

Duração: 60+15 minutos

Teste 2C

Justifique convenientemente todas as respostas

Pergunta 1

4 valores

Considere a variável aleatória X , que representa o número de nascimentos por hora em determinado hospital e que se admite ter uma distribuição de Poisson de parâmetro $\lambda > 0$ (desconhecido).

Seja (X_1, \dots, X_n) uma amostra aleatória de dimensão n proveniente de X e denote-se por \bar{X} a média da amostra aleatória. Sabe-se que $T = \bar{X}(1 + \bar{X})$ é um estimador enviesado de $E(X^2)$.

Calcule o valor do enviesamento de T na estimação de $E(X^2)$, quando $n = 19$ e $\lambda = 1.4$.

• **V.a. de interesse**

X = número de nascimentos por hora durante um dia em determinado hospital

$X \sim \text{Poisson}(\lambda)$

$E(X) = V(X) = \lambda$ DESCONHECIDO

Outro parâmetro desconhecido

$E(X^2) = V(X) + E^2(X) = \lambda + \lambda^2 = \lambda(1 + \lambda)$, $\lambda > 0$

• **Estimador de $E(X^2)$**

$T = \bar{X}(1 + \bar{X})$

• **Valor esperado de T**

Ao notarmos que $E(\bar{X}) = E(X) = \lambda$, $V(\bar{X}) = \frac{V(X)}{n} = \frac{\lambda}{n}$, segue-se, para qualquer $\lambda > 0$,

$$\begin{aligned} E(T) &= E[\bar{X}(1 + \bar{X})] \\ &= E(\bar{X}) + E(\bar{X}^2) \\ &= E(\bar{X}) + [V(\bar{X}) + E^2(\bar{X})] \\ &= \lambda + \left(\frac{\lambda}{n} + \lambda^2 \right) \\ &= \lambda(1 + \lambda) + \frac{\lambda}{n}. \end{aligned}$$

[Uma vez que $E(T) \neq \lambda(1 + \lambda)$, $\forall \lambda > 0$, T é, efectivamente, um estimador enviesado de λ .]

• **Enviesamento de T**

$$\begin{aligned} E(T) - E(X^2) &= \left[\lambda(1 + \lambda) + \frac{\lambda}{n} \right] - \lambda(1 + \lambda) \\ &= \frac{\lambda}{n} \\ &= \frac{1.4}{19} \\ &\approx 0.073684. \end{aligned}$$

Pergunta 2

4 valores

Admita que X_1 (resp. X_2) representa a idade de um indivíduo que teve pelo menos um evento coronário em 2020 (resp. em 2019). Para estimar a diferença de idades esperadas entre doentes coronários em 2020 e 2019,

$\mu_1 - \mu_2$, foram recolhidas duas amostras independentes com dimensões $n_1 = 7$ e $n_2 = 14$ (respetivamente), tendo-se obtido os seguintes resultados: $\bar{x}_1 = 51$ e $s_1 = 0.8$; $\bar{x}_2 = 49$ e $s_2 = 0.6$.

Suponha que X_1 e X_2 são variáveis aleatórias normalmente distribuídas com variâncias desconhecidas mas iguais. Obtenha um intervalo de confiança a 95% para $\mu_1 - \mu_2$.

- **V.a. de interesse**

X_1 = idade de um indivíduo que teve pelo menos um evento coronário em 2020

X_2 = idade de um indivíduo que teve pelo menos um evento coronário em 2019

- **Situação**

X_1 e X_2 v.a. independentes com distribuições normais

$(\mu_1 - \mu_2)$ DESCONHECIDO

σ_1^2 e σ_2^2 desconhecidas mas iguais

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

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

$$Z = \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2} \times \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \sim t_{(n_1+n_2-2)}$$

Passo 2 — Obtenção dos quantis de probabilidade

Uma vez que $(1 - \alpha) \times 100\% = 95\%$ e $n_1 = 7$ e $n_2 = 14$, temos $\alpha = 0.05$ e

$$\begin{cases} a_\alpha = F_{t_{(n_1+n_2-2)}}^{-1}\left(\frac{\alpha}{2}\right) = -F_{t_{(19)}}^{-1}(0.975) \stackrel{\text{tabelas, calc.}}{=} -2.093 \\ b_\alpha = F_{t_{(n_1+n_2-2)}}^{-1}\left(1 - \frac{\alpha}{2}\right) = F_{t_{(19)}}^{-1}(0.975) \stackrel{\text{tabelas, calc.}}{=} 2.093 \end{cases}$$

