



Duração: 90 minutos

2º teste B

Justifique convenientemente todas as respostas

Grupo I

10 valores

1. A concentração de um nutriente em determinado produto alimentar é uma variável aleatória com função de densidade de probabilidade dada por

$$f_X(x) = \begin{cases} (\theta + 1) x^\theta, & 0 < x < 1 \\ 0, & \text{caso contrário,} \end{cases}$$

onde θ é um parâmetro positivo desconhecido. Seja (X_1, \dots, X_n) uma amostra aleatória de X .

(a) Mostre que o estimador de máxima verosimilhança do parâmetro θ , com base na amostra aleatória referida acima, é dado por $\frac{-n}{\sum_{i=1}^n \ln(X_i)} - 1$. (2.5)

• **V.a. de interesse**

X = concentração de um nutriente em determinado produto alimentar

• **F.d.p. de X**

$$f_X(x) = \begin{cases} (\theta + 1) x^\theta, & 0 < x < 1 \\ 0, & \text{caso contrário} \end{cases}$$

• **Parâmetro desconhecido**

$\theta, \theta > 0$

• **Amostra**

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

• **Obtenção do estimador de MV de θ**

Passo 1 — Função de verosimilhança

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

Passo 2 — Função de log-verosimilhança

$$\ln L(\theta|\underline{x}) = n \ln(\theta + 1) + \theta \sum_{i=1}^n \ln(x_i)$$

Passo 3 — Maximização

A estimativa de MV de θ passa a ser representada por $\hat{\theta}$ e

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

$$\hat{\theta} : \begin{cases} \hat{\theta} = \frac{-n}{\sum_{i=1}^n \ln(x_i)} - 1 \\ -\frac{[\sum_{i=1}^n \ln(x_i)]^2}{n} < 0 \end{cases} \text{ (proposição verdadeira porque } n > 0 \text{ e } \sum_{i=1}^n \ln(x_i) \neq 0 \text{).}$$

Passo 4 — Estimador de MV de θ

$$EMV(\theta) = \frac{-n}{\sum_{i=1}^n \ln(X_i)} - 1.$$

- (b) Obtenha a estimativa de máxima verosimilhança de $h(\theta) = \frac{\theta+1}{\theta+2}$ baseada na concretização (1.5) $(x_1, x_2, x_3, x_4, x_5) = (0.32, 0.24, 0.56, 0.67, 0.58)$ para a qual $\sum_{i=1}^n \ln(x_i) \approx -4.09$.

- **Estimativa de MV de θ**

$$\begin{aligned} \hat{\theta} &= \frac{-n}{\sum_{i=1}^n \ln(x_i)} - 1 \\ &\approx \frac{-5}{-4.09} - 1 \\ &\approx 0.222494 \end{aligned}$$

- **Outro parâmetro desconhecido**

$$h(\theta) = \frac{\theta+1}{\theta+2}$$

- **Estimativa de MV de $h(\theta)$**

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

$$\begin{aligned} \widehat{h(\theta)} &= h(\hat{\theta}) \\ &= \frac{\hat{\theta} + 1}{\hat{\theta} + 2} \\ &\approx \frac{0.222494 + 1}{0.222494 + 2} \\ &\approx 0.550055. \end{aligned}$$

- (c) Averigüe se \bar{X} é um estimador centrado de $h(\theta)$. (1.0)

- **Parâmetro desconhecido**

$$h(\theta) = \frac{\theta+1}{\theta+2}$$

- **Estimador de $h(\theta)$**

$$\bar{X}$$

- **Valor esperado de \bar{X}**

Uma vez que $X_i \stackrel{i.i.d.}{\sim} X, i = 1, \dots, n$, segue-se que:

$$\begin{aligned} E(\bar{X}) &= E(X) \\ &= \int_0^1 (\theta + 1) x^{\theta+1} dx \\ &= \frac{\theta + 1}{\theta + 2} x^{\theta+2} \Big|_0^1 \\ &= \frac{\theta + 1}{\theta + 2} \\ &\equiv h(\theta). \end{aligned}$$

- **Conclusão**

Uma vez que

- T se diz um estimador centrado de $h(\theta)$ caso $E(T) = h(\theta), \forall \theta > 0$, podemos afirmar que \bar{X} é um estimador centrado de $h(\theta)$.

