

Duração: 90 minutos

2º Teste B

**Justifique convenientemente todas as respostas**

**Grupo I**

10 valores

1. Os indivíduos com idade superior a 110 anos são designados de supercentenários. Um estudo recente considera que a idade (em anos) de um supercentenário é descrita pela variável aleatória  $X$  com função de densidade de probabilidade

$$f_X(x) = \begin{cases} \lambda e^{-\lambda(x-110)}, & x \geq 110 \\ 0, & \text{caso contrário,} \end{cases}$$

onde  $\lambda$  é um parâmetro desconhecido positivo.

(a) Deduza o estimador de máxima verosimilhança de  $\lambda$  com base numa amostra aleatória de dimensão  $n$  proveniente desta população. (3.0)

• **V.a. de interesse**

$X$  = idade (em anos) de um supercentenário

• **F.d.p. de  $X$**

$$f_X(x) = \begin{cases} \lambda e^{-\lambda(x-110)}, & x \geq 110 \\ 0, & x < 110 \end{cases}$$

• **Parâmetro desconhecido**

$\lambda, \lambda > 0$

• **Amostra**

$\underline{x} = (x_1, \dots, x_n)$  amostra de dimensão  $n$  proveniente da população  $X$  [com  $x_i > 110, i = 1, \dots, n$ ].

• **Obtenção do estimador de MV de  $\lambda$**

**Passo 1 — Função de verosimilhança**

$$\begin{aligned} L(\lambda|\underline{x}) &= f_{\underline{X}}(\underline{x}) \\ &\stackrel{X_i \text{ indep}}{=} \prod_{i=1}^n f_{X_i}(x_i) \\ &\stackrel{X_i \sim X}{=} \prod_{i=1}^n f_X(x_i) \\ &= \prod_{i=1}^n \left[ \lambda e^{-\lambda(x_i-110)} \right] \\ &= \lambda^n e^{-\lambda \sum_{i=1}^n (x_i-110)}, \quad \lambda > 0 \end{aligned}$$

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

$$\ln L(\lambda|\underline{x}) = n \ln(\lambda) - \lambda \left[ \sum_{i=1}^n (x_i - 110) \right]$$

**Passo 3 — Maximização**

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

$$\hat{\lambda} : \begin{cases} \left. \frac{d \ln L(\lambda|\underline{x})}{d\lambda} \right|_{\lambda=\hat{\lambda}} = 0 & \text{(ponto de estacionaridade)} \\ \left. \frac{d^2 \ln L(\lambda|\underline{x})}{d\lambda^2} \right|_{\lambda=\hat{\lambda}} < 0 & \text{(ponto de máximo)} \\ \left. \begin{aligned} \frac{n}{\hat{\lambda}} - \sum_{i=1}^n (x_i - 110) &= 0 \\ -\frac{n}{\hat{\lambda}^2} &< 0 \end{aligned} \right\} \end{cases}$$

$$\hat{\lambda} : \begin{cases} \hat{\lambda} = \frac{n}{\sum_{i=1}^n (x_i - 110)} \\ -\frac{[\sum_{i=1}^n (x_i - 110)]^2}{n} < 0 \end{cases} \quad (\text{proposição verdadeira já que } \sum_{i=1}^n (x_i - 110) > 0).$$

**Passo 4 — Estimador de MV de  $\lambda$**

$$EMV(\lambda) = \frac{n}{\sum_{i=1}^n (X_i - 110)} \quad [= (\bar{X} - 110)^{-1}]$$

- (b) Recolheu-se uma amostra  $(x_1, \dots, x_5)$ , tendo-se obtido  $\sum_{i=1}^5 x_i = 573.9$ . Obtenha a estimativa de máxima verosimilhança da probabilidade de um supercentenário com idade  $x$  viver ainda mais um ano, isto é, da probabilidade  $P(X > x + 1 | X > x) = e^{-\lambda}$  com  $x > 110$ . (1.5)

• **Estimativa de MV de  $\lambda$**

$$\begin{aligned} \hat{\lambda} &= \frac{n}{\sum_{i=1}^n (x_i - 110)} \\ &= \frac{5}{573.9 - 5 \times 110} \\ &\approx 0.209205 \end{aligned}$$

• **Outro parâmetro desconhecido**

$$\begin{aligned} h(\lambda) &= P(X > x + 1 | X > x) \\ &= e^{-\lambda} \end{aligned}$$

