta_1 X_i + \beta_2 D_{1i} + \beta_3 D_{2i} + e_i$$

Categoria	$D_{1i}$	$D_{2i}$
A	1	0
B	0	1
C	0	0

O coeficiente  $\beta_2$  indicaria quanto  $Y$  seria, em média, maior para a categoria A ( $D_1=1$ ) que a categoria de referência C ( $D_1=0$  e  $D_2=0$ ), independente do valor de  $X$ . O coeficiente  $\beta_3$  indicaria quanto  $Y$  seria, em média, maior para a categoria B ( $D_2=1$ ) que a categoria de referência C. Pois teríamos:



Para A:  $Y_i = (\alpha + \beta_2) + \beta_1 X_i + e_i$


Para B:  $Y_i = (\alpha + \beta_3) + \beta_1 X_i + e_i$

Para C:  $Y_i = \alpha + \beta_1 X_i + e_i$

# Múltiplas Categorias: Exemplo

Sejam os dados amostrais para renda ( $Y$ ), anos de estudo ( $X$ ) e posição na ocupação:

$Y_i$	$X_i$	Posição Ocupação	$D_{1i}$	$D_{2i}$
100	0	Empregado	0	0
200	4	Empregado	0	0
400	8	Empregado	0	0
400	4	Autônomo	1	0
500	8	Autônomo	1	0
600	0	Empregador	0	1



Independente dos anos de escolaridade, o rendimento médio dos autônomos seria 146,7 reais superior ao dos empregados e o dos empregadores 506,7 superior.

Sejam as binárias:

$$D_{1i} = \begin{cases} 1, & \text{se Autônomo} \\ 0, & \text{c.c.} \end{cases}$$

$$D_{2i} = \begin{cases} 1, & \text{se Empregador} \\ 0, & \text{c.c.} \end{cases}$$

Supondo o modelo:

$$Y_i = \alpha + \beta_1 X_i + \beta_2 D_{1i} + \beta_3 D_{2i} + e_i$$

O estimador de MQO:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{y})$$

$$\hat{\beta} = \begin{pmatrix} 6 & 24 & 2 & 1 \\ 24 & 160 & 12 & 0 \\ 2 & 12 & 2 & 0 \\ 1 & 0 & 0 & 1 \end{pmatrix}^{-1} \begin{pmatrix} 2200 \\ 9600 \\ 900 \\ 600 \end{pmatrix} = \begin{pmatrix} 93,3 \\ 35 \\ 146,7 \\ 506,7 \end{pmatrix}$$



A senhorita Rose Jolie, gerente do departamento de RH da empresa TEMCO, gostaria de estimar os parâmetros de um modelo de regressão linear que levasse em consideração as variáveis explicativas *educ* e *dept* na explicação da variável resposta *salário*. Auxilie a senhorita Jolie nesta proposição.



**Apenas para lembrar, a senhorita Jolie, coletou informações de uma amostra aleatória de 46 funcionários da empresa, sobre as seguintes variáveis:**

**id** – número cadastral do funcionário;

**salario** – anual, em dólares;

**anosemp** – tempo (em anos) na empresa;

**expprev** – experiência anterior (em anos);

**educ** – anos de estudo após o segundo grau;

**sexo** – (feminino = 0, masculino = 1);

**dept** – departamento no qual o funcionário atua

(Compras = 1, Engenharia = 2, Propaganda = 3, Vendas = 4);

**super** – número de empregados sob responsabilidade do empregado.



## Resolução do Exercício

À primeira vista, como existem quatro departamentos na empresa *TEMCO*, Rose Jolie poderia optar por usar a **variável *dept***, com os valores 1, 2, 3 e 4.

Dessa maneira,

$$\text{salário} = \beta_1 + \beta_2 \text{educ} + \beta_3 \text{dept} + \varepsilon$$

No entanto, ao fazer isto, Rose Jolie estaria introduzindo uma ideia de espaçamento, que ficará mais clara nos resultados descritos nos *slides* a seguir.

