



Duração: 90 minutos

2º teste A

Justifique convenientemente todas as respostas

Grupo I

10 valores

1. A variável aleatória X representa o número diário de análises químicas efectuadas por um pequeno laboratório e possui função de probabilidade satisfazendo:

$$P(X = x) = \frac{(x+1)(x+2)}{2} (1-p)^x p^3, \quad x = 0, 1, 2, \dots,$$

onde $p \in]0, 1[$ é uma probabilidade desconhecida. Seja (X_1, X_2, \dots, X_n) uma amostra aleatória de X .

(a) Mostre que o estimador de máxima verosimilhança do parâmetro p , com base na amostra aleatória referida acima, é dado por $3/(\bar{X} + 3)$. (3.0)

• **V.a. de interesse**

X = número diário de análises químicas a efectuar por um pequeno laboratório

• **Fp. de X**

$$P(X = x) = \frac{(x+1)(x+2)}{2} (1-p)^x p^3, \quad x = 0, 1, 2, \dots$$

• **Parâmetro desconhecido**

$$p, \quad 0 < p < 1$$

• **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

$$\begin{aligned} L(p | \underline{x}) &= P(\underline{X} = \underline{x}) \\ &\stackrel{X_i \text{ indep}}{=} \prod_{i=1}^n P(X_i = x_i) \\ &\stackrel{X_i \sim X}{=} \prod_{i=1}^n P(X = x_i) \\ &= \prod_{i=1}^n \left[\frac{(x_i + 1)(x_i + 2)}{2} (1-p)^{x_i} p^3 \right] \\ &= 2^{-n} \left[\prod_{i=1}^n (x_i + 1)(x_i + 2) \right] (1-p)^{\sum_{i=1}^n x_i} p^{3n}, \quad 0 < p < 1 \end{aligned}$$

Passo 2 — Função de log-verosimilhança (caso $\bar{x} > 0$)

$$\ln L(p | \underline{x}) = -n \ln(2) + \sum_{i=1}^n \ln[(x_i + 1)(x_i + 2)] + \ln(1-p) \sum_{i=1}^n x_i + 3n \ln(p)$$

Passo 3 — Maximização

A estimativa de MV de p passa a ser representada por \hat{p} e

$$\hat{p} : \begin{cases} \frac{d \ln L(p | \underline{x})}{dp} \Big|_{p=\hat{p}} = 0 & \text{(ponto de estacionaridade)} \\ \frac{d^2 \ln L(p | \underline{x})}{dp^2} \Big|_{p=\hat{p}} < 0 & \text{(ponto de máximo)} \\ \begin{cases} -\frac{\sum_{i=1}^n x_i}{1-\hat{p}} + \frac{3n}{\hat{p}} = 0 \\ -\frac{\sum_{i=1}^n x_i}{(1-\hat{p})^2} - \frac{3n}{\hat{p}^2} < 0 \end{cases} & \text{(prop. verdadeira porque } \bar{x} \geq 0 \text{ e } n > 0) \end{cases}$$

$$\hat{p} : \begin{cases} -\hat{p}n\bar{x} + 3n - 3n\hat{p} = 0 & \Leftrightarrow \hat{p} = \frac{3}{\bar{x}+3} \\ \left[-\frac{n\bar{x}}{\left(1-\frac{3}{\bar{x}+3}\right)^2} - \frac{3n}{\left(\frac{3}{\bar{x}+3}\right)^2} = -\frac{n(\bar{x}+3)^3}{3\bar{x}} < 0 \right]. \end{cases}$$

Passo 4 — Estimador de MV de λ

$$EMV(p) = \frac{3}{\bar{X} + 3}.$$

- (b) Obtenha a estimativa de máxima verosimilhança de $E(X) = 3\left(\frac{1}{p} - 1\right)$ baseada na concretização $(x_1, x_2, x_3, x_4, x_5) = (2, 3, 1, 4, 0)$. (1.5)

