

**CONCURSO PÚBLICO DE PROVAS E TÍTULOS PARA O CARGO EFETIVO DE PROFESSOR DA  
CARREIRA DE MAGISTÉRIO SUPERIOR – EDITAL Nº 28/2023 – PROGRAD**

**FOLHA DE QUESTÕES**

Área:

Número de C.P.F. \_\_\_\_\_

**QUESTÃO 07: (1 PONTO)** Seja  $X$  uma variável aleatória normalmente distribuída com média  $\mu$  e variância,  $\sigma^2 = 100$ . Um pesquisador pretende testar as seguintes hipóteses:

$$H_0: \mu = 75 \text{ contra} \\ H_a: \mu < 75$$

Para isso, é retirada de  $X$  uma amostra aleatória de tamanho  $n = 25$ . Considerando que  $H_0$  será rejeitada caso a média amostral seja menor ou igual a 70 (limite da Região Crítica, RC), determine:

- (0,4 PONTO)** o erro tipo I e sua probabilidade ( $\alpha$ ).
- (0,4 PONTO)** o erro tipo II e sua probabilidade ( $\beta$ ), supondo o caso específico, em que  $\mu = 68$ , ou seja,  $\beta(68)$ .
- (0,2 PONTO)** Com base na amostra obtida da variável aleatória  $X$ , obteve-se  $\bar{X} = 72$ . Calcule o valor  $p$  do teste. Essa informação sugere que a média verdadeira seja menor que o valor-alvo estabelecido?

**OBSERVAÇÃO:** A Tabela da distribuição Normal padrão está anexada ao final da prova para consultas.

**CHAVE DE CORREÇÃO:**

**a)** A Região Crítica (RC) referente ao problema é dada por  $RC = \{y \in \mathbb{R} \mid y \leq 70\}$ . O erro de tipo I, pode ser descrito da seguinte forma:

*Erro de tipo I:* Dizer que a média é menor e igual a 70, enquanto na verdade, ela é de fato igual a 75.

Dessa forma, a probabilidade de se cometer o erro I pode ser determinada por:

$$P(\text{erro I}) = P(\bar{X} \in RC \mid H_0 \text{ é verdadeira}) = \alpha.$$

Sob  $H_0$  verdadeira, tem-se que  $\bar{X}$  possui distribuição normal com valor médio igual a 75 e desvio padrão dado por  $\sigma_{\bar{X}} = \sigma/\sqrt{n} = 10/\sqrt{25} = 10/5 = 2$ , isto é,  $\bar{X} \sim N(\mu_{\bar{X}} = 75, \sigma_{\bar{X}}^2 = 4)$ . Assim, segue que:

$$\begin{aligned} \alpha = P(\text{erro I}) &= P(\bar{X} \leq 70 \mid \bar{X} \sim N(75, 4)) \\ &= P\left(Z \leq \frac{70 - 75}{2}\right), \quad Z \sim N(0,1) \\ &= P(Z \leq -2,5) = \Phi(-2,5) = 0,0062 = 0,62\% \end{aligned}$$

**CONCURSO PÚBLICO DE PROVAS E TÍTULOS PARA O CARGO EFETIVO DE PROFESSOR DA  
CARREIRA DE MAGISTÉRIO SUPERIOR – EDITAL Nº 28/2023 – PROGRAD**

**FOLHA DE QUESTÕES**

Área:

Número de C.P.F. \_\_\_\_\_

**b)** O erro tipo II pode ser descrito da seguinte forma:

*Erro tipo II:* Dizer que a média é maior que 70, sendo que de fato a média é igual a 68 ( $\mu = 68$ ).

A probabilidade de se cometer o erro tipo II, é então calculada da seguinte forma:

$$P(\text{erro II}) = P(\bar{X} \notin RC \mid H_1 \text{ é verdadeira}) = \beta(68)$$

Sob  $H_1$  verdadeira, tem-se que a v. a.  $\bar{X}$  é tal que  $\bar{X} \sim N(\mu_{\bar{X}} = 68, \sigma_{\bar{X}}^2 = 4)$ . Assim, segue que:

$$\begin{aligned} P(\text{erro II}) &= P(\bar{X} > 70 \mid \bar{X} \sim N(68, 4)) \\ &= P\left(Z > \frac{70 - 68}{2}\right) \\ &= 1 - P(Z \leq 1) \\ &= 1 - \Phi(1) \\ &= 1 - 0,8413 = 0,1586 = 15,86\% = \beta(68) \end{aligned}$$

**c)** Para o cálculo de valor  $p$ , segue pela definição que:

$$\text{valor } p = P(\bar{X} \leq 72 \mid \mu = 75) = P\left(Z \leq \frac{72 - 75}{2}\right) = P\left(Z \leq -\frac{3}{2}\right) = \Phi(-1,5) = 0,0668$$

$$\therefore \text{valor } p = 0,0668.$$

E conclui-se que, estabelecido o valor do nível de significância  $\alpha$ , o pesquisador não deve rejeitar a hipótese  $H_0$  se o valor  $p = 0,0668 > \alpha$ . Caso contrário, se o valor  $p = 0,0668 \leq \alpha$ , rejeita-se a hipótese  $H_0$ , em favor da Hipótese alternativa,  $H_a$ .

