

Duração: 90 minutos

2º teste B

Justifique convenientemente todas as respostas!

Grupo I

10 valores

1. Seja $\mathbf{X} = (X_1, \dots, X_n)$, com $n > 2$, uma amostra aleatória de uma população com função de probabilidade

$$P(X = x) = (x-1)p^2(1-p)^{x-2}, \quad 0 < p \leq 1 \text{ e } x \in \{2, 3, \dots\}$$

em que $E[X] = \frac{2}{p}$ e $Var[X] = \frac{2(1-p)}{p^2}$.

(a) Determine o estimador de máxima verosimilhança do parâmetro p .

(3.0)

$$\begin{aligned} \mathcal{L}(p, x_1, \dots, x_n) &\equiv f_{\mathbf{X}}(x_1, \dots, x_n) \stackrel{iid}{=} \prod_{i=1}^n f_X(x_i) = \prod_{i=1}^n (x_i - 1)p^2(1-p)^{x_i-2} = \\ &= p^{2n}(1-p)^{\sum_{i=1}^n x_i - 2n} \prod_{i=1}^n (x_i - 1) \end{aligned}$$

Para $p \in]0, 1[$, $\log \mathcal{L}(p, x_1, \dots, x_n) = 2n \log p + (\sum_{i=1}^n x_i - 2n) \log(1-p) + \sum_{i=1}^n \log(x_i - 1)$ (diferenciável em ordem a p)

$$\frac{d\mathcal{L}}{dp} = 0 \iff \frac{2n}{p} - \frac{\sum_{i=1}^n x_i - 2n}{1-p} = 0 \iff p = \frac{2}{\bar{x}} \text{ e}$$

$$\frac{d^2\mathcal{L}}{dp^2} = -\frac{2n}{p^2} - \frac{\sum_{i=1}^n x_i - 2n}{(1-p)^2} < 0, \quad \forall 0 < p < 1 \text{ uma vez que } \sum_{i=1}^n x_i \geq 2n$$

$$\therefore \hat{p}_{MV} = \frac{2}{\bar{X}}$$

(b) Tendo em vista a estimação do valor esperado de X , compare a eficiência do estimador \bar{X} relativamente ao estimador $T = \frac{X_1 + X_n}{2}$.

(1.5)

$$E[\bar{X}] = E\left[\frac{\sum_{i=1}^n X_i}{n}\right] = \frac{\sum_{i=1}^n E[X_i]}{n} = E[X] = \frac{2}{p}$$

$$Var[\bar{X}] = Var\left[\frac{\sum_{i=1}^n X_i}{n}\right] = \frac{\sum_{i=1}^n Var[X_i]}{n^2} = \frac{Var[X]}{n} = \frac{2(1-p)}{np^2}$$

$$E[T] = E\left[\frac{X_1 + X_n}{2}\right] = \frac{E[X_1] + E[X_n]}{2} = E[X] = \frac{2}{p}$$

$$Var[T] = Var\left[\frac{X_1 + X_n}{2}\right] = \frac{Var[X_1] + Var[X_n]}{4} = \frac{Var[X]}{2} = \frac{(1-p)}{p^2}$$

$$\frac{EQM[T]}{EQM[\bar{X}]} = \frac{Var[T] + (E[T] - 2/p)^2}{Var[\bar{X}] + (E[\bar{X}] - 2/p)^2} = \frac{n}{2} > 1, \text{ uma vez que } n > 2.$$

$\therefore \bar{X}$ é um estimador de $E[X] = \frac{2}{p}$ mais eficiente que T .

2. Uma dada exploração leiteira tem por objetivo ter uma produção média diária de leite por vaca de 29 Kg. Sabe-se que a produção diária de leite por vaca é modelada por uma distribuição normal com variância igual a 2.25 Kg^2 . Para analisar a produção média de leite por vaca nessa exploração, recolheu-se a produção diária de 12 vacas que conduziu a uma média por vaca de 28.0 Kg.

(a) Com base na amostra recolhida, obtenha um intervalo de confiança a 99% para o valor esperado da produção diária de leite por vaca.

(3.0)

Sejam $Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0, 1)$ e $a = \Phi^{-1}(0.995) \approx 2.5758$.

$$P(-a \leq Z \leq a) = 0.99 \iff P\left(\bar{X} - a \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + a \frac{\sigma}{\sqrt{n}}\right) = 0.99$$

$$IAC_{0.99}(\mu) = \left[\bar{X} - a \frac{\sigma}{\sqrt{n}}, \bar{X} + a \frac{\sigma}{\sqrt{n}}\right] \implies IC_{0.99}(\mu) = [26.8847, 29.1154]$$

(b) Teste ao nível de significância de 1% se o valor esperado da produção diária de leite por vaca é 29 Kg. O que pode concluir relativamente à satisfação do objetivo de a produção média diária de leite por vaca nessa exploração leiteira ser 29 Kg?

(2.5)

Testar $H_0 : \mu = 29$ contra $H_1 : \mu \neq 29$ a um nível de significância α é equivalente a avaliar se $29 \in IC_{(1-\alpha)}(\mu)$. Uma vez que o valor 29 pertence ao intervalo de confiança determinado em (a) então não se deve rejeitar H_0 a um nível de significância de 0.01. Conclui-se assim, a esse nível de significância, que os dados não permitem afirmar que o objetivo pretendido não foi atingido.