• **Estimativa de MV de p**

$$\begin{aligned} \hat{p} &= \frac{3}{\bar{x} + 3} \\ &= \frac{3}{\frac{2+3+1+4+0}{5} + 3} \\ &= \frac{3}{2+3} \\ &= 0.6 \end{aligned}$$

• **Outro parâmetro desconhecido**

$$h(p) = 3\left(\frac{1}{p} - 1\right)$$

• **Estimativa de MV de $h(p)$**

Ao invocar a propriedade de invariância dos estimadores de máxima verosimilhança, obtemos a estimativa de MV de $h(p)$:

$$\begin{aligned} \overline{h(p)} &= h(\hat{p}) \\ &= 3\left(\frac{1}{\hat{p}} - 1\right) \\ &= 3\left(\frac{1}{0.6} - 1\right) \\ &= 2 \quad [\equiv \bar{x} \text{ pois } h(\hat{p}) = 3\left(\frac{1}{\hat{p}} - 1\right) = 3\left(\frac{1}{\frac{3}{\bar{x}+3}} - 1\right) = \bar{x}]. \end{aligned}$$

2. De forma a comparar dois grupos de estudantes universitários, considerou-se a variável aleatória X_1 (respetivamente X_2) que representa a altura, em cm, de estudantes com actividade física acima da média (respetivamente abaixo da média). Ao seleccionarem-se casualmente 20 estudantes de cada um dos grupos, obtiveram-se $\bar{x}_1 = 173$ e $\bar{x}_2 = 171$. Admita que X_1 e X_2 possuem distribuições normais com valores esperados μ_1 e μ_2 desconhecidos e desvios padrão conhecidos e iguais a $\sigma_1 = 6.4$ e $\sigma_2 = 7.2$.

- (a) Obtenha um intervalo de confiança a 95% para $\mu_1 - \mu_2$. (2.5)

• **V.a. de interesse**

X_1 = altura (em cm) de estudante com actividade física acima da média

X_2 = altura (em cm) de estudante com actividade física abaixo da média

• **Situação**

$X_i \stackrel{indep.}{\sim} \text{normal}(\mu_i, \sigma_i^2), \quad i = 1, 2$

$(\mu_1 - \mu_2)$ DESCONHECIDO

σ_1^2 e σ_2^2 conhecidas

$n_1 = n_2 = 20$

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

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

$$Z = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim \text{normal}(0, 1)$$

[dado que se pretende determinar um IC para a diferença de valores esperados de duas populações independentes com distribuições normais e com variâncias conhecidas.]

Passo 2 — Obtenção dos quantis de probabilidade

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

$$\begin{cases} a_\alpha = \Phi^{-1}(\alpha/2) = \Phi^{-1}(0.025) = -\Phi^{-1}(1 - 0.025) \stackrel{\text{tabela/calcul.}}{=} -1.9600 \\ b_\alpha = \Phi^{-1}(1 - \alpha/2) = \Phi^{-1}(0.975) \stackrel{\text{tabela/calcul.}}{=} 1.9600. \end{cases}$$

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

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

$$P\left[a_\alpha \leq \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \leq b_\alpha \right] = 1 - \alpha$$

$$P\left[(\bar{X}_1 - \bar{X}_2) - b_\alpha \times \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \leq \mu_1 - \mu_2 \leq (\bar{X}_1 - \bar{X}_2) - a_\alpha \times \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \right] = 1 - \alpha$$

Passo 4 — Concretização

Tendo em conta que

$$IC_{(1-\alpha) \times 100\%}(\mu_1 - \mu_2) = \left[(\bar{x}_1 - \bar{x}_2) \pm \Phi^{-1}(1 - \alpha/2) \times \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \right]$$

e atendendo aos valores dos quantis acima e de $n_i, \bar{x}_i, \sigma_i^2$ ($i = 1, 2$), segue-se

$$\begin{aligned} IC_{95\%}(\mu_1 - \mu_2) &= \left[(173 - 171) \pm 1.9600 \times \sqrt{\frac{6.4^2}{20} + \frac{7.2^2}{20}} \right] \\ &\simeq [2 \pm 1.9600 \times 2.15407] \\ &\simeq [-2.22197, 6.22197]. \end{aligned}$$

(b) Confronte as hipóteses $H_0 : \mu_1 - \mu_2 = 1$ e $H_1 : \mu_1 - \mu_2 > 1$, calculando para o efeito o valor-p. (3.0)

• **V.a. de interesse e situação**

Ver alínea (a).

