

**Atenção:** Não serão aceitas respostas sem justificativa. As soluções devem ser feitas nos espaços apropriados.

1. Túlio está vendendo cartelas de rifa com o objetivo de juntar dinheiro para comprar um vídeo-game que custa R\$ 1.200,00. Cada cartela de rifa tem um preço aleatório, definido por raspadinhas no corpo da cartela. Em média, compradores pagam R\$ 50,00 com desvio padrão de R\$ 10,00.
  - (a) Túlio vendeu 25 cartelas. Qual é a probabilidade de ele ter conseguido uma quantia suficiente para fazer a compra que deseja?
  - (b) Quantas cartelas Túlio precisaria vender para conseguir recursos suficientes para essa compra com 50% de probabilidade?

Obs.: Admita que, em ambos os casos, o tamanho amostral é suficientemente grande para que seja válida a aproximação fornecida pelo Teorema Central do Limite.

2. Cinco pessoas estão almoçando juntas. Os nomes dessas pessoas, ordenando-as em termos de idade (do mais novo para o mais velho), são: Paulo, Andrea, Jorge, Daniela e Vitor. Com base em suas idades, foram calculadas as seguintes medidas: Média = 21, Mediana = 25, Distância Interquartil = 10, Amplitude = 30 (todas elas expressas em anos) e Variância = 146 anos<sup>2</sup>.
  - (a) Quais são as idades de cada um deles?
  - (b) Alguma dessas cinco observações pode ser considerada discrepante, pelo critério para identificação de outliers que se baseia nos quartis da variável? Qual?

Obs.: Amplitude = (Maior valor) – (Menor valor).

3. Um administrador do governo quer avaliar a proporção  $p$  de aprovação da comunidade sobre determinado projeto. Para isso fez uma pesquisa de opinião selecionando ao acaso 40 pessoas da população de interesse. Considerando “1” = favorável e “0” = desfavorável, temos então 40 variáveis aleatórias iid  $X_1, X_2, \dots, X_{40}$ , todas elas com distribuição de Bernoulli( $p$ ). Considere as quatro seguintes alternativas de estimador para  $p$ :

$$\hat{p}_A = \frac{X_{10} + X_{20} + X_{30} + X_{40}}{4}, \quad \hat{p}_B = \frac{X_{10} + 2X_{20} + 3X_{30} + 4X_{40}}{10}, \quad \hat{p}_C = \frac{\sum_{i=1}^{40} X_i}{40} \quad e$$

$$\hat{p}_D = \frac{\sum_{i=1}^{10} X_i + 2 \cdot \sum_{i=11}^{20} X_i + 3 \cdot \sum_{i=21}^{30} X_i + 4 \cdot \sum_{i=31}^{40} X_i}{100}$$

- (a) Qual é o viés (ou vício) de cada um desses estimadores?
- (b) Expresse o erro quadrático médio (EQM) de cada um deles em função de  $p$ . Ordene esses estimadores em termos de seus EQM, e diga qual é o melhor de acordo com esse critério.
- (c) Se os dados coletados foram:

10001 11111 10111 11110 11000 11111 11111 11100,

qual é a estimativa de  $p$  para cada uma das quatro alternativas?

4. Um disparador de partículas realiza o lançamento de partículas idênticas e o tempo com que essas partículas percorrem uma certa distância é normalmente distribuído com média e variância desconhecidas. Com objetivo de estudar propriedades desse disparador, foram lançadas 25 partículas e foi computado o tempo, em segundos, que cada uma delas levou para percorrer uma distância  $D$ . Esses dados seguem abaixo:

9, 12, 13, 15, 15, 17, 18, 18, 18, 19, 19, 20, 20, 21, 22, 24, 24, 24, 25, 26, 26, 27, 29, 31, 33

Denotando por  $x_i$  as medições acima, temos:  $\sum_{i=1}^{25} x_i = 525$      $\sum_{i=1}^{25} x_i^2 = 11877$

- (a) Construa um intervalo de 95% de confiança para o tempo médio com que as partículas lançadas percorrem essa distância  $D$ . Interprete o significado do intervalo obtido.
- (b) Um físico afirmou que o tempo médio necessário para as partículas disparadas percorrerem uma distância  $D$ , como essa, é de no máximo 18 segundos. Utilizando o conceito de p-valor, verifique se a afirmação  $H_0$  do físico será contestada ao nível de significância de 2%.
- (c) Construa um teste de hipóteses com nível de significância 8% para testar se o 3º quartil dos tempos com que as partículas disparadas percorrem essa distância  $D$  é igual a 23 contra a alternativa de que ele é diferente de 23. Qual a conclusão desse teste?

Obs.: Note que é possível relacionar quartis com proporções.

