

Nome _____ N° _____

Espaço reservado a classificações

A utilização do telemóvel, em qualquer circunstância, é motivo suficiente para a anulação da prova.

Perguntas de escolha múltipla: apenas uma opção é correta
cada resposta certa vale **1** valor
cada resposta errada vale **-0.25** valores

Pergunta Verdadeiro/Falso: cada resposta certa vale **0.25** valores
cada resposta errada vale **-0.25** valores

Se necessitar de espaço utilize a última página do enunciado, indicando com clareza a respetiva questão.
É expressamente proibido destacar as folhas do enunciado.

TESTE I

1. Para cada afirmação assinale se esta é verdadeira (V) ou falsa (F). (1.0)

	V	F
Num teste estatístico de dimensão $\alpha = 0.05$, rejeita-se H_0 sempre que $t < 0.05$, em que t é o valor observado da estatística de teste.		×
Seja $T = \frac{X_1 + X_2 + \sum_{i=1}^n X_i}{n+2}$ um estimador para o valor esperado de uma variável aleatória X , $\mu = E(X)$, com base numa amostra casual de dimensão n . Então T é estimador centrado de μ .	×	
Num teste estatístico de dimensão $\alpha = 0.1$ não se rejeita H_0 se o valor- p for 0.09.		×
Uma estatística é uma variável aleatória.	×	

2. Num restaurante foram selecionadas ao acaso 61 faturas com indicação de NIF, tendo-se verificado que a soma dos montantes foi de 1279 euros e a sua variância corrigida $s^2 = 62$. Assume-se que o montante, em euros, de faturas com NIF tem distribuição normal.

(a) Pretende-se testar, ao nível de significância de 5%, se o montante médio de faturas com NIF é 21 euros. (1.0)
A região crítica do teste estatístico correspondente será:

- $W = \{(x_1, \dots, x_n) : \bar{x} < 21 - 2\sqrt{1.0164}\}$
- $W = \{(x_1, \dots, x_n) : \bar{x} > 21 + 2\sqrt{1.0164}\}$
- $W = \{(x_1, \dots, x_n) : \bar{x} < 21 - 1.645\sqrt{1.0164} \text{ ou } \bar{x} > 21 + 1.645\sqrt{1.0164}\}$
- $W = \{(x_1, \dots, x_n) : \bar{x} < 21 - 2\sqrt{1.0164} \text{ ou } \bar{x} > 21 + 2\sqrt{1.0164}\}$

- (b) Com base na alínea anterior, o que pode concluir sobre a afirmação “o montante médio das faturas com NIF é 21”? Justifique. (1.0)

X: montante, em euros, de faturas com NIF

$$X \sim Normal(\mu_X, \sigma^2)$$

Pela alínea anterior a região de rejeição para a média da amostra do teste estatístico

$$H_0 : \mu_X = 21 \quad \text{contra} \quad H_1 : \mu_X \neq 21$$

para um nível de significância de 5% é $W =] - \infty, 18.98367[\cup] 23.01633, +\infty[$.

Tem-se $\bar{x} = \frac{1279}{61} = 20.96721 \notin W$, logo não se rejeita a hipótese de que o montante médio das faturas com NIF, μ , é 21, ao nível de significância de 5%.

- (c) Na mesma loja foram selecionadas ao acaso outras 61 faturas, mas sem indicação de NIF, tendo-se verificado que a soma dos montantes foi de 1324 euros. Assume-se que o montante de faturas sem NIF também tem distribuição normal e que a variância das faturas com ou sem NIF é 50. Usando um teste adequado, comente a veracidade da afirmação “o montante médio das faturas com indicação de NIF é inferior ao das faturas sem NIF”. (2.0)

X: montante, em euros, de faturas com NIF

Y : montante, em euros, de faturas sem NIF

$$X \sim Normal(\mu_X, \sigma^2 = 50) \quad \text{e} \quad Y \sim Normal(\mu_Y, \sigma^2 = 50)$$

Pretende-se testar:

$$H_0 : \mu_X - \mu_Y \geq 0 \quad \text{contra} \quad H_1 : \mu_X - \mu_Y < 0$$

$$\text{Estatística Teste: } T_0 = \frac{\bar{X} - \bar{Y}}{\sqrt{2 \frac{50}{61}}} \sim Normal(0, 1)$$

Valor observado da estatística teste: $\bar{x} = 20.96721$ e $\bar{y} = \frac{1324}{61} = 21.70492$, logo $t_{obs} = \frac{20.96721 - 21.70492}{1.280369} = -0.5761698$

Valor-p: $P(T_0 < t_{obs}) = 1 - \Phi(-0.58) = 1 - 0.7190 = 0.281 \Rightarrow$ valor-p = 28%

Logo, não se rejeita a hipótese H_0 . Há evidência a favor de H_0 , de que o montante médio das faturas com indicação de NIF é superior ou igual ao das faturas sem indicação de NIF.

