

Parte teórica

Nome: _____ Nº _____

1. Perguntas de Verdadeiro/Falso (1.5 valores) - Para cada afirmação, assinale se esta é Verdadeira (V) ou Falsa (F). Uma resposta certa vale 0.3 e uma resposta errada penaliza em idêntico valor.

	V	F
Num teste de dimensão $\alpha = 0.01$ em que o valor- $p = 0.02$, rejeita-se H_0 .		X
Num teste do χ^2 à bondade do ajustamento a região de rejeição pode ser bilateral		X
Se $\hat{\theta}$ é um estimador não enviesado de θ , então pode-se concluir que $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$	X	
No MRL $y_t = \beta_1 + \beta_2 x_{t2} + \beta_3 x_{t3} + u_t$ pode-se garantir que a soma dos resíduos MQ é nula, isto é, que $\sum_{t=1}^n \hat{u}_t = 0$	X	
No MRL $y_t = \beta_1 + \beta_2 x_{t2} + \beta_3 x_{t3} + u_t$, $t = 1, 2, \dots, 50$, $R^2 = 0.9$, pode acontecer que não se rejeite individualmente $H_0 : \beta_2 = 0$	X	

2. Perguntas de escolha múltipla (2.25 valores) - Para cada pergunta escolha (assinalando com X) a alternativa correcta. Uma resposta certa vale 0.75 valores e uma resposta errada penaliza em 0.25 valores.

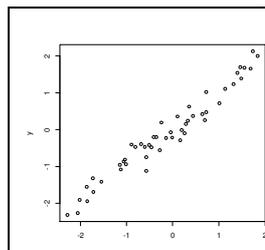
a. Suponha que a região crítica ($\alpha = 0.05$) de um determinado teste de hipóteses é dada por $W = \{(x_1, x_2, \dots, x_n) : q_{obs} > 21.026\}$, tendo a estatística de teste, quando H_0 é verdadeiro, uma distribuição do Qui-Quadrado com 12 graus de liberdade. Observada uma amostra casual verificou-se que $q_{obs} = 20.65$. Então

- H_0 deve ser rejeitada
- A região de não rejeição é dada por $\bar{W} = \{(x_1, x_2, \dots, x_n) : q_{obs} > 1 / 21.026\}$
- O valor-p é dado pela área por baixo de uma função densidade do $\chi^2_{(12)}$ e à direita de 20.65
- Nenhuma das alternativas anteriores é verdadeira.

b. O lema de Neyman-Pearson é um resultado particularmente interessante para a:

- construção de intervalos de confiança
- definição de testes de hipóteses
- estimação pela máxima verosimilhança
- estimação pelo método dos momentos

c. A figura representa o diagrama de dispersão dos valores y_t e x_t . Qual poderá ser o valor do coeficiente de determinação que se obtém ao estimar a regressão $y_t = \beta_1 + \beta_2 x_t + u_t$?



- 0.95
- 0.95
- 0.05
- 0.05

3. Perguntas de desenvolvimento (2.25 valores) – A alínea a) vale 1 valor e a alínea b) 1.25.

- a. Seja uma população X de média μ e variância σ^2 . Com o intuito de estimar μ recolheu-se uma amostra casual de dimensão $n = 4$, tendo-se definido o estimador $T = \frac{2X_1 + X_2 + X_3 - X_4}{4}$. Deduza o valor esperado e a variância do estimador explicitando os passos que for dando.

$$\begin{aligned} E(T) &= E\left(\frac{2X_1 + X_2 + X_3 - X_4}{4}\right) = \frac{1}{4}(2E(X_1) + E(X_2) + E(X_3) - E(X_4)) \\ &= \frac{1}{4}(2\mu + \mu + \mu - \mu) \quad \text{idêntica distribuição e } E(X) = \mu \\ &= \frac{3}{4}\mu \end{aligned}$$

$$\begin{aligned} \text{var}(T) &= \text{var}\left(\frac{2X_1 + X_2 + X_3 - X_4}{4}\right) = \frac{1}{16}(4\text{var}(X_1) + \text{var}(X_2) + \text{var}(X_3) + \text{var}(X_4)) \quad \text{independentes} \\ &= \frac{7}{16}\sigma^2 \quad \text{idêntica distribuição e } \text{var}(X) = \sigma^2 \end{aligned}$$