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

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

$$P\left(a_\alpha \leq \frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2} \times \left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \leq b_\alpha\right) = 1 - \alpha$$

$$\begin{aligned} P\left[(\bar{X}_1 - \bar{X}_2) - F_{t_{(n_1+n_2-2)}}^{-1}(1 - \alpha/2) \times \sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2} \times \left(\frac{1}{n_1} + \frac{1}{n_2}\right)} \leq \mu_1 - \mu_2 \right. \\ \left. \leq (\bar{X}_1 - \bar{X}_2) + F_{t_{(n_1+n_2-2)}}^{-1}(1 - \alpha/2) \times \sqrt{\frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2} \times \left(\frac{1}{n_1} + \frac{1}{n_2}\right)} \right] = 1 - \alpha \end{aligned}$$

Passo 4 — Concretização

Tendo em conta os quantis acima, as dimensões amostrais n_1 e n_2 , bem como as concretizações de \bar{X}_1 , \bar{X}_2 , S_1^2 e S_2^2 e a expressão geral do IC,

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

segue-se

$$\begin{aligned}
IC_{95\%}(\mu_1 - \mu_2) &= \left[(51 - 49) \pm 2.093 \times \sqrt{\frac{(7-1) \times 0.8^2 + (14-1) \times 0.6^2}{7+14-2}} \times \left(\frac{1}{7} + \frac{1}{14} \right) \right] \\
&= [2 \pm 2.093 \times 0.309984] \\
&= [1.3512, 2.6488].
\end{aligned}$$

Pergunta 3

4 valores

Uma engenheira biomédica conjectura que o número esperado de mutações em determinadas regiões de um cromossoma é igual a $\lambda_0 = 101$. Considere que o número X dessas mutações segue uma distribuição de Poisson.

Supondo que entre $n = 78$ cromossomas observados se identificaram 8255 mutações, teste a conjectura da engenheira biomédica contra a alternativa $H_1 : E(X) \neq \lambda_0$. Decida com base no valor-p aproximado.

- **V.a. de interesse**

X = número de mutações em determinadas regiões de um cromossoma

- **Situação**

$X \sim \text{Poisson}(\lambda)$

λ DESCONHECIDO

- **Hipóteses**

$H_0 : \lambda = \lambda_0 = 101$

$H_1 : \lambda \neq \lambda_0$

- **Estatística de teste**

$$T = \frac{\bar{X} - \lambda_0}{\sqrt{\frac{\lambda_0}{n}}} \underset{H_0}{\sim} \text{normal}(0, 1)$$

- **Região de rejeição de H_0**

Teste bilateral ($H_1 : \lambda \neq \lambda_0$), logo a região de rejeição de H_0 é do tipo $W = (-\infty, -c) \cup (c, +\infty)$.

- **Decisão (com base no valor-p)**

O valor observado da estatística de teste é igual a

$$\begin{aligned}
t &= \frac{\frac{8255}{78} - 101}{\sqrt{\frac{101}{78}}} \\
&\approx 4.2475
\end{aligned}$$

e

$$\begin{aligned}
\text{valor-p} &= 2 \times P(|T| > |t| \mid H_0) \\
&\approx 2 \times [1 - \Phi(|t|)] \\
&\approx 2 \times [1 - \Phi(4.2475)] \\
&\approx 2 \times [1 - \Phi(4.25)],
\end{aligned}$$

onde $\Phi(4.25) > \Phi(4.09) \stackrel{\text{tabelas, calc}}{=} 0.999978$. Consequentemente,

$$\begin{aligned} \text{valor} - p &\simeq 2 \times [1 - \Phi(4.25)] \\ &< 2 \times (1 - 0.999978) \\ &= 0.000044, \end{aligned}$$

pelo que devemos rejeitar H_0 a qualquer n.s. $\alpha_0 > 0.0044\%$, designadamente a qualquer dos n.u.s. (1%, 5%, 10%).

[Alternativamente e usando uma calculadora, conclui-se que $\text{valor} - p \simeq 2 \times [1 - \Phi(4.2475)] \simeq 0.0000216169$, pelo que:

- não devemos rejeitar H_0 a qualquer n.s. $\alpha_0 \leq 0.00216169\%$;
- devemos rejeitar H_0 a qualquer n.s. $\alpha_0 > 0.00216169\%$, nomeadamente a qualquer dos n.u.s. (1%, 5%, 10%).]