1. Num estudo realizado pela autoridade de segurança rodoviária foram registados para os dias úteis da semana os seguintes dados: (4.0)

Dia da semana	segunda	terça	quarta	quinta	sexta	TOTAL
Nº de acidentes	87	75	81	66	91	400

Teste a hipótese de os acidentes se distribuírem uniformemente pelos vários dias úteis da semana. Decida com base no valor-p.

Numerando os dias úteis da semana de 1 a 5, seja $X = \text{“dia da semana em que ocorre um acidente rodoviário”}$. Pretende-se testar $H_0 : X \sim U(\{1, \dots, 5\})$ contra $H_1 : X \neq U(\{1, \dots, 5\})$.

Seja $p_i^0 = P(X = i | H_0) = 1/5, i = 1, \dots, 5$.

i	o_i	p_i^0	$e_i = np_i^0$
1	87	0.2	80
2	75	0.2	80
3	81	0.2	80
4	66	0.2	80
5	91	0.2	80
$n = 400$			

Como todas as classes têm uma frequência esperada superior a 5 não é necessário agrupar classes ($k = 5$) e, não havendo qualquer parâmetro estimado ($\beta = 0$), a estatística de teste é $Q_0 = \sum_{i=1}^5 \frac{(O_i - E_i)^2}{E_i} \underset{H_0}{\approx} \chi_{(4)}^2$.

Tem-se $q_0 \approx 4.9$ e valor-p = $P(Q_0 > q_0 | H_0) = 1 - F_{\chi_{(4)}^2}(4.9) \approx 0.298$. Deve-se rejeitar H_0 para níveis de significância ≥ 0.298 e não rejeitar no caso contrário. Para os níveis de significância usuais os dados não fornecem evidência para a rejeição de H_0 .

2. Para testar um instrumento que mede a concentração de ácido láctico no sangue foram utilizadas 16 amostras sanguíneas para as quais se conhece essa concentração e registou-se o valor da concentração fornecido pelo instrumento. Seja x a concentração conhecida de ácido láctico e Y a concentração de ácido láctico medida pelo instrumento. Admitindo a validade do modelo de regressão linear simples, foram calculadas as seguintes estatísticas, incluindo estimativas de mínimos quadrados de parâmetros do modelo de regressão:

$$\sum_{i=1}^{16} x_i = 117, \sum_{i=1}^{16} x_i^2 = 1305, \sum_{i=1}^{16} y_i = 147.1, \sum_{i=1}^{16} y_i^2 = 2045.75, \hat{\beta}_1 = 1.22, \hat{\sigma} = 1.18$$

- (a) Obtenha a estimativa pontual para o incremento no valor esperado fornecido pelo instrumento para a concentração de ácido láctico no sangue provocada pelo aumento de 5 unidades da concentração conhecida. (1.0)

Pretende-se estimar $\delta = E[Y | x + 5] - E[Y | x] = \beta_0 + \beta_1(x + 5) - (\beta_0 + \beta_1 x) = 5\beta_1$. Como $\hat{\beta}_1 = 1.22$ tem-se $\hat{\delta} = 6.1$.

- (b) Indicando hipóteses de trabalho convenientes, teste a significância do modelo de regressão linear ao nível de significância de 5%. (3.0)

Admitindo que $Y_i | x_i \stackrel{ind}{\sim} N(\beta_0 + \beta_1 x_i, \sigma^2), i = 1, \dots, 16$, quer-se testar $H_0 : \beta_1 = 0$ contra $H_1 : \beta_1 \neq 0$.

Seja $T = \frac{\hat{\beta}_1 - \beta_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^{16} x_i^2 - 16\bar{x}^2}}} \sim t_{(14)}$. Sob H_0 , tem-se a estatística de teste $T_0 = \frac{\hat{\beta}_1}{\sqrt{\frac{\hat{\sigma}^2}{\sum_{i=1}^{16} x_i^2 - 16\bar{x}^2}}} \sim t_{(14)}$.

Para o nível de significância de 0.05 deve-se rejeitar H_0 se $|T_0| > a$ em que $a = F_{t_{(18)}}^{-1}(0.975) \approx 2.1448$. Como $t_0 \approx 21.92$ rejeita-se H_0 para o nível de significância de 0.05, ou seja, os dados não permitem afirmar que x não influencia Y sob o modelo de regressão adotado.

- (c) Tirando partido da relação entre o coeficiente de determinação e a estimativa de mínimos quadrados de β_1 , calcule o coeficiente de determinação e interprete o valor obtido. (2.0)

$$R^2 = \frac{\left(\sum_{i=1}^n x_i y_i - n\bar{x}\bar{y}\right)^2}{\left(\sum_{i=1}^n x_i^2 - n\bar{x}^2\right) \times \left(\sum_{i=1}^n y_i^2 - n\bar{y}^2\right)} = \hat{\beta}_1^2 \frac{\sum_{i=1}^n x_i^2 - n\bar{x}^2}{\sum_{i=1}^n y_i^2 - n\bar{y}^2} \approx 0.965.$$

Conclui-se que 96.5% da variabilidade observada nas medições efetuadas é explicada pelo MRLS o que evidencia o bom ajustamento desse modelo aos dados.