# Soluções

1. (a) Sejam  $X_1, \dots, X_{25}$  variáveis aleatórias representando os valores pagos em cada cartela. Assim, a probabilidade do dinheiro ser suficiente é

$$P\left(\sum_{i=1}^{25} X_i \geq 1200\right) = P(\bar{X} \geq 1200/25), \quad \text{em que } \bar{X} \sim N(50, 100/25).$$

Logo,

$$P(\bar{X} \geq 1200/25) = P(\bar{X} \geq 48) = P\left(Z \geq \frac{48 - 50}{10/\sqrt{25}}\right) = P(Z \geq -1) = 0,8413.$$

- (b) Deseja-se saber qual é o valor de  $n$  tal que

$$P\left(\sum_{i=1}^n X_i \geq 1200\right) = 0,50.$$

Temos que

$$P\left(\sum_{i=1}^n X_i \geq 1200\right) = P(\bar{X} \geq 1200/n), \quad \text{em que } \bar{X} \sim N(50, 100/n).$$

Logo,

$$\begin{aligned} P(\bar{X} \geq 1200/n) &= P\left(Z \geq \frac{1200/n - 50}{10/\sqrt{n}}\right) = 0,50 \\ \Rightarrow \frac{1200/n - 50}{10/\sqrt{n}} &= 0 \Rightarrow n = 1200/50 = 24. \end{aligned}$$

2. (a) Sejam  $x_1 \leq x_2 \leq x_3 \leq x_4 \leq x_5$  as idades de Paulo, Andrea, Jorge, Daniela e Vitor, respectivamente. Então, temos:

$$\text{Mediana} = x_3 = 25, \quad \text{(I)}$$

$$\text{Distância Interquartil} = x_4 - x_2 = 10, \quad \text{(II)}$$

$$\text{Amplitude} = x_5 - x_1 = 30, \quad \text{(III)}$$

$$\text{Média} = 21 \rightarrow x_1 + x_2 + x_3 + x_4 + x_5 = 5 \times 21 = 105 \quad \text{(IV)}$$

$$\text{Variância} = 146 \rightarrow x_1^2 + x_2^2 + x_3^2 + x_4^2 + x_5^2 - 5 \times 21^2 = 4 \times 146 \quad \text{(V)}$$

Substituindo (I), (II) e (III) em (IV), obtemos:

$$x_1 + x_2 + 25 + (x_2 + 10) + (x_1 + 30) = 105 \rightarrow 2x_1 + 2x_2 = 40 \rightarrow x_1 + x_2 = 20 \rightarrow x_2 = 20 - x_1 \quad \text{(VI)}$$

$$\text{Além disso, de (II), } x_4 = x_2 + 10 = 20 - x_1 + 10 = 30 - x_1 \quad \text{(VII)}$$

Substituindo (VI), (I), (VII) e (III) em (V), chegamos a:

$$x_1^2 + (20 - x_1)^2 + 25^2 + (30 - x_1)^2 + (30 + x_1)^2 = 4 \times 146 + 5 \times 441 = 2789.$$

Isto nos leva a equação do 2º grau:  $x_1^2 - 10x_1 + 9 = 0$ , cujas raízes são 9 e 1.

Experimentemos inicialmente a solução  $x_1 = 9$ .

Ela nos leva a:  $x_2 = 20 - 9 = 11$ ,  $x_3 = 25$ ,  $x_4 = 30 - 9 = 21$  e  $x_5 = 30 + 9 = 39$ .

Essa solução não serve, porque aqui temos  $x_3 = 25 > x_4 = 21$ , contrariando a premissa de que os dados estão ordenados.

Experimentemos agora a solução  $x_1 = 1$ . Ela nos leva a:

$x_2 = 20 - 1 = 19$ ,  $x_3 = 25$ ,  $x_4 = 30 - 1 = 29$  e  $x_5 = 30 + 1 = 31$ . Solução correta!

As idades são, portanto, as seguintes: Paulo: 1, Andrea: 19, Jorge: 25, Daniela: 29 e Vitor: 31.

- (b) As cercas neste caso são: Cerca inferior =  $x_2 - 1,5 \times DIQ = 19 - 1,5 \times 10 = 4$  e

Cerca superior =  $x_4 + 1,5 \times DIQ = 29 + 1,5 \times 10 = 44$ .

Sendo assim, temos um único outlier, que é a idade de Paulo = 1 ano.