• **Estimativa de MV de  $h(\lambda)$**

Invocando a propriedade de invariância dos estimadores de máxima verosimilhança, conclui-se que a estimativa de MV de  $h(\lambda)$  é dada por

$$\begin{aligned} \widehat{h(\lambda)} &= h(\hat{\lambda}) \\ &= e^{-\hat{\lambda}} \\ &\approx e^{-0.209205} \\ &\approx 0.811229. \end{aligned}$$

2. De modo a comparar a popularidade de dois sites da internet, considerou-se a variável aleatória  $X_1$  (respetivamente  $X_2$ ) que representa o número de acessos semanais ao site 1 (respetivamente ao site 2). Ao selecionarem-se casualmente 41 registos semanais de cada um dos dois sites, obtiveram-se os seguintes resultados:  $\bar{x}_1 = 2952.8$ ,  $s_1^2 = 3307.53$ ,  $\bar{x}_2 = 3002.4$ ,  $s_2^2 = 3100.20$ .

- (a) Determine um intervalo de confiança aproximado a 90% para  $\mu_1 - \mu_2 = E(X_1) - E(X_2)$ . (2.5)

• **V.a. de interesse**

$X_i$  = número de acessos semanais ao site  $i$ , ( $i = 1, 2$ )

• **Situação**

$X_i$  v.a. com dist. arbitrária, valor esperado  $\mu_i$  e variância  $\sigma_i^2$  ( $i = 1, 2$ )

$X_1 \perp\!\!\!\perp X_2$

$(\mu_1 - \mu_2)$  DESCONHECIDO

$\sigma_1^2$  e  $\sigma_2^2$  desconhecidas [não necessariamente iguais]

$n_1 = n_2 = 41 \geq 30$  [i.e., ambas as amostras possuem dimensão suficientemente grande].

• **Obtenção do IC para  $\mu_1 - \mu_2$**

**Passo 1 — Seleção da v.a. fulcral para  $\mu_1 - \mu_2$**

$$Z = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \underset{a}{\sim} \text{normal}(0, 1)$$

[dado que se pretende determinar um IC para a diferença de valores esperados de duas populações com distribuições arbitrárias independentes e com variâncias desconhecidas e dispomos de duas amostras com dimensões suficientemente grandes.]

### Passo 2 — Obtenção dos quantis de probabilidade

Ao ter-se em consideração que  $(1 - \alpha) \times 100\% = 90\%$ , far-se-á uso dos quantis

$$\begin{cases} a_\alpha = \Phi^{-1}(\alpha/2) = \Phi^{-1}(0.05) = -\Phi^{-1}(1 - 0.05) \stackrel{\text{tabela/calcul.}}{=} -1.6449 \\ b_\alpha = \Phi^{-1}(1 - \alpha/2) = \Phi^{-1}(0.95) \stackrel{\text{tabela/calcul.}}{=} 1.6449. \end{cases}$$

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

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

$$P \left[ a_\alpha \leq \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \leq b_\alpha \right] \simeq 1 - \alpha$$

$$P \left[ (\bar{X}_1 - \bar{X}_2) - b_\alpha \times \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \leq \mu_1 - \mu_2 \leq (\bar{X}_1 - \bar{X}_2) - a_\alpha \times \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \right] \simeq 1 - \alpha$$

### Passo 4 — Concretização

Tendo em conta que

$$IC_{(1-\alpha) \times 100\%}(\mu_1 - \mu_2) = \left[ (\bar{x}_1 - \bar{x}_2) \pm \Phi^{-1}(1 - \alpha/2) \times \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \right],$$

bem como os valores dos quantis acima e de  $n_i$ ,  $\bar{x}_i$ ,  $s_i^2$  ( $i = 1, 2$ ), segue-se

$$\begin{aligned} IC_{95\%}(\mu_1 - \mu_2) &= \left[ (2952.8 - 3002.4) \pm 1.6449 \times \sqrt{\frac{3307.53}{41} + \frac{3100.2}{41}} \right] \\ &\simeq [-49.6 \pm 1.6449 \times 12.501449] \\ &\simeq [-70.163625, -29.036375]. \end{aligned}$$

(b) Confronte as hipóteses  $H_0 : \mu_1 - \mu_2 = 0$  e  $H_1 : \mu_1 - \mu_2 < 0$ , calculando para o efeito o valor-p. (3.0)

- **V.a. de interesse e situação**

Ver alínea (a).

