

Nome: _____ Número: _____

Notas: Certifique-se de que o seu telemóvel está desligado. Se não estiver é motivo suficiente para anulação da prova. As perguntas de escolha múltipla valem 1 valor; respostas erradas são penalizadas em 0.25. Caso nada seja dito em contrário utilize um nível de significância de 5% nos testes de hipóteses que efetuar. Fundamente e formalize devidamente todas as respostas. Pode usar a última página para continuar qualquer questão.

Espaço reservado para classificações				
1)	2)	6)	7)	EM(3, 4, 5):
8a)	8c)	8e)	8g)	EM(8.b, d, f):

1. O *reality show* “A Horta” tem grande sucesso entre os telespectadores. Para estudar as audiências recolheu-se, de forma independente, informação junto de homens e mulheres. De 100 homens inquiridos, 70 responderam ver o programa, enquanto num total de 150 mulheres, 114 responderam igualmente ser fãs do programa. De acordo com um intervalo de confiança a 99% pode afirmar que, na população, a proporção de mulheres que vê o programa é superior à proporção de homens? [1.5]

θ_1 – proporção de mulheres na população que vê o programa

θ_2 – proporção de homens na população que vê o programa

Variável Fulcral:

$$\frac{\bar{X}_1 - \bar{X}_2 - (\theta_1 - \theta_2)}{\sqrt{\frac{\bar{X}_1(1 - \bar{X}_1)}{150} + \frac{\bar{X}_2(1 - \bar{X}_2)}{100}}} \stackrel{a}{\sim} N(0,1)$$

Intervalo de confiança a 99% para $\theta_1 - \theta_2$:

$$z_{0.005} = 2.57583$$

$$s^* = \sqrt{\frac{\bar{x}_1(1 - \bar{x}_1)}{150} + \frac{\bar{x}_2(1 - \bar{x}_2)}{100}} = 0.05758 \quad \text{com } \bar{x}_1 = 0.76 \text{ e } \bar{x}_2 = 0.7$$

$$\theta_1 - \theta_2 \in (0.06 \pm 2.57583 \times 0.05758) \Leftrightarrow \theta_1 - \theta_2 \in (-0.08832, 0.208316) \text{ com 99\% de confiança}$$

Conclusão: com 99% de confiança a diferença entre a proporção de mulheres e a proporção de homens na população pode situar-se entre -0.09 e 0.21 e como tal não se pode concluir que seja taxativamente positiva, i.e., não se pode concluir que a proporção de mulheres seja maior do que a proporção de homens.

2. O gerente de um *resort* afirma que o preço médio de uma estadia não é superior a 500 euros. Suponha que o preço de uma estadia é uma variável aleatória com desvio padrão igual a 40 euros. Para efetuar o teste proposto rejeita-se a afirmação do gerente quando a média da amostra for superior a 510 euros. Considerando uma amostra casual de 50 estadias, qual é aproximadamente o nível de significância associado a este teste? Não se esqueça de definir as hipóteses em teste. [2.0]

Afirmção do gerente: $\mu \leq 500$ (com μ o preço médio de uma estadia).

$$\sigma = 40$$

Região de rejeição:

$$W = \{\bar{x} : \bar{x} > 510\}$$

$n=50 \rightarrow$ podem usar-se os resultados para grandes amostras

Teste:

$$H_0 : \mu \leq 500 \quad H_1 : \mu > 500$$

Estatística de teste:

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{50}} \stackrel{a}{\sim} N(0,1) \text{ sob } H_0$$

Nível de significância = α = probabilidade do erro de 1ª espécie:

$$\alpha \approx P(\bar{X} > 510 | \mu = 500) \approx 1 - \Phi\left(\frac{510 - 500}{40/\sqrt{50}}\right) \approx 1 - \Phi(1.76777) \approx 0.03855$$

3. Assinale a alternativa correta:

- Todas as variáveis fulcrais são estimadores.
- Todos os estimadores são variáveis fulcrais.
- Todos os estimadores são estatísticas.
- Todas as anteriores.

4. Se um teste de hipótese simples contra uma alternativa simples tem potência 0.8, isso significa que:

- quando H_0 é falsa, a probabilidade de H_0 ser rejeitada é de 0.8.
- quando H_0 é verdadeira, a probabilidade de H_0 ser rejeitada é de 0.8.
- quando H_0 é verdadeira, a probabilidade de H_0 não ser rejeitada é de 0.8.
- quando H_0 é falsa, a probabilidade de H_0 não ser rejeitada é de 0.8.