- b. Seja o modelo $y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + u_i$ que foi estimado pelos MQ. Defina a regressão auxiliar que se utiliza para prever $E(y | x_2 = 3, x_3 = 1)$ explicando como é obtida.

$$\text{Regressão auxiliar: } y_i = \theta + \beta_2(x_{i2} - 3) + \beta_3(x_{i3} - 1) + u_i$$

O nosso objectivo é estimar $\theta = E(y | x_2 = 3, x_3 = 1) = \beta_1 + \beta_2 \times 3 + \beta_3 \times 1$. Daqui tira-se $\beta_1 = \theta - 3\beta_2 - \beta_3$ que se substitui na equação original

$$\begin{aligned} y_i &= \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + u_i \\ &= \theta - 3\beta_2 - \beta_3 + \beta_2 x_{i2} + \beta_3 x_{i3} + u_i \\ &= \theta + \beta_2(x_{i2} - 3) + \beta_3(x_{i3} - 1) + u_i \end{aligned}$$

Ao estimar a regressão auxiliar estar-se-á a estimar θ .

Parte Prática

Nome: _____ Nº _____

Espaço reservado para classificações

1. (15) 3. (15) 4a. (10) 4d. (15)
2a. (15) 4b. (15) 4e. (15)
2b. (15) 4c. (10) 4f. (15)

T: _____
P: _____

**Em todos os testes de hipóteses que fizer, formule as hipóteses em teste, indique a estatística de teste e a sua distribuição. Se nada for dito em contrário utilize $\alpha = 0.05$. Para os intervalos de confiança proceda de forma semelhante referindo a variável fulcral.
Se necessitar de espaço dispõe de uma página em branco no fim do enunciado**

- 1) Seja uma população com distribuição dada por $f(x|\theta) = \theta x^{\theta-1}$, $0 < x < 1$, $\theta > 0$.
Obtenha o estimador para θ através do método da máxima verosimilhança.

$$L(\theta) = \prod_{i=1}^n f(x_i | \theta) = \prod_{i=1}^n \theta x_i^{\theta-1}$$

$$\ell(\theta) = \ln L(\theta) = \sum_{i=1}^n (\ln \theta + (\theta - 1) \ln x_i)$$

$$\ell'(\theta) = \sum_{i=1}^n \left(\frac{1}{\theta} + \ln x_i \right) \text{ logo } \ell'(\theta) = 0 \Leftrightarrow \sum_{i=1}^n \left(\frac{1}{\theta} + \ln x_i \right) = 0 \Leftrightarrow \frac{n}{\theta} = -\sum_{i=1}^n \ln x_i \Leftrightarrow \theta = -\frac{n}{\sum_{i=1}^n \ln x_i}$$

$$\text{Como } \ell''(\theta) = \sum_{i=1}^n \left(-\frac{1}{\theta^2} \right) = -\frac{n}{\theta^2} < 0, \text{ o estimador de MV será } \hat{\theta} = -\frac{n}{\sum_{i=1}^n \ln X_i}$$

- 2) No início do semestre o Professor de Estatística 2 afirmou que o estudo ao longo do semestre tinha como conseqüências a melhoria dos resultados obtidos em exame. Um dos alunos decidiu testar esta teoria, tendo observado a média e a variância corrigida das notas finais de alguns alunos, uns dos quais estudaram ao longo do semestre (grupo 1) e outros concentraram o estudo nas vésperas do exame (grupo 2). Os valores observados, no que se refere à nota final na disciplina foram:

Grupo 1 – Estudo ao longo do semestre	$n_1 = 11$	$\bar{x}_1 = 13.5$	$s_1'^2 = 1.0$
Grupo 2 – Estudo concentrado	$n_2 = 21$	$\bar{x}_2 = 12.8$	$s_2'^2 = 5.0$

Assuma que em cada grupo as notas têm distribuição normal.

- a. Considere apenas o grupo dos alunos que estudaram regularmente ao longo do semestre e construa um intervalo de confiança a 95% para a nota esperada.