**QUESTÃO 08: (1,5 PONTO)** Um dos modelos mais empregados em análise de dados é o modelo de regressão linear. Quando temos somente uma variável auxiliar ou regressora  $x$ , temos o modelo de regressão linear simples, dado por:  $Y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$ , em que  $Y_i$  é o valor da variável resposta  $Y$ ,  $\beta_0$  e  $\beta_1$  são os parâmetros do modelo,  $x_i$  é o valor pré-fixado da variável explicativa  $x$  ( $x_i$  é constante conhecida),  $\varepsilon_i$  é um termo de erro aleatório, com média 0 e variância constante  $\sigma^2$ . Além disso, os erros aleatórios  $\varepsilon_i$  são não correlacionados, ou seja,  $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$ , para todo  $i \neq j$ , com  $i, j = 1, \dots, n$ .

Frequentemente, assumimos que os erros possuem distribuição normal, ou seja,  $\varepsilon_i \sim N(0, \sigma^2)$ . Assim, pode-se mostrar que a distribuição de probabilidade de  $Y_i$  é dada por  $Y_i | x_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$ .

**CONCURSO PÚBLICO DE PROVAS E TÍTULOS PARA O CARGO EFETIVO DE PROFESSOR DA  
CARREIRA DE MAGISTÉRIO SUPERIOR – EDITAL Nº 28/2023 – PROGRAD**

**FOLHA DE QUESTÕES**

Área:

Número de C.P.F. \_\_\_\_\_

- a) **(0,7 PONTO)** Seja  $(x_1, Y_1), (x_2, Y_2), \dots, (x_n, Y_n)$  uma amostra aleatória observada segundo o modelo de regressão linear simples apresentado, obtenha os estimadores de mínimos quadrados para os parâmetros  $\beta_0$  e  $\beta_1$  do modelo.
- b) **(0,8 PONTO)** Mostre que os estimadores de mínimos quadrados  $\hat{\beta}_0$  e  $\hat{\beta}_1$  são não tendenciosos, ou seja,  $E(\hat{\beta}_1) = \beta_1$  e  $E(\hat{\beta}_0) = \beta_0$ . Para tal, reescreva  $\hat{\beta}_1$  como combinação linear de  $Y_i$ , ou seja,  $\hat{\beta}_1 = \sum_{i=1}^n k_i Y_i$ , com  $k_i = \frac{(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$ .

**CHAVE DE CORREÇÃO:**

a) Do modelo de regressão linear simples, temos que

$$\varepsilon_i = Y_i - \beta_0 - \beta_1 x_i.$$

O método de mínimos quadrados consiste em encontrar os valores de  $\beta_0$  e  $\beta_1$  que minimizam a soma dos quadrados dos erros, definida por

$$S = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_i)^2.$$

Para encontrar esse mínimo, precisamos derivar a função  $S$  em relação a  $\beta_0$  e  $\beta_1$  e igualar a zero, ou seja, os estimadores de mínimos quadrados  $\hat{\beta}_0$  e  $\hat{\beta}_1$  devem satisfazer:

$$\left. \frac{\partial S}{\partial \beta_0} \right|_{\hat{\beta}_0, \hat{\beta}_1} = -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) = 0$$

e

$$\left. \frac{\partial S}{\partial \beta_1} \right|_{\hat{\beta}_0, \hat{\beta}_1} = -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 x_i) x_i = 0$$

Simplificando, temos:

$$\sum_{i=1}^n Y_i - n\hat{\beta}_0 - \hat{\beta}_1 \sum_{i=1}^n x_i = 0 \quad (1)$$

$$\sum_{i=1}^n x_i Y_i - \hat{\beta}_0 \sum_{i=1}^n x_i - \hat{\beta}_1 \sum_{i=1}^n x_i^2 = 0, \quad (2)$$

o qual é denominador sistema de equações normais.