Alternativamente, a região de rejeição do teste ao nível de significância de 5% é $W =] - \infty, -1.645[$ e $t_{obs} \notin W$, logo não se rejeita H_0 ao nível de significância de 5%.

3. Para inferir sobre a probabilidade θ de cancelamento de reservas num hotel por parte dos seus clientes, o gestor do hotel decidiu analisar os processos relativos a 230 reservas passadas, escolhidas ao acaso da sua vasta carteira, registando-se para cada reserva se a mesma tinha sido cancelada ou não.

(a) Mostre que o estimador do método dos momentos para θ é centrado.

(1.0)

$$X = \begin{cases} 1, & \text{reserva cancelada} \\ 0, & \text{caso contrário} \end{cases} \quad \text{logo} \quad X \sim \text{Bernoulli}(\theta) \quad \text{e} \quad E(X) = \theta.$$

Pelo método dos momentos $E(X) = \bar{X}$, logo o estimador de θ pelo método dos momentos é $\hat{\theta} = \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$.

Tem-se

$$E(\bar{X}) = E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) \stackrel{\text{ident. dist.}}{=} \frac{1}{n} \sum_{i=1}^n E(X) = \frac{nE(X)}{n} = E(X) = \theta$$

logo, o estimador do método dos momentos para θ , \bar{X} , é centrado.

(b) De acordo com a desigualdade de Fréchet-Cramér-Rao, o estimador T da alínea anterior é o mais eficiente se:

(1.0)

$Var(T) = 0$

$Var(T) = \frac{\theta(1-\theta)}{230}$

$Var(T) < \frac{\theta(1-\theta)}{230}$

$Var(T) > \frac{\theta(1-\theta)}{230}$

(c) Sabendo que, das 230 reservas analisadas, 29 foram canceladas, construa um intervalo com nível de confiança aproximadamente 95% para θ .

(1.5)

Variável Fulcral: $\frac{\bar{X} - \theta}{\sqrt{\frac{\bar{X}(1-\bar{X})}{n}}} \sim \text{Normal}(0, 1)$

Logo, sendo $\bar{x} = \frac{29}{230} = 0.126087$, o intervalo de confiança aproximadamente a 95% é dado por

$$\bar{x} \pm z_{\alpha/2} \sqrt{\frac{\bar{x}(1-\bar{x})}{n}} = 0.126087 \pm 1.96 \sqrt{\frac{0.126087(1-0.126087)}{230}} = (0.0831866, 0.1689874)$$

- (d) Qual deveria ser a dimensão da amostra casual por forma a garantir que o “erro” cometido no intervalo da alínea anterior é inferior a 4%? (1.5)

Pretende-se determinar n tal que $P(|\bar{X} - \theta| < 0.04) \geq 0.95$:

$$0.95 \leq P(|\bar{X} - \theta| < 0.04) = P(-0.04 < \bar{X} - \theta < 0.04) = P\left(-\frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}} < \frac{\bar{X} - \theta}{\sqrt{\frac{\theta(1-\theta)}{n}}} < \frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}}\right)$$

$$\underbrace{\frac{\bar{X} - \theta}{\sqrt{\frac{\theta(1-\theta)}{n}}} \sim N(0,1)}_{\Leftrightarrow} \quad \Phi\left(\frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}}\right) - \Phi\left(-\frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}}\right) \geq 0.95 \Leftrightarrow \Phi\left(\frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}}\right) - \left(1 - \Phi\left(\frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}}\right)\right) \geq 0.95$$

$$\Leftrightarrow \Phi\left(\frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}}\right) \geq \frac{1.95}{2} = 0.975 \Leftrightarrow \frac{0.04}{\sqrt{\frac{\theta(1-\theta)}{n}}} \geq 1.96 \Leftrightarrow \left(\frac{0.04}{1.96}\right)^2 \geq \frac{\theta(1-\theta)}{n}$$

$$\Leftrightarrow n \geq \left(\frac{1.96}{0.04}\right)^2 \theta(1-\theta)$$

Considerando o valor máximo que a variância de X ($V(X) = \theta(1-\theta)$) pode tomar, obtém-se

$$n \geq \left(\frac{1.96}{0.04}\right)^2 \frac{1}{4} = 600.25$$

Logo, $n = 601$.

