

$Y$ : variável aleatória de interesse (variável resposta)

$X$ : variável regressora ou independente

A tensão:  $X$  não é variável aleatória

$Y$  é descrita como uma soma de uma parcela determinística e outra aleatória.

A parte determinística é uma reta em função de  $X$ .

informação sobre  $Y$  que só depende de conhecemos  $X$ .

A parte aleatória, chamada de erro, representa os inúmeros fatores que podem influenciar  $Y$ .

O erro provoca variações ou flutuações ou mesmo distorções na parte determinística.

- erros positivos ou negativos podem ocorrer e que  $IE(\varepsilon) = 0$
- $Var(\varepsilon)$  não depende de  $X$ .

Modelos de Regressão linear  
Simplificadas (MRLS)

$$Y = \beta_0 + \beta_1 x + \varepsilon$$

$\beta_0$ ,  $\beta_1$  e  $x$ : constantes

$$E(\varepsilon) = 0$$

$$\text{Var}(\varepsilon) = \sigma^2$$

MRLS (Normal)

$$Y = \beta_0 + \beta_1 x + \varepsilon$$

$\beta_0$ ,  $\beta_1$  e  $x$ : constantes

$$\varepsilon \sim N(0; \sigma^2).$$

Resultado 1: para um valor

pré-fixaado,  $x$ , de  $X$

$$Y \sim N(\beta_0 + \beta_1 x; \sigma^2)$$

ou seja:  $E(Y|x) = \beta_0 + \beta_1 \cdot x$

$$\text{Var}(Y|x) = \sigma^2$$

Exercício 1: verifique o resultado 1.

## Estimadores de mínimos quadrados

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

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

Sabemos que  $y|x \sim N(\beta_0 + \beta_1 x; \sigma^2)$

Então  $y_i \sim N(\beta_0 + \beta_1 x_i; \sigma^2)$

independentes para  $i = 1, 2, \dots, n$ .

E os estimadores  $\hat{\beta}_0$  e  $\hat{\beta}_1$

são combinações lineares de  $y_1, y_2, \dots, y_n$ ,  
logo tb têm distribuição normal.

Exercício 2: verifique que

a)  $E(\hat{\beta}_1) = \beta_1$ ,

b)  $E(\hat{\beta}_0) = \beta_0$ .

ou seja, que  $\hat{\beta}_0$  e  $\hat{\beta}_1$  são estimadores  
não viésados para  $\beta_0$  e  $\beta_1$ .

Exercício 3: Verifique que

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\text{Var}(\hat{\beta}_0) = \sigma^2 \left[ \frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})} \right]$$

Exercício 4: Verifique que

$$\text{Cov}(Y_i, Y_j) = 0 \text{ para } i \neq j$$

Exercício 5: Verifique que:

a)  $\text{Cov}(\bar{Y}, \hat{\beta}_1) = 0$  (use exercício 4)

b)  $\text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = \frac{-\bar{x}\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$ ,

O que significa que o sinal de  $\text{Cov}(\hat{\beta}_0, \hat{\beta}_1)$  depende do valor de  $\bar{x}$ .

A partir dos resultados dos exercícios 2 e 3, temos que as distribuições de  $\hat{\beta}_0$  e  $\hat{\beta}_1$  são

$$\hat{\beta}_0 \sim N\left(\beta_0; \sigma^2 \left[ \frac{1}{n} + \frac{\bar{x}^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \right]\right)$$

$$\hat{\beta}_1 \sim N\left(\beta_1; \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}\right)$$

$y_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$  é escrito como  
 $\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 x_i$  o que pode confundir bastante.

Observar que  $E(y|x_i) = y_i$

E falta apresentar um estimador para  $\text{Var}(\epsilon) = \sigma^2$ .

Seu estimador de mínimos quadrados é

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{(n-2)}$$

um estimado não viável.

Sabe-se ainda

$$\frac{(n-2)\hat{\sigma}^2}{\sigma^2} \sim \chi^2_{(n-2)}$$

(qui-quadrado)  
c/ n-2 graus de liberdade)