Pergunta 4

4 valores

Seja X a massa (em gramas) de um carapau médio. Uma bióloga defende a hipótese H_0 de esta variável aleatória ter distribuição normal com valor esperado e desvio padrão iguais a 100 e 31 gramas (respetivamente). Numa amostra casual de 200 desses peixes, foram registadas as seguintes frequências por intervalos de massa:

Intervalo de massa	≤ 60]60, 80]]80, 120]]120, 140]	> 140
Frequência absoluta observada	20	26	96	33	25
Frequência absoluta esperada sob H_0	E_1	32.2	96.2	32.2	E_5

Calcule as frequências absolutas esperadas sob H_0 omissas E_1 e E_5 (aproximando-as às décimas). Serão os dados consistentes com H_0 ? Decida com base no valor-p aproximado.

- **V.a. de interesse**

X = massa (em gramas) de um carapau médio

- **Hipóteses**

$H_0 : X \sim \text{normal}(\mu = 100, \sigma^2 = 31^2)$

$H_1 : X \not\sim \text{normal}(\mu = 100, \sigma^2 = 31^2)$

- **Estatística de teste**

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

onde:

- k = no. de classes = 5;
- O_i = freq. abs. observável da classe i ;
- E_i = freq. abs. esperada sob H_0 da classe i ;
- $\beta = 0$.

• **Frequência esperadas sob H_0 omissas**

$$\begin{aligned}
 E_1 &= n \times P(X \leq 60 | H_0) \\
 &= 200 \times \Phi\left(\frac{60 - 100}{31}\right) \\
 &\approx 200 \times \Phi(-1.29) \\
 &\stackrel{\text{tabelas, calc.}}{=} 200 \times (1 - 0.9015) \\
 &= 19.7 \\
 E_5 &= n - \sum_{i=1}^4 E_i \\
 &\approx 200 - (19.7 + 32.2 + 96.2 + 32.2) \\
 &= 19.7.
 \end{aligned}$$

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

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

• **Decisão (com base no valor-p)**

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	≤ 60	20	19.7	$\frac{(20 - 19.7)^2}{19.7} = 0.0046$
2	$]60, 80]$	26	32.2	1.1938
3	$]80, 120]$	96	96.2	0.0004
4	$]120, 140]$	33	32.2	0.0199
5	> 140	25	19.7	1.4259
		$\sum_{i=1}^k o_i = n$ = 200	$\sum_{i=1}^k e_i = n$ = 200	$t = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$ ≈ 2.6445

Dado que o valor observado da estatística de teste é $t = \sum_{i=1}^k \frac{(o_i - E_i)^2}{E_i} \approx 2.6445$ e $W = (c, +\infty)$, obtemos

$$\begin{aligned}
 \text{valor-p} &= P(T > t | H_0) \\
 &\approx 1 - F_{\chi_{(k-1)}^2}(t) \\
 &= 1 - F_{\chi_{(4)}^2}(2.6445) \\
 &\approx 0.618954
 \end{aligned}$$

e devemos

- não rejeitar de H_0 a qualquer n.s. $\alpha_0 \leq \text{valor-p} = 61.8954\%$, designadamente aos n.u.s. (1%, 5%, 10%);
- rejeitar de H_0 a qualquer n.s. $\alpha_0 > \text{valor-p} = 61.8954\%$.

Alternativamente e recorrendo às tabelas de quantis da distribuição do qui-quadrado, podemos obter um intervalo para o valor-p deste teste:

$$\begin{aligned}
 F_{\chi_{(4)}^2}^{-1}(0.30) = 2.195 &< t = 2.6445 < 2.753 = F_{\chi_{(4)}^2}^{-1}(0.40) \\
 0.30 &< F_{\chi_{(4)}^2}(2.6445) < 0.40 \\
 0.60 = 1 - 0.40 &< \text{valor-p} \approx 1 - F_{\chi_{(4)}^2}(2.6445) < 1 - 0.30 = 0.70.
 \end{aligned}$$

Logo:

- não devemos rejeitar H_0 a qualquer n.s. $\alpha_0 \leq 60\%$, nomeadamente aos n.u.s. (1%, 5%, 10%);
- devemos rejeitar H_0 a qualquer n.s. $\alpha_0 \geq 70\%$.