• **Hipóteses**

$$H_0 : \mu_1 - \mu_2 = \mu_0 = 1$$

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

• **Estatística de teste**

$$T = \frac{(\bar{X}_1 - \bar{X}_2) - \mu_0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim_{H_0} \text{normal}(0, 1)$$

[uma vez que se pretende efectuar um teste sobre a diferença de valores esperados de duas populações independentes com distribuições normais e com variâncias conhecidas.]

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

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

• **Decisão (com base no valor-p)**

O valor observado da estatística de teste é igual a

$$\begin{aligned} t &= \frac{(\bar{x}_1 - \bar{x}_2) - \mu_0}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \\ &= \frac{(173 - 171) - 1}{\sqrt{\frac{6.4^2}{20} + \frac{7.2^2}{20}}} \\ &\approx \frac{1}{2.154066} \\ &\approx 0.464238 \end{aligned}$$

e a região de rejeição deste teste é um intervalo à direita. Donde

$$\begin{aligned} \text{valor-p} &= P(T > t \mid H_0) \\ &= 1 - \Phi(t) \\ &\approx 1 - \Phi(0.46) \\ &\stackrel{\text{tabela/calcul.}}{=} 1 - 0.6772 \\ &= 0.3228. \end{aligned}$$

Logo é suposto:

- não rejeitar H_0 a qualquer n.s. $\alpha_0 \leq 32.28\%$, por exemplo, a qualquer dos n.u.s. (1%, 5% e 10%);
- rejeitar H_0 a qualquer n.s. $\alpha_0 > 32.28\%$.

Grupo II

10 valores

1. Em determinado processo industrial é crucial caracterizar a variável aleatória X que representa o número de peças mecânicas inspecionadas até se encontrar uma peça defeituosa. Uma engenheira mecânica defende a hipótese H_0 de que X possui distribuição geométrica com parâmetro desconhecido p . Uma amostra aleatória de 200 contagens do número de peças mecânicas inspecionadas até se encontrar uma peça defeituosa conduziu à seguinte tabela de frequências:

Classe	1 a 4	5 a 8	9 a 12	13 a 16	17 a 20	21 ou mais
Frequência absoluta observada	7	7	10	5	8	163
Estimativa da freq. abs. esperada sob H_0	e_1	7.57	7.27	6.99	6.71	e_6

- (a) Sabendo que a estimativa de máxima verosimilhança de p é $\hat{p} \approx 0.01$, obtenha os valores das estimativas e_1 e e_6 (aproximando-as às centésimas). (1.0)

• **V.a. de interesse**

X = número de peças mecânicas inspecionadas até se encontrar uma peça defeituosa

• **Fp. conjecturada**

$P(X = x) = (1 - p)^{x-1} p$, $x = 1, 2, \dots$, onde p é uma probabilidade desconhecida.

• **Estimativas das frequências absolutas esperadas omissas**

Atendendo à dimensão da amostra $n = 200$, à f.p. conjecturada, à estimativa de MV facultada $\hat{p} \approx 0.01$ e à propriedade de invariância dos EMV, temos:

$$\begin{aligned} e_1 &= n \times P(X \leq 4 \mid p = \hat{p}) \\ &= 200 \times \sum_{i=1}^4 (1 - \hat{p})^{i-1} \hat{p} \\ &= 200 \times \hat{p} \times \frac{1 - (1 - \hat{p})^4}{1 - (1 - \hat{p})} \\ &\approx 200 \times (1 - 0.99^4) \\ &\approx 7.88; \end{aligned}$$

$$\begin{aligned}
e_5 &= n \times \hat{P}(X \geq 21) \\
&= n - \sum_{i=1}^5 e_i \\
&\approx 200 - (7.88 + 7.57 + 7.27 + 6.99 + 6.71) \\
&= 163.58.
\end{aligned}$$