## Resolução do Exercício

Escrevendo a equação de regressão de interesse, para cada um dos departamentos, temos que:

$$E(\text{salário} | \text{educ}, \text{dept} = 1) = (\beta_1 + \beta_3) + \beta_2 \text{educ}$$

$$E(\text{salário} | \text{educ}, \text{dept} = 2) = (\beta_1 + 2\beta_3) + \beta_2 \text{educ}$$

$$E(\text{salário} | \text{educ}, \text{dept} = 3) = (\beta_1 + 3\beta_3) + \beta_2 \text{educ}$$

$$E(\text{salário} | \text{educ}, \text{dept} = 4) = (\beta_1 + 4\beta_3) + \beta_2 \text{educ}$$

## Resolução do Exercício

Dessa forma, admitiríamos, por exemplo, que

$$\begin{aligned} E(\text{salário} \mid \text{educ}, \text{dept} = 2) - E(\text{salário} \mid \text{educ}, \text{dept} = 1) &= \\ &= E(\text{salário} \mid \text{educ}, \text{dept} = 4) - E(\text{salário} \mid \text{educ}, \text{dept} = 3) = \\ &= \beta_3 \end{aligned}$$

ou seja, que a diferença entre os salários esperados dos funcionários dos departamentos de Engenharia e Compras é a mesma que a dos funcionários dos departamentos de Propaganda e Engenharia, mantendo constante o tempo de escolaridade.

## Resolução do Exercício

Assim, se Rose Jolie utilizasse *dept* da forma como foi construída, então ela estaria impondo uma restrição ao modelo, que não sabemos se é real.

Ainda, se a ordem das categorias da variável departamento fosse alterada, estaríamos propondo um novo conjunto de restrições ao modelo, o que muito provavelmente nos levaria a resultados completamente diferentes do caso anterior.

## Resolução do Exercício

Portanto, o ideal seria utilizar um grupo de variáveis que representasse os estados de interesse, que no nosso caso não apresentam nenhuma ordenação natural, de tal sorte a nunca alterar o resultado final, qualquer que seja o critério de criação adotado para a construção destas variáveis.

## Resolução do Exercício

A solução é, portanto, trabalharmos com algumas **variáveis dummy**.

No geral, se temos  $p$  estados, devemos trabalhar com  $p - 1$  **variáveis dummy**.



## Resolução do Exercício

Para o nosso exemplo, poderíamos definir as variáveis *dummy*  $D_C$ ,  $D_E$  e  $D_P$  da seguinte maneira, para representar os estados da variável departamento:

<i>dept</i>	$D_C$	$D_E$	$D_P$
Compras	1	0	0
Engenharia	0	1	0
Propaganda	0	0	1
Vendas	0	0	0

# Resolução do Exercício

Assim, partindo do modelo de regressão linear

$$y_i = \beta_1 + \beta_2 \text{educ}_i + \delta_1 D_{Ci} + \delta_2 D_{Ei} + \delta_3 D_{Pi} + \varepsilon_i$$

temos que:

Compras:  $y_i = (\beta_1 + \delta_1) + \beta_2 \text{educ}_i + \varepsilon_i$

Engenharia:  $y_i = (\beta_1 + \delta_2) + \beta_2 \text{educ}_i + \varepsilon_i$

Propaganda:  $y_i = (\beta_1 + \delta_3) + \beta_2 \text{educ}_i + \varepsilon_i$

Vendas:  $y_i = \beta_1 + \beta_2 \text{educ}_i + \varepsilon_i$

## Resolução do Exercício

Do *slide* 14, o parâmetro  $\delta_1$ , por exemplo, pode ser interpretado como a diferença esperada entre os salários dos profissionais das áreas de Compras e Vendas, que apresentam o mesmo tempo de escolaridade.

Ainda, vale lembrar que, estamos admitindo que o acréscimo médio no salário correspondente ao acréscimo em um ano de escolaridade é o mesmo para os quatro departamentos.



# Exercícios Suplementares

# 4

Admita que a variável aleatória  $X$ , que representa o número de linhas de código sem erros de sintaxe até à deteção da primeira linha de código com erros de tal tipo, possui função de probabilidade

$$P(X = x) = \begin{cases} (1 - p)^x p, & x = 0, 1, 2, \dots \\ 0, & \text{caso contrário,} \end{cases}$$

onde  $p$  é um parâmetro desconhecido.