Variável fulcral $\frac{\bar{X} - \mu}{S' / \sqrt{n}} \sim t_{(n-1)}$ com $n = 11$

O IC a 95% para μ_1 vem $\bar{x} \pm t_{0.025} \frac{s'}{\sqrt{11}}$ isto é $13.5 \pm 2.228 \times 1 / \sqrt{11}$ já que $\alpha = 0.05$ ou seja

(12.83; 14.17)

- b. Assumindo que a variância populacional é a mesma nos 2 grupos, teste ($\alpha = 0.05$) a teoria do professor em relação às médias das notas.

$$H_0 : \mu_1 \leq \mu_2 \quad \text{contra} \quad H_1 : \mu_1 > \mu_2 \quad \text{ou} \quad H_0 : \mu_1 = \mu_2 \quad \text{contra} \quad H_1 : \mu_1 > \mu_2$$

$$\text{Estatística de teste } T = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{1}{n_1} + \frac{1}{n_2}} \sqrt{\frac{(n_1 - 1)S_1'^2 + (n_2 - 1)S_2'^2}{n_1 + n_2 - 2}}} \sim t_{(n_1 + n_2 - 2)}$$

$$\text{Como } T_{obs} = \frac{13.5 - 12.8}{\sqrt{\frac{1}{11} + \frac{1}{21}} \sqrt{\frac{10 \times 1.0 + 20 \times 5.0}{30}}} = 0.9822 \text{ tem-se } \text{valor} - p = 0.1669 \text{ logo não se rejeita } H_0$$

ou seja a teoria do professor não está correcta.

Alternativamente $W = \{t : t > 1.697\}$ e tira-se a mesma conclusão já que $T_{obs} \notin W$

- 3) Observada uma amostra aleatória de dimensão $n = 100$ referente à variável aleatória X – número de idas ao centro de saúde/ano em determinado país – quer-se testar se esta tem distribuição de Poisson de parâmetro 1.5. Os valores observados foram

Nº de visitas	0	1	2	3	4
Nº de observações	20	35	25	12	8

Efectue o teste para $\alpha = 0.05$.

Teste do qui-quadrado à bondade do ajustamento

$$H_0 : X \sim Po(1.5) \text{ contra } H_1 : H_0 \text{ falsa que vai ser testada por } H'_0 : p_j = p_{0j} (j = 1, 2, \dots, k)$$

$$\text{Estatística de teste } Q = \sum_{j=1}^k \frac{(N_j - n \times p_{0j})^2}{n \times p_{0j}} \sim \chi^2_{(k-1)}$$

Com

$$p_{0j} = \Pr(X = j) \text{ para } j = 1, 2, 3, 4 \text{ assumindo } H_0$$

$$p_{05} = \Pr(X \geq 4) \text{ assumindo } H_0$$

Nº visitas	0	1	2	3	4+
j	1	2	3	4	5
Nº observado	20	35	25	12	8
Nº esperado	22.31	33.47	25.10	12.55	6.57

$$q_{obs} = \frac{(20 - 22.31)^2}{22.31} + \frac{(35 - 33.47)^2}{33.47} + \dots + \frac{(8 - 6.57)^2}{6.57} = 0.6449$$

Logo $\text{valor} - p = 0.9579$, logo não se rejeita que a distribuição seja uma Poisson de parâmetro 1.5.

- 4) Com o objectivo de estudar o sucesso dos alunos na cadeira de Estatística 2 de determinada escola (dados inventados), construiu-se o seguinte modelo:

$$\text{NotaEst2}_i = \beta_1 + \beta_2 \text{idade}_i + \beta_3 \text{rapaz}_i + \beta_4 \text{NotaEst1}_i + \beta_5 \text{FaltasSem} + \beta_6 \text{HorasEst} + u_i$$

Onde:

- NotaEst2 – Nota na cadeira de Estatística 2;
- idade – Idade do aluno na data do exame;
- rapaz – Variável binária que toma o valor 1 quando o aluno é de sexo masculino;
- NotaEst1 – Nota na cadeira de estatística 1;

- *FaltasSem* – Número médio de aulas a que o aluno faltou por semana;
- *HorasEst* – Número de horas de estudo ao longo do semestre (extra aulas).