- **Hipóteses**

$$H_0 : \mu_1 - \mu_2 = \mu_0 = 0$$

$$H_1 : \mu_1 - \mu_2 < \mu_0$$

- **Estatística de teste**

$$T = \frac{(\bar{X}_1 - \bar{X}_2) - \mu_0}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \underset{H_0}{\sim} \text{normal}(0, 1)$$

[uma vez que se pretende efectuar um teste de igualdade dos valores esperados de duas populações com distribuições arbitrárias independentes e com variâncias desconhecidas, dispondo de duas amostras com dimensões suficientemente grandes.]

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

Estamos a lidar com um teste unilateral inferior ( $H_1 : \mu_1 - \mu_2 < \mu_0$ ), logo a região de rejeição de  $H_0$  é do tipo  $W = (-\infty, -c)$ .

- **Decisão (com base no valor-p)**

O valor observado da estatística de teste é igual a

$$\begin{aligned}
t &= \frac{(\bar{x}_1 - \bar{x}_2) - \mu_0}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \\
&= \frac{(2952.8 - 3002.4) - 0}{\sqrt{\frac{3307.53}{41} + \frac{3100.2}{41}}} \\
&\approx \frac{-49.6}{12.501449} \\
&\approx -3.967540.
\end{aligned}$$

e a região de rejeição deste teste é um intervalo à esquerda. Consequentemente

$$\begin{aligned}
\text{valor} - p &= P(T < t \mid H_0) \\
&\approx \Phi(t) \\
&\approx \Phi(-3.97) \\
&= 1 - \Phi(3.97) \\
&\stackrel{\text{tabela/ calc.}}{=} 1 - 0.999964 \\
&= 0.000036.
\end{aligned}$$

Logo é suposto:

- não rejeitar  $H_0$  a qualquer nível de significância  $\alpha_0 \leq 0.0036\%$ ;
- rejeitar  $H_0$  a qualquer n.s.  $\alpha_0 > 0.0036\%$ , nomeadamente a qualquer dos níveis usuais de significância (1%, 5% e 10%).

## Grupo II

10 valores

1. Uma estudante recorreu a um *software* estatístico para gerar 1800 números pseudo-aleatórios no intervalo  $[0, 1]$ , tendo obtido a seguinte tabela de frequências:

Classe	$]0, 0.2]$	$]0.2, 0.5]$	$]0.5, 0.8]$	$]0.8, 1]$
Frequência absoluta observada	391	490	580	339

A estudante defende a hipótese  $H_0$  de que o *software* gerou números pseudo-aleatórios que seguem uma distribuição uniforme contínua no intervalo  $[0, 1]$ .

- (a) Calcule os valores das frequências absolutas esperadas sob  $H_0$  de cada uma das classes. (1.0)

- **V.a. de interesse**

$X$  = número pseudo-aleatório gerado pelo *software* estatístico

- **Distribuição, f.d.p. e f.d. conjecturadas**

$X \sim$  uniforme contínua(0, 1)

$$f_X(x) = \begin{cases} 1, & 0 \leq x \leq 1 \\ 0, & \text{caso contrário} \end{cases}$$

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(t) dt = \begin{cases} \int_{-\infty}^x 0 dt = 0, & x < 0 \\ \int_{-\infty}^0 0 dt + \int_0^x 1 dt = x, & 0 \leq x \leq 1 \\ \int_{-\infty}^0 0 dt + \int_0^1 1 dt + \int_1^x 0 dt = 1, & x > 1. \end{cases}$$

- **Frequências absolutas esperadas**

Atendendo à dimensão da amostra  $n = 1800$  e à f.d. conjecturada, segue-se, para  $i = 1, \dots, 4$ :

$$\begin{aligned}
E_1 &= n \times [F(0.2) - F(0)] \\
&= 1800 \times (0.2 - 0) \\
&= 360;
\end{aligned}$$

$$\begin{aligned}
E_2 &= n \times [F(0.5) - F(0.2)] \\
&= 1800 \times (0.5 - 0.2) \\
&= 540; \\
E_3 &= n \times [F(0.8) - F(0.5)] \\
&= 1800 \times (0.8 - 0.5) \\
&= 540; \\
E_4 &= n - \sum_{i=1}^3 E_i \\
&= 1800 - (360 + 540 + 540) \\
&= 360.
\end{aligned}$$

(b) Teste  $H_0$ , ao nível de significância de 5%.