3. (a) Usando as propriedades da esperança de uma combinação linear de variáveis aleatórias iid:

$$E(\hat{p}_A) = E\left(\frac{X_{10} + X_{20} + X_{30} + X_{40}}{4}\right) = p, \quad E(\hat{p}_B) = E\left(\frac{X_{10} + 2 \cdot X_{20} + 3 \cdot X_{30} + 4 \cdot X_{40}}{10}\right) = p,$$

$$E(\hat{p}_C) = E\left(\frac{\sum_{i=1}^{40} X_i}{40}\right) = p, \quad E(\hat{p}_D) = E\left(\frac{\sum_{i=1}^{10} X_i + 2 \cdot \sum_{i=11}^{20} X_i + 3 \cdot \sum_{i=21}^{30} X_i + 4 \cdot \sum_{i=31}^{40} X_i}{100}\right) = p$$

O viés é  $B(\hat{\theta}) = E(\hat{\theta}) - \theta$ . Assim,  $B(\hat{p}_A) = B(\hat{p}_B) = B(\hat{p}_C) = B(\hat{p}_D) = 0$

(b) Usando as propriedades da variância de uma combinação linear de variáveis aleatórias iid:

$$Var(\hat{p}_A) = Var\left(\frac{X_{10} + X_{20} + X_{30} + X_{40}}{4}\right) = \frac{1}{16}(Var(X_{10}) + Var(X_{20}) + Var(X_{30}) + Var(X_{40})) = \frac{p(1-p)}{4},$$

$$Var(\hat{p}_B) = \frac{Var(X_{10}) + 4 \cdot Var(X_{20}) + 9 \cdot Var(X_{30}) + 16 \cdot Var(X_{40})}{100} = \frac{3}{10}p(1-p)$$

$$Var(\hat{p}_C) = Var\left(\frac{\sum_{i=1}^{40} X_i}{40}\right) = \frac{\sum_{i=1}^{40} Var(X_i)}{40^2} = \frac{p(1-p)}{40}$$

$$Var(\hat{p}_D) = \frac{Var(\sum_{i=1}^{10} X_i) + 4 \cdot Var(\sum_{i=11}^{20} X_i) + 9 \cdot Var(\sum_{i=21}^{30} X_i) + 16 \cdot Var(\sum_{i=31}^{40} X_i)}{100^2} = \frac{3}{100}p(1-p)$$

Colocando as frações:  $\frac{1}{4} \frac{3}{10} \frac{1}{40} \frac{3}{100}$  com o mesmo denominador:  $\frac{100}{400} \frac{120}{400} \frac{10}{400} \frac{12}{400}$ . Assim,  $Var(\hat{p}_C) \leq Var(\hat{p}_D) \leq Var(\hat{p}_A) \leq Var(\hat{p}_B)$ . Como os estimadores são não viciados, temos que:

$$EQM(\hat{p}_C) \leq EQM(\hat{p}_D) \leq EQM(\hat{p}_A) \leq EQM(\hat{p}_B)$$

O melhor estimador é o  $\hat{p}_C$ .

(c) Para esse conjunto de dados, temos as seguintes estimativas:

$$\hat{p}_A = \frac{2}{4} = 0,5$$

$$\hat{p}_B = \frac{1 + 2 \times 0 + 3 \times 1 + 4 \times 0}{10} = \frac{4}{10} = 0,4$$

$$\hat{p}_C = \frac{30}{40} = 0,75$$

$$\hat{p}_D = \frac{7 + 2 \times 8 + 3 \times 7 + 4 \times 8}{100} = \frac{76}{100} = 0,76$$

4. (a) Estatísticas necessárias:  $\bar{x} = \sum_{i=1}^{25} \frac{x_i}{25} = \frac{525}{25} = 21$  e  $s_x^2 = \frac{\sum_{i=1}^{25} x_i^2 - 25\bar{x}^2}{25-1} = \frac{11877 - 25 \cdot (21)^2}{24} = 35,5$

Seja  $\mu$  o tempo médio. Como temos variância desconhecida e tamanho amostral pequeno ( $n < 30$ ), é preciso construir o intervalo através da distribuição t-student. Temos que:

$$P\left(t_{n-1}\left(\frac{\alpha}{2}\right) < \frac{\bar{X} - \mu}{\frac{S}{\sqrt{n}}} < t_{n-1}\left(1 - \frac{\alpha}{2}\right)\right) = 1 - \alpha$$

$$P\left(-t_{n-1}\left(1 - \frac{\alpha}{2}\right) \frac{S}{\sqrt{n}} < \bar{X} - \mu < t_{n-1}\left(1 - \frac{\alpha}{2}\right) \frac{S}{\sqrt{n}}\right) = 1 - \alpha$$

$$P\left(\bar{X} - t_{n-1}\left(1 - \frac{\alpha}{2}\right) \frac{S}{\sqrt{n}} < \mu < \bar{X} + t_{n-1}\left(1 - \frac{\alpha}{2}\right) \frac{S}{\sqrt{n}}\right) = 1 - \alpha$$

Os extremos do Intervalo de Confiança a 95% para  $\mu$  são, portanto:

$$\bar{x} \pm t_{24}(0,975) \frac{s_x}{\sqrt{n}}, \quad \text{ou seja, } 21 \pm 2,064 \sqrt{\frac{35,5}{25}}$$

Logo,  $IC(\mu, 95\%) = [18,540 ; 23,460]$  em segundos.

