

# Modelos Lineares


## Regressão Linear Simples

**Professora Ariane Ferreira**



**Instituto Politécnico**  
Campus Regional da UERJ  
Nova Friburgo - RJ

## Decomposição dos resíduos



## Somas Quadradas

Soma dos Quadrados totais (SST): 
$$SST = \sum_{i=1}^n (y_i - \bar{y})^2$$

Decompondo o termo: 
$$y_i - \bar{y} = (y_i - \hat{y}_i) - (\bar{y} - \hat{y}_i)$$

SST fica:

$$SST = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\bar{y} - \hat{y}_i)^2 - 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\bar{y} - \hat{y}_i)$$

## Somas Quadradas

Usando os resíduos:  $y_i - \hat{y}_i = e_i$

E a propriedade de ortogonalidade:  $\sum_{i=1}^n e_i = \sum_{i=1}^n e_i x_i = \sum_{i=1}^n e_i \hat{y}_i = 0$

Temos:

$$\begin{aligned}
 SST &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\bar{y} - \hat{y}_i)^2 - 2 \sum_{i=1}^n e_i (\bar{y} - \hat{y}_i) \\
 &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\bar{y} - \hat{y}_i)^2 - 2\bar{y} \underbrace{\sum_{i=1}^n e_i}_0 - 2 \underbrace{\sum_{i=1}^n e_i \hat{y}_i}_0
 \end{aligned}$$

Resultando em:

$$SST = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

## Somas Quadradas

Soma dos Quadrados dos Erros (SSE):  $SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2$

Soma dos Quadrados da Regressão:  $SSR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$

Temos então:  $SST = SSE + SSR$

## Estimação de $\sigma^2$

Precisamos estimar  $\sigma^2$  para calcularmos  $V(\hat{a})$  e  $V(\hat{b})$ .

Usaremos a soma quadrada:

$$\sum_{i=1}^n (y_i - ax_i - b)^2 = \sum_{i=1}^n (y_i - \hat{y}_i - ax_i - b + \hat{y}_i)^2$$

Trocando  $\hat{y}_i$  por  $\hat{a}x_i + \hat{b}$ ,

$$\sum_{i=1}^n (y_i - ax_i - b)^2 = \sum_{i=1}^n \{y_i - \hat{y}_i + (\hat{a} - a)x_i + (\hat{b} - b)\}^2$$

## Estimação de $\sigma^2$

Desenvolvendo a soma quadrada e sabendo que

Usaremos a soma quadrada:  $y_i - \hat{y}_i = e_i$

Temos:

$$\begin{aligned} \sum_{i=1}^n (y_i - ax_i - b)^2 &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 + (\hat{a} - a)^2 \sum_{i=1}^n x_i^2 + n(\hat{b} - b)^2 \\ &\quad + 2(\hat{a} - a) \underbrace{\sum_{i=1}^n e_i x_i}_0 + 2(\hat{b} - b) \underbrace{\sum_{i=1}^n e_i}_0 + (\hat{a} - a)(\hat{b} - b) \sum_{i=1}^n x_i \end{aligned}$$

Propriedade de ortogonalidade dos resíduos

$$\sum_{i=1}^n e_i = \sum_{i=1}^n e_i x_i = \sum_{i=1}^n e_i \hat{y}_i = 0$$

## Estimação de $\sigma^2$

Temos:

$$\sum_{i=1}^n (y_i - ax_i - b)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + (\hat{a} - a)^2 \sum_{i=1}^n x_i^2 + n(\hat{b} - b)^2 + 2n(\hat{a} - a)(\hat{b} - b)\bar{x}$$

Trocamos na expressão acima  $\sum_{i=1}^n x_i^2$  por  $\sum_{i=1}^n (x_i - \bar{x})^2 + n\bar{x}^2 = S_{xx} + n\bar{x}^2$

Temos:

$$\sum_{i=1}^n (y_i - ax_i - b)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + (\hat{a} - a)^2 S_{xx} - n\bar{x}^2(\hat{a} - a)^2 + n(\hat{b} - b)^2 + 2n(\hat{a} - a)(\hat{b} - b)\bar{x}$$

$$\sum_{i=1}^n (y_i - ax_i - b)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + (\hat{a} - a)^2 S_{xx} + n\{(\hat{a} - a)\bar{x} + (\hat{b} - b)\}^2$$



## Estimação de $\sigma^2$

Usando:  $\hat{a}\bar{x} + \hat{b} = \bar{y}$ ,

$$\sum_{i=1}^n (y_i - ax_i - b)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + (\hat{a} - a)^2 S_{xx} + n\{\bar{y} - (a\bar{x} + b)\}^2$$

Dividindo ambos os lados por  $\sigma^2$  :

$$\underbrace{\sum_{i=1}^n \left( \frac{y_i - ax_i - b}{\sigma} \right)^2}_{f_{\chi^2}(n)} = \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{\sigma} \right)^2 + \underbrace{\left( \frac{(\hat{a} - a)\sqrt{S_{xx}}}{\sigma} \right)^2}_{f_{\chi^2}(1)} + \underbrace{\left( \frac{\{\bar{y} - (a\bar{x} + b)\}\sqrt{n}}{\sigma} \right)^2}_{f_{\chi^2}(1)}$$

v.a. à n graus de liberdade

v.a. à 1 grau de liberdade

v.a. à 1 grau de liberdade

Estimação de  $\sigma^2$ 

Então: 
$$\frac{SSE}{\sigma^2} = \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{\sigma} \right)^2 \sim f_{\chi^2}(n-2)$$

Calculamos a esperança matemática:  $E(SSE) = (n-2)\sigma^2$

Em conclusão o estimador não tendencioso de  $\sigma^2$  é:

$$\hat{\sigma}^2 = \frac{SSE}{n-2} \stackrel{\text{def}}{=} MSE$$

MSE= Média quadrada dos erros (resíduos)