Pergunta 5

4 valores

Os dados relativos à produção de trigo (x , em toneladas) e ao preço do quilo de farinha de trigo (Y , em cêntimos de euro) em 7 anos consecutivos conduziram a

$$\sum_{i=1}^7 x_i = 34, \quad \sum_{i=1}^7 x_i^2 = 190, \quad \sum_{i=1}^7 y_i = 440, \quad \sum_{i=1}^7 y_i^2 = 30\,150, \quad \sum_{i=1}^7 x_i y_i = 2\,365.$$

Admita que as variáveis x e Y estão relacionadas de acordo com o modelo de regressão linear simples: $Y = \beta_0 + \beta_1 x + \varepsilon$.

Após ter enunciado as hipóteses de trabalho que entender convenientes, obtenha um intervalo de confiança a 95% para β_1 e a amplitude deste intervalo de confiança, tirando partido dos resultados acima.

• **Modelo de RLS**

Y = preço do quilo de farinha (v.a. resposta)

x = produção de trigo (variável explicativa)

$$Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \quad i = 1, \dots, n$$

• **Hipóteses de trabalho**

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

• **Estimativas de MV de β_0 e β_1 ; estimativa de σ^2**

Importa notar que

- o $n = 7$
- o $\sum_{i=1}^n x_i = 34$
 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{34}{7} \approx 4.857143$
 $\sum_{i=1}^n x_i^2 = 190$
 $\sum_{i=1}^n x_i^2 - n \bar{x}^2 \approx 190 - 7 \times 4.857143^2 \approx 24.857133$
- o $\sum_{i=1}^n y_i = 440$
 $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{440}{7} \approx 62.857143$
 $\sum_{i=1}^n y_i^2 = 30\,150$
 $\sum_{i=1}^n y_i^2 - n \bar{y}^2 = 30\,150 - 7 \times 62.857143^2 \approx 2492.857143$
- o $\sum_{i=1}^n x_i y_i = 2\,365$
 $\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} \approx 2\,365 - 7 \times 4.857143 \times 62.857143 \approx 227.857075$

Logo,

$$\begin{aligned} \hat{\beta}_1 &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \\ &\approx \frac{227.857075}{24.857133} \\ &\approx 9.166668 \end{aligned}$$

$$\begin{aligned}
\hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x} \\
&\approx 62.857143 - 9.166668 \times 4.857143 \\
&\approx 18.333326 \\
\hat{\sigma}^2 &= \frac{1}{n-2} \left[\left(\sum_{i=1}^n y_i^2 - n \bar{y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right] \\
&\approx \frac{1}{7-2} (2492.857017 - 9.166668^2 \times 24.857133) \\
&\approx 80.833352.
\end{aligned}$$

• **Obtenção do IC para β_1**

Passo 1 — Seleção da v.a. fulcral

$$Z = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \sim t_{(n-2)}$$

Passo 2 — Obtenção dos quantis de probabilidade

$$\begin{cases} a_\alpha = F_{t_{(n-2)}}(\alpha/2) = -F_{t_{(7-2)}}(1 - 0.05/2) = -F_{t_{(5)}}(0.975) \stackrel{\text{tabelas, calc.}}{=} -2.571 \\ b_\alpha = F_{t_{(n-2)}}(1 - \alpha/2) = F_{t_{(7-2)}}(1 - 0.05/2) = F_{t_{(5)}}(0.975) \stackrel{\text{tabelas, calc.}}{=} 2.571 \end{cases}$$

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

$$\begin{aligned}
P(a_\alpha \leq Z \leq b_\alpha) &= 1 - \alpha \\
P \left[a_\alpha \leq \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \leq b_\alpha \right] &= 1 - \alpha \\
P \left[\hat{\beta}_1 - b_\alpha \times \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}} \leq \beta_1 \leq \hat{\beta}_1 - a_\alpha \times \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}} \right] &= 1 - \alpha
\end{aligned}$$

Passo 4 — Concretização

Tendo em conta a expressão geral do IC para β_1 ,

$$IC_{(1-\alpha) \times 100\%}(\beta_1) = \left[\hat{\beta}_1 \pm F_{t_{(n-2)}}^{-1}(1 - \alpha/2) \times \sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}} \right],$$

e os resultados anteriores, o IC pretendido e a sua amplitude são iguais a

$$\begin{aligned}
IC_{95\%}(\beta_1) &\approx \left[9.166668 \pm 2.571 \times \sqrt{\frac{80.833352}{24.857133}} \right] \\
&\approx [9.166668 \pm 2.571 \times 1.803307] \\
&\approx [4.530365, 13.802971]
\end{aligned}$$

$$13.802971 - 4.530365 \approx 9.27261.$$