Deduza o estimador de máxima verosimilhança de  $p$ , baseado numa amostra aleatória de dimensão  $n$  proveniente de  $X$ .



# Resolução do Exercício

- **V.a. de interesse; f.p.**

$X$

$$P(X = x) = \begin{cases} (1-p)^x p, & x = 0, 1, 2, \dots \\ 0, & \text{caso contrário,} \end{cases}$$

- **Parâmetro desconhecido**

$p \quad (p \in [0, 1])$

- **Amostra**

$\underline{x} = (x_1, \dots, x_n)$ , amostra de dimensão  $n$  proveniente de  $X$ .

- **Dedução do estimador de MV de  $p$**

**Passo 1 — Função de verosimilhança**

$$\begin{aligned} L(p | \underline{x}) &= P(\underline{X} = \underline{x}) \stackrel{X_i \text{ indep}}{=} \prod_{i=1}^n P(X_i = x_i) \\ &\stackrel{X_i \sim X}{=} \prod_{i=1}^n P(X = x_i) \\ &= \prod_{i=1}^n [(1-p)^{x_i} p] \\ &= p^n (1-p)^{\sum_{i=1}^n x_i}, \quad p \in [0, 1] \end{aligned}$$

**Passo 2 — Função de log-verosimilhança**

$$\ln L(p | \underline{x}) = n \ln(p) + \ln(1-p) \times \sum_{i=1}^n x_i, \quad p \in [0, 1]$$

# Resolução do Exercício

A estimativa de MV de  $p$  é representada por  $\hat{p}$  e

$$\hat{p} : \begin{cases} \frac{d \ln L(p|x)}{dp} \Big|_{p=\hat{p}} = 0 & \text{(ponto de estacionaridade)} \\ \frac{d^2 \ln L(p|x)}{dp^2} \Big|_{p=\hat{p}} < 0 & \text{(ponto de máximo)} \end{cases}$$

$$\begin{cases} \frac{n}{\hat{p}} - \frac{\sum_{i=1}^n x_i}{1-\hat{p}} = 0 \\ -\frac{n}{\hat{p}^2} - \frac{\sum_{i=1}^n x_i}{(1-\hat{p})^2} < 0 \quad \text{(prop. verdadeira)} \end{cases} \quad \hat{p} \neq 0,1 \quad \Leftrightarrow \quad \begin{cases} n - \hat{p}(n + \sum_{i=1}^n x_i) = 0 \Leftrightarrow \hat{p} = \frac{n}{n + \sum_{i=1}^n x_i} \\ - \end{cases}$$

**Passo 4 — Estimador de MV de  $p$**

$$EMV(p) = \frac{n}{n + \sum_{i=1}^n X_i} = (1 + \bar{X})^{-1}$$

Admita que o peso máximo suportado por uma marquesa portátil ergonómica é uma variável aleatória  $X$  com distribuição normal. Foram selecionados aleatoriamente 28 dessas marquesas, tendo-se observado uma variância amostral corrigida de  $s^2 = 3.8$ .

Qual é o intervalo de confiança a 90% para a variância de  $X$ ?

- A: [2.482, 6.060]    B: [1.599, 2.521]    **C: [2.558, 6.353]**    D: [2.376, 7.042]





# Resolução do Exercício

- **V.a. de interesse**

$X$  = peso máximo suportado por uma marquesa portátil ergonómica

- **Situação**

$X \sim \text{normal}(\mu, \sigma^2)$ ,  $\mu = E(X)$  desconhecido,  $\sigma^2 = V(X)$  DESCONHECIDO