5. Assinale a alternativa correta.

Os reagrupamentos de classes num teste de ajustamento...

- ... devem ser feitos com base nas frequências observadas.
- ... devem ser feitos com base nas frequências esperadas.
- ... devem ser feitos quando o número de classes é par.
- ... devem ser feitos quando o número de classes é ímpar.

6. Represente-se a duração de um anúncio publicitário, em segundos, por uma variável aleatória X . Para testar se X tem distribuição exponencial de média 10 segundos, recolheu-se uma amostra de 100 anúncios, registando-se a seguinte informação:

Duração (Segundos)	(0, 5]	(5, 10]	(10, 15]	(15, 20]	≥ 20
Frequência Observada	25	30	15	20	10
Frequência Esperada	A	B	14.475	8.779	13.534

Calcule as duas primeiras frequências esperadas em falta no quadro (**A** e **B**) e efetue o teste em questão, considerando um nível de 1%. Que pode concluir? [2.0]

$$p_{01} = P(X \leq 5 | X \sim \text{Exp}(0.1)) = 1 - e^{-0.5} = 0.393469$$

$$A = 100p_{01} = 39.3469$$

$$p_{02} = P(5 < X \leq 10 | X \sim \text{Exp}(0.1)) = e^{-0.5} - e^{-1} = 0.238651$$

$$B = 100p_{02} = 23.8651$$

Teste:

$$H_0 : X \sim \text{Exp}(0.1) \quad H_1 : H_0 \text{ falsa}$$

Estatística de teste:

$$Q = \sum_{j=1}^5 \frac{(N_j - fe_j)^2}{fe_j} \sim \chi^2(5-1) \text{ sob } H_0; \quad fe_j = 100p_{\circ j} - \text{frequência esperada da classe } j$$

$$Q_{obs} = 5.2313 + 1.5771 + 0.019 + 14.3423 + 0.9228 = 22.0925$$

$$W_{0.05} = \{Q : Q > 13.2767\}$$

$Q_{obs} \in W_{0.05}$, como tal rejeita-se H_0 . A evidência empírica rejeita a hipótese da duração de um anúncio publicitário ter distribuição exponencial de média 10 segundos.

7. Admita que numa determinada região o número de vezes que uma pessoa vai ao ginásio por semana é uma variável aleatória X com a seguinte função probabilidade:

$$f(x|\theta) = \frac{\theta^x}{(\theta + 1)^{x+1}} \quad (x = 0, 1, 2, \dots; \theta > 0)$$

Recolhida uma amostra casual de 10 pessoas desta região obteve-se $\sum_{i=1}^{10} x_i = 6$. Sabendo que o estimador da máxima verosimilhança para θ é \bar{X} calcule, justificando, a estimativa para a percentagem de pessoas desta região que não frequenta o ginásio. [1.5]

Pretende-se estimar $P(X = 0) = f(0|\theta)$. Pela propriedade da invariância dos estimadores da máxima verosimilhança então,

$$\hat{P}(X = 0) = \hat{f}(0|\theta) = f(0|\hat{\theta}) \text{ com } \hat{\theta} \text{ estimador da M.V. de } \theta.$$

Estimativa da M.V. para θ : $\hat{\theta} = \bar{x} = 0.6$

Estimativa da M.V da $P(X = 0) = f(0|\theta)$:

$$\hat{P}(X = 0) = f(0|\hat{\theta} = 0.6) = \frac{0.6^0}{(1 + 0.6)^{0+1}} = \frac{1}{1.6} = 0.625$$

Estima-se que 62.5% das pessoas desta região não frequenta o ginásio.

8. O estudo econométrico que se segue baseia-se na análise ao consumo mensal de internet em função de um conjunto de características pessoais. Para tal, foi definido o seguinte modelo de regressão linear:

$$int = \beta_0 + \beta_1 \log(rend) + \beta_2 ncontas + \beta_3 idade + \beta_4 idade^2 + u$$

Onde:

- *int* – consumo mensal de internet do indivíduo, em gigabytes;
- *rend* – rendimento mensal do indivíduo, em euros;
- *ncontas* – número de contas ativas do indivíduo em redes sociais;
- *idade* – idade do indivíduo, em anos.