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

(3.0)

• **Hipóteses**

$H_0 : X \sim \text{geométrica}(p)$ (p desconhecido)

$H_1 : X \neq \text{geométrica}(p)$

• **Nível de significância**

$\alpha_0 = 5\%$

• **Estatística de teste**

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

onde:

$k = \text{No. de classes} = 6$

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

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

$\beta = \text{No. de parâmetros a estimar} = 1$ [dado que p é uma probabilidade desconhecida.]

• **Estimativas das frequências absolutas esperadas sob H_0**

De acordo com a tabela facultada e a alínea (a), as estimativas [de MV] das frequências absolutas esperadas sob H_0 aproximadas às centésimas são: $e_1 \approx 7.88$; $e_2 \approx 7.57$; $e_3 \approx 7.27$; $e_4 \approx 6.99$; $e_5 \approx 6.71$; $e_6 \approx 163.58$.

[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 é o intervalo à direita $W = (c, +\infty)$, onde

$$\begin{aligned}
c &= F_{\chi^2_{(k-\beta-1)}^{-1}}(1 - \alpha_0) \\
&= F_{\chi^2_{(6-1-1)}^{-1}}(1 - 0.05) \\
&\stackrel{\text{tabela/calcul.}}{=} 9.488.
\end{aligned}$$

• **Decisão**

i	Classe i	Freq. abs. obs. o_i	Estim. freq. abs. esp. sob H_0 e_i	Parcelas valor obs. estat. teste $\frac{(o_i - e_i)^2}{e_i}$
1	{1, 2, 3, 4}	7	7.88	$\frac{(7-7.88)^2}{7.88} \approx 0.098$
2	{5, 6, 7, 8}	7	7.57	$\frac{(7-7.57)^2}{7.57} \approx 0.043$
3	{9, 10, 11, 12}	10	7.27	1.025
4	{13, 14, 15, 16}	5	6.99	0.567
5	{17, 18, 19, 20}	8	6.71	0.248
6	{21, 22, ...}	163	163.58	0.002
		$\sum_{i=1}^k o_i = n = 200$	$\sum_{i=1}^k e_i = n = 200$	$t = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i} \approx 1.983$

Uma vez que $t \approx 1.983 \notin W = (9.488, +\infty)$, não devemos rejeitar H_0 ao n.s. de $\alpha_0 = 5\%$ [nem a qualquer outro n.s. inferior a α_0].

2. Um conjunto de 20 medições independentes conduziu aos seguintes resultados referentes ao nível de pressão sonora de uma fonte de ruído (x , em dB) e ao aumento da tensão arterial de um indivíduo causado pela exposição a esta fonte de ruído (Y , em mm Hg):

$$\sum_{i=1}^{20} x_i = 1646, \quad \sum_{i=1}^{20} x_i^2 = 138476, \quad \sum_{i=1}^{20} y_i = 86, \quad \sum_{i=1}^{20} y_i^2 = 494, \quad \sum_{i=1}^{20} x_i y_i = 7594,$$

onde $[\min_{i=1,\dots,20} x_i, \max_{i=1,\dots,20} x_i] = [60, 100]$.