2. O diâmetro (X , em mm) dos cilindros hidráulicos produzidos por determinada fábrica possui distribuição normal com parâmetros desconhecidos μ e σ^2 . A concretização de uma amostra aleatória de dimensão 10 conduziu aos seguintes resultados: $\sum_{i=1}^{10} x_i = 846$ e $\sum_{i=1}^{10} x_i^2 = 71\,607$.

(a) Determine um intervalo de confiança a 95% para σ^2 . (2.5)

• **V.a. de interesse**

X = diâmetro de cilindro hidráulico produzido pela fábrica

• **Situação**

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

μ desconhecido

σ^2 DESCONHECIDO

• **Obtenção do IC para σ^2**

Passo 1 — Selecção da v.a. fulcral para σ^2

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

[uma vez que é suposto determinar um IC para a variância de uma população normal, com valor esperado desconhecido.]

Passo 2 — Obtenção dos quantis de probabilidade

Ao ter-se em consideração que $n = 10$ e $(1 - \alpha) \times 100\% = 95\%$, far-se-á uso dos quantis

$$\begin{cases} a_\alpha = F_{\chi_{(n-1)}^2}^{-1}(\alpha/2) = F_{\chi_{(9)}^2}^{-1}(0.025) \stackrel{\text{tabela/calc.}}{=} 2.700 \\ b_\alpha = F_{\chi_{(n-1)}^2}^{-1}(1 - \alpha/2) = F_{\chi_{(9)}^2}^{-1}(0.975) \stackrel{\text{tabela/calc.}}{=} 19.02. \end{cases}$$

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

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

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

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

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

Passo 4 — Concretização

Atendendo ao par de quantis acima e ao facto de

$$\begin{aligned} s^2 &= \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - n(\bar{x})^2 \right] \\ &= \frac{1}{10-1} [71\,607 - 10 \times (846/10)^2] \\ &= 3.9(3) \end{aligned}$$

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

segue-se:

$$\begin{aligned} IC_{95\%}(\sigma^2) &= \left[\frac{(10-1) \times 3.9(3)}{19.02}, \frac{(10-1) \times 3.9(3)}{2.700} \right] \\ &\simeq [1.860928, 13.109220]. \end{aligned}$$

(b) Teste $H_0: \sigma^2 = 4$ contra $H_1: \sigma^2 > 4$. Decida com base no valor- p . (2.5)

• **V.a. de interesse e situação**

Ver alínea (a).

- **Hipóteses**

$$H_0 : \sigma^2 = \sigma_0^2 = 4$$

$$H_1 : \sigma^2 > \sigma_0^2$$

- **Estatística de teste**

$$T = \frac{(n-1)S^2}{\sigma_0^2} \sim_{H_0} \chi^2_{(n-1)}$$

[dado que se pretende efectuar um teste sobre a variância de uma população normal, com valor esperado desconhecido.]

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

Estamos a lidar com um teste unilateral superior ($H_1 : \sigma^2 > \sigma_0^2$), logo a região de rejeição de H_0 (para valores da estatística de teste) é do tipo $W = (c, +\infty)$.