CONCURSO PÚBLICO DE PROVAS E TÍTULOS PARA O CARGO EFETIVO DE PROFESSOR DA  
CARREIRA DE MAGISTÉRIO SUPERIOR – EDITAL Nº 28/2023 – PROGRAD

**FOLHA DE QUESTÕES**

Área:

Número de C.P.F. \_\_\_\_\_

Pela equação (1), obtemos

$$n\hat{\beta}_0 = \sum_{i=1}^n Y_i - \hat{\beta}_1 \sum_{i=1}^n x_i \Rightarrow \hat{\beta}_0 = \frac{\sum_{i=1}^n Y_i}{n} - \hat{\beta}_1 \frac{\sum_{i=1}^n x_i}{n}.$$

E substituindo na equação (2), temos

$$\begin{aligned} & \sum_{i=1}^n x_i Y_i - \left( \frac{\sum_{i=1}^n Y_i}{n} - \hat{\beta}_1 \frac{\sum_{i=1}^n x_i}{n} \right) \sum_{i=1}^n x_i - \hat{\beta}_1 \sum_{i=1}^n x_i^2 = 0 \\ \Rightarrow & \sum_{i=1}^n x_i Y_i - \frac{\sum_{i=1}^n Y_i \sum_{i=1}^n x_i}{n} + \hat{\beta}_1 \frac{(\sum_{i=1}^n x_i)^2}{n} - \hat{\beta}_1 \sum_{i=1}^n x_i^2 = 0 \\ \Rightarrow & \sum_{i=1}^n x_i Y_i - \frac{\sum_{i=1}^n Y_i \sum_{i=1}^n x_i}{n} = \hat{\beta}_1 \left[ \sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n} \right] \end{aligned}$$

Portanto,

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n x_i Y_i - \frac{\sum_{i=1}^n x_i \sum_{i=1}^n Y_i}{n}}{\sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}}$$

e

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{x},$$

onde  $\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$  e  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ .

b)

$$E(\hat{\beta}_1) = E\left(\sum_{i=1}^n k_i Y_i\right) = E(k_1 Y_1 + k_2 Y_2 + \dots + k_n Y_n) \Rightarrow$$

$$E(\hat{\beta}_1) = k_1 E(Y_1) + k_2 E(Y_2) + \dots + k_n E(Y_n) = \sum_{i=1}^n k_i E(Y_i).$$

Conforme apresentado no enunciado, e pode-se mostrar também,  $E(Y_i) = \beta_0 + \beta_1 x_i$ . Logo,

$$E(\hat{\beta}_1) = \sum_{i=1}^n k_i E(Y_i) = \sum_{i=1}^n k_i (\beta_0 + \beta_1 x_i) = \beta_0 \sum_{i=1}^n k_i + \beta_1 \sum_{i=1}^n k_i x_i.$$

Temos que

$$\sum_{i=1}^n k_i = \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n x_i - n\bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2} = 0.$$

**CONCURSO PÚBLICO DE PROVAS E TÍTULOS PARA O CARGO EFETIVO DE PROFESSOR DA  
CARREIRA DE MAGISTÉRIO SUPERIOR – EDITAL Nº 28/2023 – PROGRAD**

**FOLHA DE QUESTÕES**

Área:

Número de C.P.F. \_\_\_\_\_

e

$$\sum_{i=1}^n k_i x_i = \sum_{i=1}^n \frac{(x_i - \bar{x})x_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})x_i}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\sum_{i=1}^n (x_i^2 - \bar{x}x_i)}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$

Desenvolvendo o numerador, temos:

$$\sum_{i=1}^n (x_i^2 - \bar{x}x_i) = \sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i = \sum_{i=1}^n x_i^2 - \bar{x} \sum_{i=1}^n x_i = \sum_{i=1}^n x_i^2 - n\bar{x}^2.$$

e desenvolvendo o denominador, temos:

$$\sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - 2\bar{x} \sum_{i=1}^n x_i + n\bar{x}^2 = \sum_{i=1}^n x_i^2 - n\bar{x}^2.$$

Então,

$$\sum_{i=1}^n k_i x_i = \frac{\sum_{i=1}^n (x_i^2 - \bar{x}x_i)}{\sum_{i=1}^n (x_i - \bar{x})^2} = 1.$$

Assim, concluímos que

$$E(\hat{\beta}_1) = \beta_0 \sum_{i=1}^n k_i + \beta_1 \sum_{i=1}^n k_i x_i = \beta_1.$$

Agora, queremos mostrar que  $E(\hat{\beta}_0) = \beta_0$ .

$$\begin{aligned} E(\hat{\beta}_0) &= E(\bar{Y} - \hat{\beta}_1 \bar{x}) = E\left(\frac{\sum_{i=1}^n Y_i}{n}\right) - \bar{x}E(\hat{\beta}_1) = \\ &= E\left(\frac{Y_1 + Y_2 + \dots + Y_n}{n}\right) - \bar{x}E(\hat{\beta}_1) = \frac{1}{n}E(Y_1 + Y_2 + \dots + Y_n) - \bar{x}E(\hat{\beta}_1) = \\ &= \frac{1}{n} \sum_{i=1}^n E(Y_i) - \bar{x}E(\hat{\beta}_1) = \frac{1}{n} \sum_{i=1}^n (\beta_0 + \beta_1 x_i) - \bar{x}\beta_1 = \\ &= \frac{1}{n} \left[ n\beta_0 + \beta_1 \sum_{i=1}^n x_i \right] - \beta_1 \bar{x} = \beta_0 + \beta_1 \bar{x} - \beta_1 \bar{x} = \beta_0. \end{aligned}$$