- (a) Considere o modelo de regressão linear simples de Y em x e determine a estimativa de mínimos quadrados do valor esperado do aumento da tensão arterial de um indivíduo exposto a um ruído com nível de pressão sonora de 110 dB. (2.0)

- **Estimativa de MQ de $E(Y | x) = \beta_0 + \beta_1 x$ com $x = 110$**

Dado que

$$n = 20$$

$$\sum_{i=1}^n x_i = 1646$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1646}{20} = 82.3$$

$$\sum_{i=1}^n x_i^2 = 138476$$

$$\sum_{i=1}^n x_i^2 - n(\bar{x})^2 = 138476 - 20 \times 82.3^2 = 3010.2$$

$$\sum_{i=1}^n y_i = 86$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{86}{20} = 4.3$$

$$\sum_{i=1}^n y_i^2 = 494$$

$$\sum_{i=1}^n y_i^2 - n(\bar{y})^2 = 494 - 20 \times 4.3^2 = 124.2$$

$$\sum_{i=1}^n x_i y_i = 7594$$

$$\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} = 7594 - 20 \times 82.3 \times 4.3 = 516.2,$$

as estimativas de MQ de β_1 , β_0 e $\beta_0 + \beta_1 x$ são, para este modelo de RLS, iguais a:

$$\begin{aligned} \hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n(\bar{x})^2} \\ &= \frac{516.2}{3010.2} \\ &\approx 0.171484 \end{aligned}$$

$$\begin{aligned} \hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x} \\ &\approx 4.3 - 0.171484 \times 82.3 \\ &\approx -9.813133 \end{aligned}$$

$$\begin{aligned} \hat{\beta}_0 + \hat{\beta}_1 x &\approx -9.813133 + 0.171484 \times 110 \\ &\approx 9.050107. \end{aligned}$$

- **[Comentário]**

Estamos a cometer um erro de extrapolação ao estimar pontualmente $E(Y | x) = \beta_0 + \beta_1 x$ uma vez que $x = 110 \notin [\min_{i=1,\dots,n} x_i, \max_{i=1,\dots,n} x_i] = [60, 100]$.

- (b) Após ter enunciado as hipóteses de trabalho que entender convenientes, confronte $H_0 : \beta_1 = 0.2$ e $H_1 : \beta_1 \neq 0.2$, ao nível de significância de 10%. (3.0)

- **Hipóteses de trabalho**

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

- **Hipóteses**

$$H_0 : \beta_1 = \beta_{1,0} = 0.2$$

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

- **Nível de significância**

$$\alpha_0 = 10\%$$

- **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 ($H_1 : \beta_1 \neq 0.2$), 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.,

$$\begin{aligned} c &= F_{t_{(n-2)}}^{-1}(1 - \alpha_0/2) \\ &= F_{t_{(20-2)}}^{-1}(1 - 0.10/2) \\ &= F_{t_{(18)}}^{-1}(0.95) \\ &\stackrel{\text{tabela/calc.}}{=} 1.734. \end{aligned}$$

- **Decisão**

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

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{n-2} \left[\left(\sum_{i=1}^n y_i^2 - n \bar{y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right] \\ &\approx \frac{1}{20-2} (124.2 - 0.171484^2 \times 3010.2) \\ &\approx 1.982209, \end{aligned}$$

o valor observado da estatística de teste é igual a

$$\begin{aligned} t &= \frac{\hat{\beta}_1 - \beta_{1,0}}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \\ &\approx \frac{0.171484 - 0.2}{\sqrt{\frac{1.982209}{3010.2}}} \\ &= -1.111250. \end{aligned}$$

Como $t \approx -1.111250 \notin W = (-\infty, -1.734) \cup (1.734, +\infty)$ não devemos rejeitar H_0 ao n.s. de 10% [nem a qualquer n.s. inferior a 10%].

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

(1.0)

- **Cálculo do coeficiente de determinação**

$$\begin{aligned} r^2 &= \frac{(\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y})^2}{(\sum_{i=1}^n x_i^2 - n \bar{x}^2) \times (\sum_{i=1}^n y_i^2 - n \bar{y}^2)} \\ &= \frac{516.2^2}{3010.2 \times 124.2} \\ &\approx 0.712720. \end{aligned}$$

- **Interpretação coeficiente de determinação**

Cerca de 71.3% 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 bem ao conjunto de dados.