- **Decisão (com base no valor-p)**

O valor observado da estatística de teste é igual a

$$\begin{aligned} t &= \frac{(n-1)s^2}{\sigma_0^2} \\ &= \frac{(10-1) \times 3.9(3)}{4} \\ &\simeq 8.85. \end{aligned}$$

Uma vez que a região de rejeição deste teste é um intervalo à direita, temos:

$$\begin{aligned} \text{valor} - p &= P(T > t \mid H_0) \\ &= 1 - F_{\chi^2_{(n-1)}}(t) \\ &= 1 - F_{\chi^2_{(9)}}(8.85) \\ &\stackrel{\text{calc/tabela}}{=} 0.451234. \end{aligned}$$

Deste modo é suposto:

- não rejeitar H_0 a qualquer n.s. $\alpha_0 \leq 45.1234\%$, pelo que H_0 não é contrariada pelos dados aos n.u.s. (1%, 5%, 10%);
- rejeitar H_0 a qualquer n.s. $\alpha_0 > 45.1234\%$.

[Em alternativa, poderíamos recorrer às tabelas de quantis da distribuição do qui-quadrado com 9 graus de liberdade e adiantar um intervalo para o *p-value*:

$$\begin{aligned} F_{\chi^2_{(9)}}^{-1}(0.50) = 8.343 &< t = 8.85 < 9.414 = F_{\chi^2_{(9)}}^{-1}(0.60) \\ 0.50 &< F_{\chi^2_{(9)}}(8.85) < 0.60 \\ 1 - 0.60 &< 1 - F_{\chi^2_{(9)}}(8.85) < 1 - 0.50 \\ 0.40 &< \text{valor} - p < 0.50. \end{aligned}$$

Assim, é suposto:

- não rejeitar H_0 a qualquer n.s. $\alpha_0 \leq 40\%$, pelo que H_0 não é contrariada pelos dados aos n.u.s. (1%, 5%, 10%);
- rejeitar H_0 a qualquer n.s. $\alpha_0 \geq 50\%$.

Grupo II

10 valores

1. Ao recorrer a um pequeno programa destinado a gerar 250 números pseudo-aleatórios no intervalo $[0, 10]$, obtiveram-se os seguintes dados:

Classe	$[0, 2]$	$]2, 4]$	$]4, 6]$	$]6, 8]$	$]8, 10]$
Frequência absoluta observada	38	55	54	41	62

Uma engenheira informática defende a hipótese H_0 de que o programa gera números pseudo-aleatórios que seguem uma distribuição uniforme contínua no intervalo $[0, 10]$.

(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 programa

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

$X \sim$ uniforme contínua(0, 10)

$$f_X(x) = \begin{cases} \frac{1}{10}, & 0 \leq x \leq 10 \\ 0, & \text{c.c.} \end{cases}$$

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x f_X(t) dt = \begin{cases} \int_{-\infty}^x 0 dt = 0, & x < 0 \\ \int_{-\infty}^0 0 dt + \int_0^x \frac{1}{10} dt = \frac{x}{10}, & 0 \leq x \leq 10 \\ \int_{-\infty}^0 0 dt + \int_0^{10} \frac{1}{10} dt + \int_{10}^x 0 dt = 1, & x > 10. \end{cases}$$

• **Frequências absolutas esperadas**

Atendendo à dimensão da amostra $n = 250$ e à f.d. conjecturada, segue-se, para $i = 1, \dots, 5$:

$$\begin{aligned} E_i &= n \times [F(2i) - F(2i - 2)] \\ &= 250 \times \left(\frac{2i}{10} - \frac{2i - 2}{10} \right) \\ &= 250 \times \frac{1}{5} \\ &= 50. \end{aligned}$$

(b) Teste H_0 , ao nível de significância de 10%. (3.0)

• **Hipóteses**

$H_0 : X \sim$ uniforme contínua(0, 10)

$H_1 : X \not\sim$ uniforme contínua(0, 10)

• **Nível de significância**

$\alpha_0 = 10\%$

• **Estatística de Teste**

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

onde:

k = No. de classes = 5

O_i = Frequência absoluta observável da classe i

E_i = Frequência absoluta esperada, sob H_0 , da classe i

β = 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: $E_i = 50, i = 1, \dots, 5$.