A estimação do modelo inicial encontra-se na Equação 1, em Anexo. Igualmente no Anexo encontrará outras regressões estimadas que lhe serão úteis para as questões que se seguem.

a) Interprete a estimativa associada ao regressor “log(rend)” e teste a significância estatística deste. [1.5]

$\hat{\beta}_1 = 14.881 \rightarrow$ se o rendimento mensal aumentar 1%, estima-se que o consumo de internet aumenta, em média, cerca de 0.15 gigabytes, mantendo as restantes variáveis constantes.

$$H_0: \beta_1 = 0 \quad vs \quad H_1: \beta_1 \neq 0$$

Estatística de teste: $t_1 = \hat{\beta}_1 / se(\hat{\beta}_1) \sim t(n - k - 1) \rightarrow t(495) \approx N(0, 1)$

Pela Equação 1, em anexo, obtém-se: $t_{1,obs} = 10.085$ e $p_{obs} = 0$. Então, porque o valor-p é igual a zero, rejeita-se H_0 aos níveis de significância habituais, concluindo-se que o regressor “log(rend)” é estatisticamente significativo.

b) O valor do coeficiente de determinação da Equação 1 significa que:

- 29.75% dos resíduos são iguais a zero.
- o estimador OLS apenas utilizou 29.75% da amostra.
- a probabilidade de o modelo estar errado é igual a 0.2975.
- os regressores explicam 29.75% da variação total amostral do consumo de internet.

c) Com base num teste de hipóteses adequado verifique se a idade da pessoa é um fator estatisticamente relevante no consumo de internet. [1.5]

$$H_0: \beta_3 = \beta_4 = 0 \quad vs \quad H_1: \beta_3 \neq 0 \vee \beta_4 \neq 0$$

$$F = \frac{R_{ur}^2 - R_r^2}{1 - R_{ur}^2} \times \frac{n - k - 1}{q} \sim F(q, n - k - 1) \rightarrow F(2, 495)$$

$$f_{obs} = \frac{0.297533 - 0.264774}{1 - 0.297533} \times \frac{495}{2} \approx 11.542$$

Região de rejeição: $W_{5\%} = \{f: f > 3\}$

Porque $f_{obs} \in W_{5\%}$, rejeita-se H_0 ao nível de 5%. Evidência estatística de que a idade é um fator relevante no consumo de internet.

Nota: Valor-p: $p_{obs} = P(F \geq f_{obs}|H_0) = P(F \geq 11.542) \approx 0.00001$

d) Qual é aproximadamente a idade da pessoa a partir da qual o efeito sobre o consumo de internet passa a ser negativo?

25 anos

30 anos

35 anos

40 anos

e) Construa um intervalo de confiança a 95% para $\theta = \frac{\beta_1}{100} + \beta_2$ e interprete o resultado. [2.0]

$$\theta = \frac{\beta_1}{100} + \beta_2 \Leftrightarrow \beta_2 = \theta - \frac{\beta_1}{100}$$

$$int = \beta_0 + \beta_1 \log(rend) + \beta_2 ncontas + \beta_3 idade + \beta_4 idade^2 + u \Leftrightarrow$$

$$int = \beta_0 + \beta_1 \log(rend) - \beta_1 \frac{ncontas}{100} + \theta ncontas + \beta_3 idade + \beta_4 idade^2 + u$$

$$int = \beta_0 + \beta_1 \left[\log(rend) - \frac{ncontas}{100} \right] + \theta ncontas + \beta_3 idade + \beta_4 idade^2 + u$$

$$\text{IC a 95\% de confiança para } \theta: \theta \in [\hat{\theta} \pm t_{\alpha/2} se(\hat{\theta})]$$

$$\theta \in [0.714397 \pm 1.96 \times 0.223958]$$

$$\theta \in [0.275439; 1.153355]$$

Interpretação: se o rendimento do indivíduo aumentar 1% e simultaneamente tiver mais uma conta ativa (mantendo a idade constante) estima-se que o consumo mensal de internet possa aumentar entre 0.28 e 1.15 gigabytes com 95% de confiança.

f) Escolha a alternativa correta.

De acordo com o seguinte output do *EViews*, pode concluir-se que:

Ramsey RESET Test
Equation: EQ01
Specification: INT C LOG(REND) NCONTAS IDADE IDADE^2

	Value	df	Probability
F-statistic	9.876384	(2, 493)	0.0001

- A probabilidade de o modelo inicial estar bem especificado é igual a 0.0001.
- Existe evidência estatística de que o modelo inicial sofre de má especificação.
- Existe evidência estatística de que os erros do modelo inicial são homocedásticos.
- Existe evidência estatística de que o modelo inicial está bem especificado.

g) Diga qual o objetivo da estimação da Equação 4 em Anexo e tire as principais conclusões a ela associadas no que respeita às propriedades do OLS. [2.0]

Teste de Heterocedasticidade White Simplificado.