Recolhida uma amostra de 141 alunos, estimou-se o modelo através dos mínimos quadrados (**Anexo 1**). As perguntas referem-se sempre ao modelo apresentado podendo utilizar os restantes anexos, sempre que necessário. Em todos os outputs apresentados a variável dependente é sempre *NotaEst2*.

- a. Interprete as estimativas obtidas para os coeficientes de regressão referentes às variáveis *NotaEst1* e *rapaz*

$b_2 = 0.5437$ Tudo o resto igual, um acréscimo de 1 valor na nota final de Estatística 1 origina um acréscimo de 0.5437 na nota esperada em Estatística 2

$b_4 = 0.2602$ Tudo o resto igual, a nota esperada em Estatística 2 de um rapaz situa-se 0.2602 pontos acima da de uma rapariga.

- b. No seu conjunto, as variáveis presentes no modelo são estatisticamente relevantes para explicar a nota final a estatística 2? Efectue um teste adequado. Teste também a relevância individual das variáveis *HorasEst* e *rapaz* na explicação da nota obtida em Estatística 2.

$$H_0: \beta_2 = \beta_3 = \dots = \beta_6 = 0 \quad \text{contra} \quad H_1: \exists \beta_j \neq 0 \quad j = 2, 3, \dots, 6$$

$$\text{Teste F.} \quad F = \frac{R^2 / (k-1)}{(1-R^2) / (n-k)} \sim F(k-1, n-k)$$

$F_{obs} = 21.7644$ $\text{valor} - p \approx 0$ rejeita-se H_0 logo as variáveis presentes são, no seu conjunto, estatisticamente relevantes.

$$H_0: \beta_j = 0 \quad \text{contra} \quad H_1: \beta_j \neq 0 \quad \text{Est. Teste} \quad T = \frac{b_j - \beta_j}{s_{b_j}} \sim t_{(135)}$$

Para *HorasEst* vem $t_{obs} = 8.6765$, $\text{valor} - p \approx 0$ rejeita-se H_0 logo a variável é estatisticamente relevante.

Para *rapaz* vem $t_{obs} = 1.1547$, $\text{valor} - p = 0.25021$, não se rejeita H_0 logo a variável não é estatisticamente relevante.

- c. Formalize o teste de hipóteses relacionado com a estimação presente no **Anexo 2** e retire a sua conclusão. Independentemente da conclusão que tirar, as restantes alíneas referem-se ao modelo original dado no Anexo 1.

$$H_0: \beta_2 = \beta_3 = 0 \quad \text{contra} \quad H_1: \beta_2 \neq 0 \quad \text{ou} \quad \beta_3 \neq 0$$

$$\text{Teste F.} \quad F = \frac{(VR_0 - VR_1) / 2}{VR_1 / (n-k)} \sim F(2, n-k)$$

$$F_{obs} = \frac{(228.6450 - 222.3281) / 2}{1.6469} = 1.9178 \quad \text{valor} - p = 0.1509$$

Não se rejeita H_0 logo as variáveis *idade* e *rapaz* não são, no seu conjunto, estatisticamente relevantes.

- d. Teste $H_0: \beta_4 = 0.5$ contra $H_1: \beta_4 > 0.5$ para $\alpha = 0.05$. Interprete o significado do teste.

$$H_0: \beta_4 = 0.5 \quad \text{contra} \quad H_1: \beta_4 > 0.5 \quad \text{Est. Teste} \quad T = \frac{b_4 - 0.5}{s_{b_j}} \sim t_{(135)}$$

$$T_{obs} = \frac{0.5437 - 0.5}{0.09} = 0.4856 \quad \text{valor} - p = 0.3140$$

logo não se rejeita H_0 , isto é, não se rejeita que o impacto de 1 valor adicional em Estatística 1 seja inferior ou igual a meio valor na nota esperada de Estatística 2, tudo o resto igual

- e. A Ana, aluna de 22 anos que acabou de obter 11 a Estatística 1 e que vai frequentar estatística 2 no próximo semestre, pede-lhe que construa um intervalo de previsão a 90% para a nota que ela irá obter se não faltar a nenhuma aula e estudar 30 horas ao longo do semestre (extra-aulas).