TESTE II

1. Para cada afirmação assinale se esta é verdadeira (V) ou falsa (F). (1.0)

	V	F
Se num teste de ajustamento que envolve 2 parâmetros desconhecidos e onde não foi necessário agrupar classes se tem, sob H_0 , $Q \stackrel{a}{\sim} \chi_{(9)}^2$, onde Q é a estatística teste, então o número de classes é 11.		×
No MRL a variável residual u é uma variável aleatória não observável porque depende dos coeficientes do modelo, que são desconhecidos.	×	
O teste de permanência de estrutura é um teste que permite detetar a presença de autocorrelação nos erros do modelo.		×
Uma das hipóteses do MRL é a heterocedasticidade condicionada.		×

2. Para testar se o desempenho profissional de determinada categoria de trabalhadores depende do género (2.0)
inquiriu-se uma amostra casual simples de 1000 trabalhadores tendo-se obtido:

	género	
	masculino	feminino
baixo	170	120
médio	260	180
alto	170	100

Teste, ao nível de significância de 5%, a hipótese de independência entre o desempenho profissional e o género.

Pretende-se testar

$$H_0 : p_{ij} = p_{i.} \times p_{.j} \forall i, j \quad \text{contra} \quad H_1 : \exists(i, j) : p_{ij} \neq p_{i.} \times p_{.j}$$

Estatística Teste (sob H_0): $Q = \sum_i \sum_j \frac{N_{ij} - n\hat{p}_{ij}}{n\hat{p}_{ij}} \stackrel{a}{\sim} \chi_{(2)}^2$ (número de graus de liberdade = $(3 - 1) \times (2 - 1) = 2$)

Logo, a região crítica, ao nível de significância de 5% é $W = \{q : q > 5.991\}$.

A tabela da frequência esperada em cada classe, sob a validade de H_0 é dada por:

	género		
	masculino	feminino	
baixo	174	116	$\hat{p}_{i.}$ 0.29
médio	264	176	0.44
alto	162	108	0.27
$\hat{p}_{.j}$	0.6	0.4	1

O valor observado da estatística teste é

$$q_{obs} = \frac{(170 - 174)^2}{174} + \frac{(120 - 116)^2}{116} + \frac{(260 - 264)^2}{264} + \frac{(180 - 176)^2}{176} + \frac{(170 - 162)^2}{162} + \frac{(100 - 108)^2}{108} = 1.369 < 5.991$$

Logo $q_{obs} = 1.369 \notin W$, pelo que não se rejeita a hipótese ao nível de significância de 5%, ou seja há evidência de independência entre o desempenho profissional e o género.

3. Para analisar o comportamento das vendas (*vendas*) das lojas de material de telecomunicação com base nas despesas em publicidade (*desp*) e na superfície da loja (*area*) em m^2 , foi especificado o seguinte modelo

$$l\text{vendas} = \beta_1 + \beta_2 l\text{desp} + \beta_3 \text{area} + \beta_4 \text{cc} + u$$

Os resultados obtidos encontram-se abaixo, onde o prefixo *l* representa o logaritmo natural e *cc* é uma variável artificial que assume o valor 1 se a loja se situa num centro comercial e o valor 0 caso contrário.

Regression Statistics	
Multiple R	0.6952
R Square	0.4833
Adjusted R Square	0.4744
Standard Error	0.2660
Observations	179

ANOVA

	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	3	11.5849	3.8616	54.5590	0.0000
Residual	175	12.3863	0.0708		
Total	178	23.9712			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>
Intercept	9.9147	0.1395	71.0640	0.0000
<i>l</i> desp	0.9620	0.2515	3.8256	0.0002
area	0.0062	0.0010	6.4936	0.0000
cc	0.1568	0.0649	2.4174	0.0167

- (a) Interprete as estimativas de β_3 e de β_4 e analise a significância estatística da variável artificial, considerando um nível de significância de 5%. (1.5)

$b_3 = 0.0062$: Estima-se que, se a área aumenta $1 m^2$, as vendas aumentam em média aproximadamente 0.62%, mantendo constantes as restantes variáveis.