Interpretação: Esse procedimento nos permite obter intervalos que conterão o verdadeiro valor do parâmetro  $\mu$ , tempo médio, com 95% de chance. Vale observar que  $\mu$  é um valor fixo, embora desconhecido, enquanto que os limites do intervalo são aleatórios.

(b) Queremos testar  $\begin{cases} H_0 : \mu \leq 18 \\ H_1 : \mu > 18 \end{cases}$

Como  $\sigma^2$  é desconhecido e  $n < 30$ , vamos utilizar o fato de que, sob  $H_0$ ,  $\frac{\bar{X} - \mu}{\frac{s}{\sqrt{n}}} \sim t_{n-1}$

Denotando p-valor por  $\tilde{\alpha}$ , temos que sendo  $H_0$  verdadeira, ou seja, sendo  $\mu = 18$ .

$$\begin{aligned} \tilde{\alpha} &= P(\bar{X} > \bar{x}) = P\left(T_{n-1} > \frac{\bar{x} - \mu}{\frac{s}{\sqrt{n}}}\right) = P\left(T_{24} > \frac{21 - 18}{\frac{\sqrt{35,5}}{\sqrt{25}}}\right) = P\left(T_{24} > \frac{3}{1,192}\right) = \\ &= P(T_{24} > 2,527) = 1 - P(T_{24} \leq 2,527) \end{aligned}$$

Pela tabela da t-student, podemos ver (olhando na linha associada a 24 graus de liberdade) que esse  $P(T_{24} \leq 2,527)$  está entre 0,99 e 0,995. Logo,  $\tilde{\alpha} \in [0,005; 0,01]$ .

Então,  $\tilde{\alpha} < 0,02 = \alpha$ , indicando que  $H_0$  deve ser rejeitado ao nível de 2%, ou seja, a afirmação do físico deve sim ser contestada.

(c) Queremos testar  $\begin{cases} H_0 : Q_3 = 23 \\ H_1 : Q_3 \neq 23 \end{cases}$

Defina  $p$  como sendo a proporção teórica de valores do tempo abaixo de 23 e  $\hat{p}$  o estimador para  $p$ , dado pela proporção amostral de valores abaixo de 23. Como a probabilidade de um ensaio da variável "tempo de deslocamento da partícula" retornar um resultado abaixo de  $Q_3$  é 75%, temos que o teste desejado equivale a testar, ao nível  $\alpha = 0,08$ :

$$\begin{cases} H_0 : p = 0,75 \\ H_1 : p \neq 0,75 \end{cases}$$

Como  $np_0(1 - p_0) = 25 \times 0,75 \times 0,25 = 4,59 \geq 3$ , podemos aproximar Binomial por Normal. Então:

$$\alpha = P(\text{Rej } H_0), \text{ se } H_0 \text{ é verdadeira} \Rightarrow$$

A região de aceitação é um intervalo da forma:  $0,75 \pm c$ , onde  $P(0,75 - c < \hat{p} < 0,75 + c) = 0,92$ , sendo  $\hat{p} \sim N(0,75; \frac{0,75 \times 0,25}{25})$

$$P(\hat{p} < 0,75 + c) = 0,96 \Rightarrow P\left(\frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} < \frac{0,75 + c - 0,75}{\sqrt{\frac{0,75(0,25)}{25}}}\right) = 0,96$$

$$P\left(Z < \frac{c}{0,0866}\right) = 0,96 \Rightarrow \frac{c}{0,0866} = Z_{0,96} \Rightarrow \frac{c}{0,0866} = 1,75 \Rightarrow c = 0.15155$$

Logo, a região de aceitação desse teste é dada por RA:  $[0,75 - 0,15155; 0,75 + 0,15155] = [0,59845; 0,90155]$ .

Como na amostra se observou  $\hat{p} = \frac{15}{25} = 0,6$  e esse valor pertence a região de aceitação encontrada, temos que  $H_0$  não foi rejeitado ao nível 8%, ou seja, não foi rejeitado que  $Q_3 = 23$ .

obs: Esse teste também poderia ser aplicado definindo por  $p$  a proporção de valores acima de 23. Nesse caso, testaríamos se  $p = 0,25$ . Com cálculos similares chegaríamos à região de aceitação RA:  $[0,40155; 0,59845]$  e concluiríamos pela não rejeição de  $H_0$  pois  $\hat{p} = 0,4 \in RA$ .