$$\text{Variável fulcral: } T = \frac{y_0 - \hat{y}_0}{s_d} \sim t_{(135)} \quad \text{com } s_d = \sqrt{s^2 + s_{\hat{\theta}}^2}$$

O output necessário encontra-se no anexo 3 a partir do qual se obtém o seguinte intervalo de previsão:

$$12.1828 \pm 1.645 \times \sqrt{1.6469 + 0.2079^2}, \text{ isto é } (10.04; 14.32)$$

- f. Admita que se decide averiguar a razoabilidade de se assumir que os erros são homocedásticos. Apresente uma regressão auxiliar adequada para o efeito bem como a hipótese em teste. Assumindo que da estimação da regressão auxiliar que apresenta se retira $R^2 = 0.11$, qual a conclusão que retira.

Duas soluções são aceitáveis: teste de White simplificado (preferível) ou teste de White

No 1º caso a regressão auxiliar é

$$\hat{u}_i^2 = \alpha_1 + \alpha_2 \text{NotaEst}2_i + \alpha_3 \text{NotaEst}2_i^2 + v_i$$

Em que \hat{u}_i representa os resíduos da regressão original e $\text{NotaEst}2_i$ os valores ajustados na mesma regressão.

$$H_0 : \alpha_2 = \alpha_3 = 0 \text{ contra } H_1 : \alpha_2 \neq 0 \text{ ou } \alpha_3 \neq 0$$

$$\text{Est. Teste } W = n \times R^2 \sim \chi_{(2)}^2$$

$W_{obs} = 141 \times 0.11 = 15.51$ e $\text{valor} - p = 0.0004$ logo rejeita-se H_0 já que existe evidência estatística de que o modelo sofre de heterocedasticidade.

Anexo 1

SUMMARY OUTPUT

<i>Regression Statistics</i>	
Multiple R	0.6681
R Square	0.44631
Adjusted R Square	0.42581
Standard Error	1.28331
Observations	141

ANOVA

	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	5	179.2161	35.8432	21.7644	6.14599E-16
Residual	135	222.3281	1.6469		
Total	140	401.5443			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>
Intercept	1.8319	2.3349	0.7846	0.43410
idade	0.1369	0.0880	1.5549	0.12231
rapaz	0.2602	0.2254	1.1547	0.25021
NotaEst1	0.5437	0.0900	6.0400	0.00000
FaltasSem	-0.2720	0.1024	-2.6568	0.00881
HorasEst	0.0453	0.0052	8.6765	0.00000

Anexo 2

SUMMARY OUTPUT

<i>Regression Statistics</i>	
Multiple R	0.6562
R Square	0.4306
Adjusted R Square	0.4181
Standard Error	1.2919
Observations	141

ANOVA

	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	3	172.8992	57.6331	34.5327	1.098E-16
Residual	137	228.6450	1.6689		
Total	140	401.5443			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>
Intercept	5.3923	1.0524	5.1237	0.0000
Nota_Est1	0.4950	0.0871	5.6837	0.0000
FaltasSem	-0.2646	0.1006	-2.6305	0.0095
HorasEst	0.0448	0.0052	8.5953	0.0000

Anexo 3 –

SUMMARY
OUTPUT

<i>Regression Statistics</i>	
Multiple R	0.6681
R Square	0.4463
Adjusted R Square	0.4258
Standard Error	1.2833
Observations	141

ANOVA					
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Significance F</i>
Regression	5	179.2161	35.8432	21.7644	6.146E-16
Residual	135	222.3281	1.6469		
Total	140	401.5443			

	<i>Coefficients</i>	<i>Standard Error</i>	<i>t Stat</i>	<i>P-value</i>
Intercept	12.1828	0.2079	58.5876	0.0000
idade-22	0.1369	0.0880	1.5549	0.1223
rapaz	0.2602	0.2254	1.1547	0.2502
Nota_Est1-11	0.5437	0.0900	6.0400	0.0000
FaltasSem	-0.2720	0.1024	-2.6568	0.0088
HorasEst-30	0.0453	0.0052	8.6765	0.0000