[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 $c = F_{\chi^2_{(k-\beta-1)}}^{-1}(1 - \alpha_0)$ teriam que ser recalculados...]

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

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

$$\begin{aligned} c &= F_{\chi^2_{(k-\beta-1)}}^{-1}(1 - \alpha_0) \\ &= F_{\chi^2_{(5-0-1)}}^{-1}(1 - 0.10) \\ &= F_{\chi^2_{(4)}}^{-1}(0.90) \\ &\stackrel{\text{tabela/calcul.}}{=} 7.779. \end{aligned}$$

• **Decisão**

No cálculo do valor obs. da estat. de teste convém recorrer à seguinte tabela auxiliar:

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	[0,2]	38	50	$\frac{(38-50)^2}{50} = 2.88$
2]2,4]	55	50	0.50
3]4,6]	54	50	0.32
4]6,8]	41	50	1.62
5]8,10]	62	50	2.88
		$\sum_{i=1}^k o_i = n$ = 250	$\sum_{i=1}^k e_i = n$ = 250	$t = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$ ≈ 8.20

Como $t \approx 8.20 \in W = (7.779, +\infty)$, devemos rejeitar H_0 ao n.s. de $\alpha_0 = 10\%$ [ou a qualquer outro n.s. superior a 10%].

2. A densidade relativa de certa madeira é descrita pela variável x e a força máxima necessária para o seu esmagamento em compressão paralela ao grão é representada pela variável aleatória Y (em psi). Uma amostra de dimensão 10 conduziu aos seguintes valores:

$$\sum_{i=1}^{10} x_i = 4.31, \quad \sum_{i=1}^{10} x_i^2 = 1.8629, \quad \sum_{i=1}^{10} y_i = 24520, \quad \sum_{i=1}^{10} y_i^2 = 61\,761\,600, \quad \sum_{i=1}^{10} x_i y_i = 10632.9,$$

onde $[\min_{i=1,\dots,10} x_i, \max_{i=1,\dots,10} x_i] = [0.39, 0.47]$.

(a) Após ter enunciado as hipóteses de trabalho que entender convenientes, calcule as estimativas de máxima verosimilhança dos parâmetros da reta de regressão linear simples de Y em x , bem como a estimativa de máxima verosimilhança de $E(Y | x = 0.431)$. (2.5)

• **Hipóteses de trabalho**

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

• **Estimativas de MV de β_0 e β_1**

Dado que

$$n = 10$$

$$\sum_{i=1}^n x_i = 4.31$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{4.31}{10} = 0.431$$

$$\sum_{i=1}^n x_i^2 = 1.8629$$

$$\sum_{i=1}^n x_i^2 - n(\bar{x})^2 = 1.8629 - 10 \times 0.431^2 = 0.00529$$

$$\sum_{i=1}^n y_i = 24520$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{24520}{10} = 2452$$

$$\sum_{i=1}^n y_i^2 = 61\,761\,600$$

$$\sum_{i=1}^n y_i^2 - n(\bar{y})^2 = 61\,761\,600 - 10 \times 2452^2 = 1\,638\,560$$

$$\sum_{i=1}^n x_i y_i = 10632.9$$

$$\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} = 10632.9 - 10 \times 0.431 \times 2452 = 64.78,$$

as estimativas de MV de β_1 e β_0 são, para este modelo de RLS, iguais a:

$$\begin{aligned} \hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n(\bar{x})^2} \\ &= \frac{64.78}{0.00529} \\ &\approx 12245.7 \end{aligned}$$

$$\begin{aligned}\hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \times \bar{x} \\ &\simeq 2452 - 12245.7 \times 0.431 \\ &\simeq -2825.9.\end{aligned}$$