$b_4 = 0.1568$: Estima-se que as vendas de uma loja situada num centro comercial são, em média, cerca de 15.68% superiores relativamente às vendas de uma loja situada fora de um centro comercial, para os mesmos valores das restantes variáveis.

Para analisar a significância estatística da variável artificial testa-se:

$$H_0 : \beta_4 = 0 \quad \text{contra} \quad H_1 : \beta_4 \neq 0$$

Sob H_0 , a estatística teste é $\frac{b_4}{s.e.(b_4)} \sim t_{(175)}$ e a região de rejeição, ao nível de significância de 5%, é (aproximadamente) $W = \{t : |t| > 1.96\}$.

Como $t_{obs} = 2.4174 \in W$, rejeita-se H_0 ao nível de significância de 5%. Logo, a variável *cc* é relevante na explicação de *l*vendas.

- (b) Construa um intervalo de confiança a 95% para a elasticidade das vendas relativamente às despesas em publicidade e teste se é de admitir que um aumento de 2% nas despesas em publicidade origine um aumento, em média, de 3% nas vendas, mantendo constantes as restantes variáveis. (2.0)

Variável Fulcral: $T = \frac{b_2 - \beta_2}{s.e.(b_2)} \sim t_{(175)}$ Logo, o intervalo de confiança 95% para β_2 é:

$$b_2 \pm 1.96s.e.(b_2) = 0.962 \pm 1.96 \times 0.2515 = (0.4691, 1.4549)$$

Pretende-se testar

$$H_0 : \beta_2 = 1.5 \quad \text{contra} \quad H_1 : \beta_2 \neq 1.5$$

Estatística teste (sob H_0): $T = \frac{b_2 - 1.5}{s.e.(b_2)} \sim t_{(175)}$

Com base no intervalo de confiança a 95% para β_2 , rejeita-se H_0 ao nível de significância de 5% pois $1.5 \notin IC_{(95\%)}$. Portanto, não há evidência estatística que suporte a afirmação.

- (c) Interprete o coeficiente de determinação R^2 e teste a significância global do modelo. (1.5)

$R^2 = 0.4833$: 48.33% da variação total de vendas é explicada pelo modelo.

Pretende-se testar

$$H_0 : \beta_2 = \beta_3 = \beta_4 = 0 \quad \text{contra} \quad H_1 : \exists \beta_j \neq 0, j = 2, 3, 4$$

Estatística teste: $\frac{(VR_0 - VR_1)/3}{VR_1/(179 - 4)} = \frac{R^2/(4 - 1)}{(1 - R^2)/(179 - 4)} \sim F_{(3,175)}$

Como $F_{obs} = 54.559$ com valor-p=0, rejeita-se H_0 . β_2 , β_3 e β_4 são, em conjunto, estatisticamente significativos.

- (d) Para testar a nulidade conjunta de β_3 e β_4 foi estimado o modelo $lvendas = \beta_1 + \beta_2 ldesp + u$, tendo-se obtido $VR = 16.959$, onde VR é a variação residual. Então, sendo F a estatística de teste adequada, tem-se (1.0)

- Sob $H_0, F \sim F_{(2,177)}$ e $F_{obs} = 32.67$
- Sob $H_0, F \sim F_{(2,176)}$ e $F_{obs} = 32.48$
- Sob $H_0, F \sim F_{(2,175)}$ e $F_{obs} = 32.30$
- Sob $H_0, F \sim F_{(2,174)}$ e $F_{obs} = 32.11$

- (e) Com base na mesma amostra e definindo $ncc = 1 - cc$, foi estimado o modelo (1.0)

$$lvendas = \alpha_1 + \alpha_2 ldesp + \alpha_3 area + \alpha_4 ncc + u$$

Apresente, justificando, a equação ajustada desse modelo.

Substituindo no modelo inicial $cc = 1 - ncc$, vem

$$lvendas = \beta_1 + \beta_2 ldesp + \beta_3 area + \beta_4 (1 - ncc) + u$$

$$\Leftrightarrow lvendas = \underbrace{(\beta_1 + \beta_4)}_{\alpha_1} + \underbrace{\beta_2}_{\alpha_2} ldesp + \underbrace{\beta_3}_{\alpha_3} area - \underbrace{\beta_4}_{\alpha_4} ncc + u$$

Logo

$$\widehat{lvendas} = 9.9147 + 0.1568 + 0.962 ldesp + 0.0062 area - 0.1568 ncc$$

$$= 10.0715 + 0.962 ldesp + 0.0062 area - 0.1568 ncc$$