Objectivo: testar a presença de Heterocedasticidade no Modelo 1

Regressão auxiliar de teste:

$$\hat{u}^2 = \alpha_0 + \alpha_1 \hat{y} + \alpha_2 \hat{y}^2 + erro$$

$$\begin{cases} H'_0: \alpha_1 = \alpha_2 = 0 \\ H'_1: \alpha_1 \neq 0 \vee \alpha_2 \neq 0 \end{cases}$$

Sob H_0 , $LM = nR_{\hat{u}^2}^2 \sim \chi^2_{(2)}$ $W_{5\%} = \{LM: LM_{obs} > \chi^2_{(2)}\}$

$\chi^2_{(2)} = 5.99$

$LM_{obs} = 500 \times 0,023825 = 11.9125$

Como $LM_{obs} \in W_{5\%}$ a hipótese nula é rejeitada a 5% de significância.

Assim sendo, existe evidência empírica de heterocedasticidade. Por conseguinte o estimador OLS não é BLUE, nem a inferência habitual é válida. Não obstante o dito estimador é centrado se se verificar a hipótese MLR4.

ANEXO

Equação 1

Dependent Variable: INT
Method: Least Squares
Included observations: 500

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-185.6037	62.78577	-2.956143	0.0033
LOG(REND)	14.88069	1.475544	10.08488	0.0000
NCONTAS	0.565590	0.225524	2.507892	0.0125
IDADE	6.319112	3.690368	1.712326	0.0875
IDADE^2	-0.078814	0.054553	-1.444716	0.1492
R-squared	0.297533	Mean dependent var		54.99000
Adjusted R-squared	0.291857	S.D. dependent var		12.54051
S.E. of regression	10.55300	Akaike info criterion		7.560646
Sum squared resid	55126.04	Schwarz criterion		7.602793
Log likelihood	-1885.162	Hannan-Quinn criter.		7.577185
F-statistic	52.41492	Durbin-Watson stat		1.828068
Prob(F-statistic)	0.000000			

Equação 2

Dependent Variable: INT
Method: Least Squares
Included observations: 500

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-81.41585	10.52907	-7.732481	0.0000
LOG(REND)	17.23404	1.414457	12.18421	0.0000
NCONTAS	0.685495	0.227860	3.008400	0.0028
R-squared	0.264774	Mean dependent var		54.99000
Adjusted R-squared	0.261815	S.D. dependent var		12.54051
S.E. of regression	10.77452	Akaike info criterion		7.598226
Sum squared resid	57696.82	Schwarz criterion		7.623514
Log likelihood	-1896.557	Hannan-Quinn criter.		7.608149
F-statistic	89.49135	Durbin-Watson stat		1.848178
Prob(F-statistic)	0.000000			

Equação 3

Dependent Variable: INT
Method: Least Squares
Included observations: 500

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-185.6037	62.78577	-2.956143	0.0033
LOG(REND)-NCONTAS/100	14.88069	1.475544	10.08488	0.0000
NCONTAS	0.714397	0.223958	3.189872	0.0015
IDADE	6.319112	3.690368	1.712326	0.0875
IDADE^2	-0.078814	0.054553	-1.444716	0.1492
R-squared	0.297533	Mean dependent var		54.99000
Adjusted R-squared	0.291857	S.D. dependent var		12.54051
S.E. of regression	10.55300	Akaike info criterion		7.560646
Sum squared resid	55126.04	Schwarz criterion		7.602793
Log likelihood	-1885.162	Hannan-Quinn criter.		7.577185
F-statistic	52.41492	Durbin-Watson stat		1.828068
Prob(F-statistic)	0.000000			

Equação 4

Dependent Variable: RES^2
Method: Least Squares
Included observations: 500

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	871.2516	300.0341	2.903842	0.0039
FITTED	-25.88942	11.51271	-2.248768	0.0250
FITTED^2	0.215808	0.109702	1.967221	0.0497
R-squared	0.023825	Mean dependent var		110.2521
Adjusted R-squared	0.019897	S.D. dependent var		180.3533
S.E. of regression	178.5500	Akaike info criterion		13.21360
Sum squared resid	15844413	Schwarz criterion		13.23888
Log likelihood	-3300.399	Hannan-Quinn criter.		13.22352
F-statistic	6.065098	Durbin-Watson stat		1.785897
Prob(F-statistic)	0.002498			

NOTA: As variáveis RES e FITTED são os resíduos e os valores ajustados da Equação 1, respetivamente.