

Duração: 60+15 minutos

Teste 2C

Justifique convenientemente todas as respostas

Pergunta 1

4 valores

(4.0)

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 $n = a$ e $\lambda = b$.

• **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

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

• **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**

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

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 e n_2 (respetivamente), tendo-se obtido os seguintes resultados: $\bar{x}_1 = \bar{x}_1$ e $s_1 = s_1$; $\bar{x}_2 = \bar{x}_2$ e $s_2 = s_2$.

Suponha que X_1 e X_2 são variáveis aleatórias normalmente distribuídas com variâncias desconhecidas mas iguais.

Obtenha um intervalo de confiança a $100 \times (1 - \alpha)\%$ 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

$$\begin{cases} a_\alpha = F_{t_{(n_1+n_2-2)}}^{-1}\left(\frac{\alpha}{2}\right) = -F_{t_{(n_1+n_2-2)}}^{-1}\left(1 - \frac{\alpha}{2}\right) \\ b_\alpha = F_{t_{(n_1+n_2-2)}}^{-1}\left(1 - \frac{\alpha}{2}\right) \end{cases}$$

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

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

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

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

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 , temos

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

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

Supondo que entre n cromossomas observados se identificaram b 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**

$H_0 : \lambda = \lambda_0$

$H_1 : \lambda \neq \lambda_0$

- **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)**

Atendendo a que o valor observado da estatística de teste é igual a

$$t = \frac{\frac{b}{n} - \lambda_0}{\sqrt{\frac{\lambda_0}{n}}}$$

e

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

devemos

- não rejeitar H_0 a qualquer n.s. $\alpha_0 \leq \text{valor-p}$;
- rejeitar H_0 a qualquer n.s. $\alpha_0 > \text{valor-p}$.

| | |
|-------------------|-----------|
| 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 σ gramas (respetivamente). Numa amostra casual de n 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 | o_1 | o_2 | o_3 | o_4 | o_5 |
| Frequência absoluta esperada sob H_0 | E_1 | E_2 | E_3 | E_4 | 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**

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

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

• **Estatística de teste**

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

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**

$$\begin{aligned} E_1 &= n \times P(X \leq 60 | H_0) \\ &= n \times \Phi\left(\frac{60 - 100}{\sigma}\right) \end{aligned}$$

$$E_5 = n - \sum_{i=1}^4 E_i.$$

• **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)**

| | Classe i | Freq. abs. obs. | Freq. abs. esp. sob H_0 | Parcelas valor obs. estat. teste |
|-----|--------------|---------------------------------|---------------------------------|---|
| i | | o_i | E_i | $\frac{(o_i - e_i)^2}{e_i}$ |
| 1 | ≤ 60 | o_1 | E_1 | $\frac{(o_1 - E_1)^2}{E_1} =$ |
| 2 | $]60, 80]$ | o_2 | E_2 | |
| 3 | $]80, 120]$ | o_3 | E_3 | |
| 4 | $]120, 140]$ | o_4 | E_4 | |
| 5 | > 140 | o_5 | E_5 | |
| | | $\sum_{i=1}^k o_i = n$ $= n$ | $\sum_{i=1}^k e_i = n$ $= n$ | $t = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$ $=$ |

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

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

e devemos

- não rejeitar de H_0 a qualquer n.s. $\alpha_0 \leq \text{valor} - p$;
- rejeitar de H_0 a qualquer n.s. $\alpha_0 > \text{valor} - p$.

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

$$\begin{aligned} F_{\chi_{(k-1)}^2}^{-1}(p_1) &= < t = \dots < = F_{\chi_{(k-1)}^2}^{-1}(p_2) \\ p_1 &< F_{\chi_{(k-1)}^2}(t) < p_2 \\ 1 - p_2 &< \text{valor} - p \approx 1 - F_{\chi_{(k-1)}^2}(t) < 1 - p_1. \end{aligned}$$

Assim, podemos adiantar que:

- não devemos rejeitar H_0 a qualquer n.s. $\alpha_0 \leq (1 - p_2) \times 100\%$;
- devemos rejeitar H_0 a qualquer n.s. $\alpha_0 \geq (1 - p_1) \times 100\%$.

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 centímetros de euro) em 7 anos consecutivos conduziram a

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

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 $100 \times (1 - \alpha)\%$ 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 $\sum_{i=1}^n x_i = \sum_{i=1}^n x_i$
 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} \sum_{i=1}^n x_i$
 $\sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i^2$
 $\sum_{i=1}^n x_i^2 - n \bar{x}^2 = \sum_{i=1}^n x_i^2 - n \left(\frac{1}{n} \sum_{i=1}^n x_i \right)^2$
- o $\sum_{i=1}^n y_i = 440$
 $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{440}{7} \approx 62.857143$

$$\sum_{i=1}^n y_i^2 = 30150$$

$$\sum_{i=1}^n y_i^2 - n \bar{y}^2 = 30150 - 7 \times 62.857143^2 \approx 2492.857143$$

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

$$\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} = \sum_{i=1}^n x_i y_i - 7 \times \left(\frac{1}{n} \sum_{i=1}^n x_i \right) \times 62.857143.$$

Logo,

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

$$\begin{aligned} \hat{\beta}_0 &= \bar{y} - \hat{\beta}_1 \bar{x} \\ &= 62.857143 - \hat{\beta}_1 \times \left(\frac{1}{n} \sum_{i=1}^n x_i \right) \end{aligned}$$

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{n-2} \left[\left(\sum_{i=1}^n y_i^2 - n \bar{y}^2 \right) - (\hat{\beta}_1)^2 \left(\sum_{i=1}^n x_i^2 - n \bar{x}^2 \right) \right] \\ &\approx \frac{1}{7-2} \left\{ 2492.857017 - (\hat{\beta}_1)^2 \left[\sum_{i=1}^n x_i^2 - n \left(\frac{1}{n} \sum_{i=1}^n x_i \right)^2 \right] \right\} \end{aligned}$$

- **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

$$\begin{cases} a_\alpha = F_{t_{(n-2)}}(\alpha/2) = -F_{t_{(7-2)}}(1 - \alpha/2) \\ b_\alpha = F_{t_{(n-2)}}(1 - \alpha/2) \end{cases}$$

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

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

$$P \left[a_\alpha \leq \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}}} \leq b_\alpha \right] = 1 - \alpha$$

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

Passo 4 — Concretização

Tendo em conta a expressão geral do IC para β_1 , o IC pretendido e a sua amplitude são iguais a

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