- **Obtenção do IC para  $\sigma^2$**

**Passo 1 — Variável aleatória fulcral para  $\sigma^2$**

$$Z = \frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2$$

**Passo 2 — Quantis de probabilidade**

Dado que  $n = 28$  e  $(1 - \alpha) \times 100\% = 90\%$ , usaremos os quantis

$$(a_\alpha, b_\alpha) : \begin{cases} P(a_\alpha \leq Z \leq b_\alpha) = 1 - \alpha \\ P(Z < a_\alpha) = P(Z > b_\alpha) = \alpha/2 \end{cases} \Leftrightarrow \begin{cases} a_\alpha = F_{\chi_{(n-1)}^2}^{-1}(\alpha/2) = F_{\chi_{(27)}^2}^{-1}(0.05) \stackrel{\text{tabela/calc.}}{=} 16.15 \\ b_\alpha = F_{\chi_{(n-1)}^2}^{-1}(1 - \alpha/2) = F_{\chi_{(27)}^2}^{-1}(0.95) \stackrel{\text{tabela/calc.}}{=} 40.11. \end{cases}$$

# Resolução do Exercício

**Passo 3 — Inversão da desigualdade**  $a_\alpha \leq Z \leq b_\alpha$

$$P(a_\alpha \leq Z \leq b_\alpha) = 1 - \alpha$$

$$P\left[a_\alpha \leq \frac{(n-1)S^2}{\sigma^2} \leq b_\alpha\right] = 1 - \alpha$$

$$P\left[\frac{(n-1)S^2}{b_\alpha} \leq \sigma^2 \leq \frac{(n-1)S^2}{a_\alpha}\right] = 1 - \alpha$$

**Passo 4 — Concretização**

Atendendo à expressão geral do IC para  $\sigma^2$ ,

$$IC_{(1-\alpha) \times 100\%}(\sigma^2) = \left[ \frac{(n-1)s^2}{F_{\chi_{(n-1)}^2}^{-1}(1-\alpha/2)}, \frac{(n-1)s^2}{F_{\chi_{(n-1)}^2}^{-1}(\alpha/2)} \right],$$

ao par de quantis acima e ao facto de  $s^2 = 3.8$ , temos:

$$\begin{aligned} IC_{90\%}(\sigma) &= \left[ \frac{(28-1) \times 3.8}{40.11}, \frac{(28-1) \times 3.8}{16.15} \right] \\ &\simeq [2.558, 6.353]. \end{aligned}$$

Suponha que o comprimento (em mm) de uma peça é uma variável aleatória com distribuição normal com valor esperado  $\mu$  desconhecido e variância  $\sigma^2$  desconhecida.

Teste a hipótese  $H_0 : \mu = 100$  contra  $H_1 : \mu < 100$ , num dia em que foram recolhidas casualmente 4 peças e a média e a variância corrigida amostrais foram de  $\bar{x} = 101.0$  e  $s^2 = 2.56$ . Decida com base no valor-p.



# Resolução do Exercício

- **V.a. de interesse**

$X$  = comprimento de uma peça metálica

- **Situação**

$X \sim \text{normal}(\mu, \sigma^2)$

$\mu$  DESCONHECIDO

$\sigma$  desconhecido

- **Hipóteses**

$H_0 : \mu = \mu_0 = 100$  vs.  $H_1 : \mu < \mu_0$

- **Estatística de teste**

$$T = \frac{\bar{X} - \mu_0}{\frac{s}{\sqrt{n}}} \sim_{H_0} t_{(n-1)}$$

- **Região de rejeição de  $H_0$  (para valores da estatística de teste)**

O teste é unilateral inferior ( $H_1 : \mu > \mu_0$ ), logo a região de rejeição de  $H_0$  é tipo  $(-\infty, c)$ .

**Decisão (com base no valor-p)**

Atendendo a que o valor observado da estatística de teste e o valor-p aproximado são iguais a

$$\begin{aligned} t &= \frac{\bar{x} - \mu_0}{\frac{s}{\sqrt{n}}} \\ &= \frac{101.0 - 100}{\frac{\sqrt{2.56}}{\sqrt{4}}} \\ &\approx 1.25 \end{aligned}$$

# Resolução do Exercício

$$\begin{aligned} \text{valor} - p &= P(T < t \mid H_0) \\ &= F_{t_{(n-1)}}(t) \\ &= F_{t_{(3)}}(1.25) \\ &\stackrel{\text{tabelas/calc.}}{=} 0.85 \end{aligned}$$

é suposto:

- não rejeitar  $H_0$  a qualquer n.s.  $\alpha_0 \leq \text{valor} - p = 85\%$ , nomeadamente ao níveis usuais de significância (1%, 5%, 10%);
- rejeitar  $H_0$  a qualquer n.s.  $\alpha_0 > \text{valor} - p = 85\%$ .