(3.0)

• **Hipóteses**

$H_0 : X \sim \text{uniforme contínua}(0, 1)$

$H_1 : X \not\sim \text{uniforme contínua}(0, 1)$

• **Nível de significância**

$\alpha_0 = 5\%$

• **Estatística de Teste**

$$T = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \stackrel{a}{\sim}_{H_0} \chi_{(k-\beta-1)}^2,$$

onde:

$k = \text{No. de classes} = 4$

$O_i = \text{Frequência absoluta observável da classe } i$

$E_i = \text{Frequência absoluta esperada, sob } H_0, \text{ da classe } i$

$\beta = \text{No. de parâmetros a estimar} = 0$  [dado que em  $H_0$  se conjectura uma distribuição específica.]

• **Frequências absolutas esperadas sob  $H_0$**

De acordo com (a), os valores das freq. absolutas esperadas sob  $H_0$  são:  $E_1 = E_4 = 360$ ;  $E_2 = E_3 = 540$ .

[Não é necessário fazer qualquer agrupamento de classes uma vez que em pelo menos 80% das classes se verifica  $E_i \geq 5$  e que  $E_i \geq 1$  para todo o  $i$ . Caso fosse preciso efectuar agrupamento de classes, os valores de  $k$  e  $c = F_{\chi_{(k-\beta-1)}^2}^{-1}(1 - \alpha_0)$  teriam que ser recalculados...]

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

Trata-se de um teste de ajustamento logo a região de rejeição de  $H_0$  escrita para valores de  $T$  é o intervalo à direita  $W = (c, +\infty)$ , onde

$$c = F_{\chi_{(k-\beta-1)}^2}^{-1}(1 - \alpha_0) = F_{\chi_{(4-0-1)}^2}^{-1}(1 - 0.05) = F_{\chi_{(3)}^2}^{-1}(0.95) \stackrel{\text{tabela/calc.}}{=} 7.815.$$

• **Decisão**

$i$	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, 0.2]	391	360	$\frac{(391-360)^2}{360} \approx 2.669$
2	]0.2, 0.5]	490	540	4.630
3	]0.5, 0.8]	580	540	2.963
4	]0.8, 1]	339	360	1.225
		$\sum_{i=1}^k o_i = n$ = 1800	$\sum_{i=1}^k E_i = n$ = 1800	$t = \sum_{i=1}^k \frac{(o_i - E_i)^2}{E_i}$ $\approx 11.487$

Como  $t \approx 11.487 \in W = (7.815, +\infty)$ , devemos rejeitar  $H_0$  ao n.s. de  $\alpha_0 = 5\%$ .

2. A determinação da resistência ao cisalhamento ( $Y$ ) de soldas por pontos é relativamente difícil, enquanto que a medição do diâmetro da solda ( $x$ ) é relativamente simples. Um conjunto de 10 medições independentes conduziu aos seguintes resultados respeitantes a  $x$  (em polegada) e a  $Y$  (em psi):

$$\sum_{i=1}^{10} x_i = 2.325, \quad \sum_{i=1}^{10} x_i^2 = 0.697425, \quad \sum_{i=1}^{10} y_i = 22860, \quad \sum_{i=1}^{10} y_i^2 = 67719400, \quad \sum_{i=1}^{10} x_i y_i = 6872.25,$$

onde  $[\min_{i=1, \dots, 10} x_i, \max_{i=1, \dots, 10} x_i] = [0.04, 0.4]$ .

(a) Considere o modelo de regressão linear simples de  $Y$  em  $x$  e determine a estimativa de mínimos quadrados do valor esperado da resistência ao cisalhamento de uma solda com diâmetro igual a 0.25 polegada. (2.0)

• **Estimativas de MQ de  $\beta_0, \beta_1$  e  $E(Y | x) = \beta_0 + \beta_1 x$  com  $x = 0.25$**