- **Estimativa de MV para** $E(Y | x = x_0) = \beta_0 + \beta_1 x_0$, com $x_0 = 0.431$

$$\begin{aligned}\hat{E}(Y | x = x_0) &= \hat{\beta}_0 + \hat{\beta}_1 x_0 \\ &= -2825.9 + 12245.7 \times 0.431 \\ &\simeq 2452.\end{aligned}$$

[Não cometemos qualquer erro de extrapolação ao estimar pontualmente $E(Y | x = x_0) = \beta_0 + \beta_1 \times x_0$ uma vez que $x_0 \in [\min_{i=1, \dots, n} x_i, \max_{i=1, \dots, n} x_i]$. Note-se que, neste caso $x_0 = \bar{x}$, logo $\hat{E}(Y | x = x_0) = \hat{\beta}_0 + \hat{\beta}_1 \bar{x} = (\bar{y} - \hat{\beta}_1 \bar{x}) + \hat{\beta}_1 \bar{x} \equiv \bar{y}$, como se pôde constatar acima.]

- (b) Teste a hipótese $E(Y | x = 0.431) = 2500$, ao nível de significância de 5%. (2.5)

- **Hipóteses** (com $x_0 = 0.431$)
 $H_0 : E(Y | x = x_0) = E_0(Y | x_0) = 2500$ vs.
 $H_1 : E(Y | x = x_0) \neq E_0(Y | x_0)$

- **Nível de significância**
 $\alpha_0 = 5\%$

- **Estatística de teste**

$$T = \frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - E_0(Y | x_0)}{\sqrt{\hat{\sigma}^2 \times \left[\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right]}} \sim_{H_0} t_{(n-2)}$$

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

Estamos a lidar com um teste bilateral ($H_1 : E(Y | x_0) \neq E_0(Y | x_0)$), pelo que a região de rejeição de H_0 [escrita para valores observados da estatística de teste] é $W = (-\infty, -c) \cup (c, +\infty)$, onde

$$\begin{aligned}c &: P(\text{Rejeitar } H_0 | H_0) = \alpha_0 \\ c &= F_{t(n-2)}^{-1}(1 - \alpha_0/2) \\ c &= F_{t(8)}^{-1}(0.975) \\ c &\stackrel{\text{tabela/ calc}}{=} 2.306\end{aligned}$$

- **Decisão**

Tendo em conta que

$$\begin{aligned}\hat{\sigma}^2 &= \frac{1}{n-2} \left[\left(\sum_{i=1}^n y_i^2 - n \bar{y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right] \\ &\simeq \frac{1}{10-2} (1638560 - 12245.7^2 \times 0.00529) \\ &\simeq 105660.1,\end{aligned}$$

o valor observado da estatística de teste é igual a

$$\begin{aligned}t &= \frac{(\hat{\beta}_0 + \hat{\beta}_1 x_0) - E_0(Y | x_0)}{\sqrt{\hat{\sigma}^2 \times \left[\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \right]}} \\ &= \frac{2452 - 2500}{\sqrt{105660.1 \times \left[\frac{1}{10} + \frac{(0.431 - 0.431)^2}{0.00529} \right]}} \\ &\simeq -0.466967.\end{aligned}$$

Como $t \simeq -0.466967 \notin W = (-\infty, -2.306) \cup (2.306, +\infty)$, não devemos rejeitar H_0 , ao nível de significância $\alpha_0 = 5\%$ [ou a qualquer outro n.s. inferior a 5%].

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

(1.0)

• **Cálculo do coeficiente de determinação**

$$\begin{aligned} r^2 &= \frac{(\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y})^2}{(\sum_{i=1}^n x_i^2 - n \bar{x}^2) \times (\sum_{i=1}^n y_i^2 - n \bar{y}^2)} \\ &= \frac{64.78^2}{0.00529 \times 1638560} \\ &\simeq 0.484132. \end{aligned}$$

• **Interpretação coeficiente de determinação**

Cerca de 48.4% 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 não parece ajustar-se bem ao conjunto de dados.