

REGRESSÃO LINEAR SIMPLES ($\hat{Y} = \hat{a} + \hat{b} X$ é a recta de regressão estimada)

MÉTODO DOS MÍNIMOS QUADRADOS ORDINÁRIOS

Um resíduo ou erro é a diferença entre o valor observado e o valor estimado pelo modelo de regressão, ou seja, $e_i = y_i - \hat{y}_i = y_i - \hat{a} - \hat{b} x_i$.

De acordo com o método dos mínimos quadrados os estimadores dos parâmetros a e b, ou seja $\hat{a}$ e $\hat{b}$, consiste na minimização da soma quadrática dos erros.

A soma quadrática dos erros é designada por $SQ_{Erro} = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{a} - \hat{b} x_i)^2$.

Esta minimização que se pretende resulta da resolução do seguinte sistema:

$$\begin{aligned} \begin{cases} \frac{\partial}{\partial a} SQ_{Erro} = 0 \\ \frac{\partial}{\partial b} SQ_{Erro} = 0 \end{cases} &\Leftrightarrow \begin{cases} \frac{\partial}{\partial a} \sum_{i=1}^n (y_i - a - b x_i)^2 = 0 \\ \frac{\partial}{\partial b} \sum_{i=1}^n (y_i - a - b x_i)^2 = 0 \end{cases} \Leftrightarrow \begin{cases} -2 \sum_{i=1}^n (y_i - a - b x_i) = 0 \\ -2 \sum_{i=1}^n x_i (y_i - a - b x_i) = 0 \end{cases} \Leftrightarrow \\ \Leftrightarrow \begin{cases} \sum_{i=1}^n y_i - n a - b \sum_{i=1}^n x_i = 0 \\ \sum_{i=1}^n x_i y_i - a \sum_{i=1}^n x_i - b \sum_{i=1}^n x_i^2 = 0 \end{cases} &\Leftrightarrow \begin{cases} n \bar{y} - n a - b n \bar{x} = 0 \\ \sum_{i=1}^n x_i y_i - a \sum_{i=1}^n x_i - b \sum_{i=1}^n x_i^2 = 0 \end{cases} \Leftrightarrow \begin{cases} a = \bar{y} - b \bar{x} \\ \sum_{i=1}^n x_i y_i - (\bar{y} - b \bar{x}) \sum_{i=1}^n x_i - b \sum_{i=1}^n x_i^2 = 0 \end{cases} \Leftrightarrow \\ \Leftrightarrow \begin{cases} - \\ \sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} + n b \bar{x}^2 - b \sum_{i=1}^n x_i^2 = 0 \end{cases} &\Leftrightarrow \begin{cases} - \\ \sum_{i=1}^n x_i y_i - n \bar{x} \bar{y} + b (n \bar{x}^2 - \sum_{i=1}^n x_i^2) = 0 \end{cases} \Leftrightarrow \\ \Leftrightarrow \begin{cases} - \\ b = \frac{-\sum_{i=1}^n x_i y_i + n \bar{x} \bar{y}}{n \bar{x}^2 - \sum_{i=1}^n x_i^2} \end{cases} &\Leftrightarrow \begin{cases} - \\ b = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2} \end{cases} \Leftrightarrow \begin{cases} - \\ b = \frac{\frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2} \end{cases} \Leftrightarrow \begin{cases} \hat{a} = \bar{y} - \hat{b} \bar{x} \\ \hat{b} = \frac{Cov(X, Y)}{Var(X)} \end{cases} \end{aligned}$$

A variável Y é chamada de variável resposta, explicada ou dependente e a variável X é chamada de variável controlada, explicativa ou independente.

Covariância entre as variáveis X e Y:

$$Cov(X, Y) = S_{XY} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}$$

Variância da variável X :

$$Var(X) = S_{XX} = S_X^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2$$

Coefficiente angular da recta (declive da recta):

$$b = \frac{n \left(\sum_{i=1}^n x_i y_i \right) - \left(\sum_{i=1}^n x_i \right) \left(\sum_{i=1}^n y_i \right)}{n \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} = \frac{Cov(X,Y)}{VAR(X)} = \frac{S_{xy}}{S_x^2}$$

Ordenada na origem da recta: $a = \bar{y} - b\bar{x}$

Coefficiente de correlação linear amostral ou índice de ajustamento:

$$r_{XY} = \frac{n \sum_{i=1}^n x_i y_i - \left(\sum_{i=1}^n x_i \right) \left(\sum_{i=1}^n y_i \right)}{\sqrt{n \left(\sum_{i=1}^n x_i^2 \right) - \left(\sum_{i=1}^n x_i \right)^2} \sqrt{n \left(\sum_{i=1}^n y_i^2 \right) - \left(\sum_{i=1}^n y_i \right)^2}} = \frac{Cov(X,Y)}{\sqrt{Var(X) Var(Y)}} = b \frac{S_x}{S_y}$$

Coefficiente de determinação:

$$R^2 = r_{XY}^2 = \frac{(Cov(X,Y))^2}{Var(X) Var(Y)} = 1 - \frac{SQ_{Erro}}{Var(Y)}$$

(*) requer uma demonstração