Dado que

$$n = 10$$

$$\sum_{i=1}^n x_i = 2.325$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{2.325}{10} = 0.2325$$

$$\sum_{i=1}^n x_i^2 = 0.697425$$

$$\sum_{i=1}^n x_i^2 - n(\bar{x})^2 = 0.697425 - 10 \times 0.2325^2 = 0.1568625$$

$$\sum_{i=1}^n y_i = 22860$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{22860}{10} = 2286$$

$$\sum_{i=1}^n y_i^2 = 67719400$$

$$\sum_{i=1}^n y_i^2 - n(\bar{y})^2 = 67719400 - 10 \times 2286^2 = 15461440$$

$$\sum_{i=1}^n x_i y_i = 6872.25$$

$$\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} = 6872.25 - 10 \times 0.2325 \times 2286 = 1557.3,$$

as estimativas de MQ de  $\beta_1, \beta_0$  e  $\beta_0 + \beta_1 x$  são, para este modelo de RLS, iguais a:

$$\begin{aligned} \hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n(\bar{x})^2} \\ &= \frac{1557.3}{0.1568625} \\ &\approx 9927.803012 \end{aligned}$$

$$\begin{aligned} \hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x} \\ &\approx 2286 - 9927.803012 \times 0.2325 \\ &\approx -22.2142 \end{aligned}$$

$$\begin{aligned} \hat{\beta}_0 + \hat{\beta}_1 x &\approx -22.2142 + 0.25 \times 9927.803012 \\ &\approx 2459.736553. \end{aligned}$$

(b) Uma engenheira mecânica defende a conjectura  $H_0 : \beta_1 = 10000$  ao passo que um engenheiro de materiais é de opinião contrária. Após ter enunciado as hipóteses de trabalho que entender convenientes, teste  $H_0$  ao nível de significância de 5%. (3.0)

• **Hipóteses de trabalho**

$$\epsilon_i \stackrel{i.i.d.}{\sim} \text{Normal}(0, \sigma^2), \quad i = 1, \dots, n$$

• **Hipóteses**

$$H_0 : \beta_1 = \beta_{1,0} = 10000$$

$$H_1 : \beta_1 \neq \beta_{1,0}$$

• **Nível de significância**

$$\alpha_0 = 5\%$$

- **Estatística de teste**

$$T = \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \sim_{H_0} t_{(n-2)}$$

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

Estamos a lidar com um teste bilateral ( $H_1 : \beta_1 \neq 10000$ ), logo a região de rejeição de  $H_0$  é do tipo  $W = (-\infty, -c) \cup (c, +\infty)$ , onde  $c : P(\text{Rejeitar } H_0 | H_0) = \alpha_0$ , i.e.,

$$\begin{aligned} c &= F_{t_{(n-2)}}^{-1}(1 - \alpha_0/2) \\ &= F_{t_{(10-2)}}^{-1}(1 - 0.05/2) \\ &= F_{t_{(8)}}^{-1}(0.975) \\ &\stackrel{\text{tabela/calc.}}{=} 2.306. \end{aligned}$$

- **Decisão**

Atendendo aos valores obtidos em (a), assim como o de

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{n-2} \left[ \left( \sum_{i=1}^n y_i^2 - n\bar{y}^2 \right) - (\hat{\beta}_1)^2 \left( \sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) \right] \\ &\approx \frac{1}{10-2} (15461440 - 9927.803012^2 \times 0.1568625) \\ &\approx 109.046214, \end{aligned}$$

o valor observado da estatística de teste é igual a

$$\begin{aligned} t &= \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n\bar{x}^2}}} \\ &\approx \frac{9927.803012 - 10000}{\sqrt{\frac{109.046214}{0.1568625}}} \\ &= -2.738252. \end{aligned}$$

Como  $t \approx -2.738252 \in W = (-\infty, -2.306) \cup (2.306, +\infty)$  devemos rejeitar  $H_0$  ao n.s. de 5% [bem como a qualquer n.s. superior que 5%).

(c) Obtenha e interprete o valor do coeficiente de determinação do modelo ajustado. (1.0)

- **Cálculo do coeficiente de determinação**

$$\begin{aligned} r^2 &= \frac{(\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y})^2}{(\sum_{i=1}^n x_i^2 - n\bar{x}^2) \times (\sum_{i=1}^n y_i^2 - n\bar{y}^2)} \\ &= \frac{1557.3^2}{0.156863 \times 15461440} \\ &\approx 0.999940. \end{aligned}$$

- **Interpretação coeficiente de determinação**

Cerca de 99.99% da variação total da variável resposta  $Y$  é explicada pela variável  $x$ , através do modelo de regressão linear simples ajustado, donde podemos afirmar que a recta estimada parece ajustar-se excepcionalmente bem ao conjunto de dados.