O engenheiro que gere uma linha de apoio *online* pretende averiguar se o tempo de assistência (em minutos) possui função de distribuição dada por  $F_0(x) = 1 - e^{-(x/2)^2}$ , para  $x > 0$  (hipótese  $H_0$ ).

Recorra ao teste de ajustamento do qui-quadrado e à tabela de frequências seguinte para testar  $H_0$  ao nível de significância de 1%.

Tempo de assistência	]0, 2/3]	]2/3, 2]	]2, 3]	]3, +∞[
Frequência absoluta observada	13	32	13	6
Frequência absoluta esperada sob $H_0$	6.73	33.73	16.80	6.74



# Resolução do Exercício

- **V.a. de interesse**

$X$  = tempo de assistência (*em minutos*)

- **Hipóteses**

$$H_0 : F_X(x) = P(X \leq x) = F_0(x) = 1 - e^{-(x/2)^2}, \quad x > 0$$

$$H_1 : F_X(x) \neq F_0(x), \quad \text{para algum } x > 0$$

- **Nível de significância**

$$\alpha_0 = 1\%$$

- **Estatística de teste**

$$T = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \underset{H_0}{\sim} \chi^2_{(k-1)},$$

onde:  $k$  = no. de classes = 4;  $O_i$  = frequência absoluta observável da classe  $i$ ;  $E_i$  = frequência absoluta esperada, sob  $H_0$ , da classe  $i$ .

# Resolução do Exercício

- **[Frequências absolutas esperadas sob  $H_0$  —** De acordo com a tabela facultada, as frequências absolutas esperadas sob  $H_0$  aproximadas às centésimas são:  $E_1 \approx 6.73$ ;  $E_2 \approx 33.73$ ;  $E_3 \approx 16.80$ ;  $E_4 \approx 6.74$ . Não é necessário fazer qualquer agrupamento de classes uma vez que se verifica  $E_i \geq 5$ , em pelo menos 80% das classes, e que  $E_i \geq 1$ , para todo o  $i$ . Caso fosse preciso efectuar agrupamento de classes, os valores de  $k$  e  $c = F_{\chi^2_{(k-1)}^{-1}}(1 - \alpha_0)$  teriam que ser recalculados...]

- **Região de rejeição de  $H_0$**  (para valores de  $T$ )

Lidamos com um teste de ajustamento, donde a região de rejeição de  $H_0$  é o intervalo à direita  $W = (c, +\infty)$ , onde

$$c = F_{\chi^2_{(k-\beta-1)}^{-1}}(1 - \alpha_0) = F_{\chi^2_{(4-1)}^{-1}}(1 - 0.01) \stackrel{\text{tabela/ calc.}}{=} 11.34.$$

- **Decisão**

exp	2,718282
p1	0,105161
n*p1	6,730284
n	64

	Classe $i$	Freq. abs. obs. $o_i$	Freq. abs. esp. sob $H_0$ $E_i$	Parcelas valor obs. estat. teste $\frac{(o_i - E_i)^2}{E_i}$
1	[0.2/3]	13	6.73	$\frac{(13-6.73)^2}{6.73} \approx 5.841$
2	]2/3,2]	32	33.73	0.089
3	]2,3]	13	16.80	0.860
4	]3,+∞[	6	6.74	0.081
		$\sum_{i=1}^k o_i = n = 64$	$\sum_{i=1}^k E_i = n = 64$	$t = \sum_{i=1}^k \frac{(o_i - E_i)^2}{E_i} \approx 6.871$

Uma vez que  $t \approx 6.871 \notin W = (11.34, +\infty)$ , não devemos rejeitar  $H_0$  ao n.s. de  $\alpha_0 = 1\%$  nem a qualquer outro n.s. inferior a  $\alpha_0$ .



# Obrigada!

Questões?

