

Quando uma variável resposta Y é função de duas ou mais variáveis regressoras (X_1, X_2, \dots, X_k) temos uma REGRESSÃO LINEAR MÚLTIPLA.

O modelo estatístico é dado por:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \epsilon_i$$

com: $i = 1, \dots, n$ e $j = 1, \dots, k$.

Considerando cada variável X_{ij} centrada em sua média \bar{X}_j , temos: $x_{ij} = X_{ij} - \bar{X}_j \Rightarrow X_{ij} = x_{ij} + \bar{X}_j$

Desta forma,

$$Y_i = \beta_0 + \beta_1(x_{i1} + \bar{X}_1) + \beta_2(x_{i2} + \bar{X}_2) + \dots + \beta_k(x_{ik} + \bar{X}_k) + \epsilon_i$$

$$Y_i = \underbrace{(\beta_0 + \beta_1 \bar{X}_1 + \dots + \beta_k \bar{X}_k)}_{\alpha} + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \epsilon_i$$

Matricialmente, o modelo RLM é dado por:

$$\underset{\sim}{Y} = X \underset{\sim}{\theta} + \underset{\sim}{\epsilon}$$

$\underset{\sim}{Y}$ é um vetor $n \times 1$ da variável aleatória Y .

$$\underset{\sim}{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_1$$

X é a matriz $n \times p$ de delineamentos, $p = k + 1$

$$X = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{bmatrix}_{p=k+1}$$

$\underline{\theta}$ é o vetor de parâmetros $p \times 1$, $p = k+1$

$$\underline{\theta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix}_1$$

p 1

$\underline{\varepsilon}$ é o vetor $n \times 1$ de erros

$$\underline{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}_1$$

n 1

Suposições:

i) A variável y é uma função LINEAR das k variáveis regressoras;

ii) As variáveis x_j são de natureza fixa;

iii) $E(\varepsilon_i) = 0 \Rightarrow E(\underline{\varepsilon}) = \phi = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}_1$

iv) Erros são homocedásticos e independentes

$$\left. \begin{array}{l} \text{Var}(\varepsilon_i) = \sigma^2 \\ \text{Cov}(\varepsilon_i, \varepsilon_{i'}) = 0 \end{array} \right\} \text{Var}(\underline{\varepsilon}) = \begin{bmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{bmatrix}_n = I_n \sigma^2 = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}_n \sigma^2$$

v) Erros têm distribuição NORMAL

$\varepsilon_i \sim N(0, \sigma^2) \Rightarrow \underline{\varepsilon} \sim N(\phi, I\sigma^2)$

$y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2) \Rightarrow \underline{y} \sim N(X\underline{\theta}, I\sigma^2)$

ESTIMAÇÃO DOS PARÂMETROS - MMQ ($n > p$)

Considerando o modelo: $y = X\theta + \varepsilon$, temos:

$$\tilde{\varepsilon} = \tilde{y} - X\tilde{\theta} \Rightarrow \text{minimizar } \sum_{i=1}^n \varepsilon_i = \tilde{\varepsilon}^T \tilde{\varepsilon} = [\varepsilon_1, \dots, \varepsilon_n] \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

$$\tilde{\varepsilon}^T \tilde{\varepsilon} = [\tilde{y} - X\tilde{\theta}]^T [\tilde{y} - X\tilde{\theta}]$$

$$Z = [\tilde{y}^T - \tilde{\theta}^T X^T] [\tilde{y} - X\tilde{\theta}]$$

$$Z = \underbrace{\tilde{y}^T \tilde{y}}_A - \underbrace{\tilde{y}^T X\tilde{\theta}}_{A^T} - \underbrace{\tilde{\theta}^T X^T \tilde{y}}_A + \underbrace{\tilde{\theta}^T X^T X \tilde{\theta}}_B$$

$$\frac{\partial Z}{\partial \tilde{\theta}} = 0$$

$$\hookrightarrow -A - A + 2B\tilde{\theta} = 0 \quad \begin{cases} A = X^T \tilde{y} \\ B = X^T X \end{cases}$$

$$-X^T \tilde{y} - X^T \tilde{y} + 2X^T X \hat{\tilde{\theta}} = 0$$

$$-2X^T \tilde{y} + 2X^T X \hat{\tilde{\theta}} = 0$$

$$X^T X \hat{\tilde{\theta}} = X^T \tilde{y} \quad (\text{SEN})$$

$$\underbrace{(X^T X)^{-1}}_I X^T X \hat{\tilde{\theta}} = \underbrace{(X^T X)^{-1}}_I X^T \tilde{y}$$

$$\boxed{\hat{\tilde{\theta}} = (X^T X)^{-1} X^T \tilde{y}}$$

QUEM SÃO AS MATRIZES ?

Considerando n observações e duas variáveis X_1 e X_2 , temos:

$$\tilde{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}_n$$

$$X = \begin{bmatrix} 1 & X_{11} & X_{12} \\ \vdots & \vdots & \vdots \\ 1 & X_{n1} & X_{n2} \end{bmatrix}_{n \times p} \quad p=3$$

$$X^T = \begin{bmatrix} 1 & \dots & 1 \\ X_{11} & \dots & X_{n1} \\ X_{12} & \dots & X_{n2} \end{bmatrix}_p$$

$$X^T X = \begin{bmatrix} 1 & \dots & 1 \\ X_{11} & \dots & X_{n1} \\ X_{12} & \dots & X_{n2} \end{bmatrix}_{p \times n} \begin{bmatrix} 1 & X_{11} & X_{12} \\ \vdots & \vdots & \vdots \\ 1 & X_{n1} & X_{n2} \end{bmatrix}_{n \times p} = \begin{bmatrix} n & \sum X_{1i} & \sum X_{12} \\ \sum X_{1i}^2 & \sum X_{1i} X_{2i} & \\ \sum X_{12}^2 & & \end{bmatrix}_p$$

sim
simétrica

OBS: $\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} \\ a_{31} \end{bmatrix} \begin{bmatrix} a_{11} \\ a_{21} \\ a_{31} \end{bmatrix} = a_{11} \cdot a_{11} + a_{12} \cdot a_{21} + a_{13} \cdot a_{31}$

$(A+B)^T = A^T + B^T$
 $(AB)^T = B^T A^T$

$\frac{\partial A^T \theta}{\partial \theta} = \frac{\partial \theta^T A}{\partial \theta} = A$
 $\frac{\partial \theta^T B \theta}{\partial \theta} = 2B\theta$

$$\mathbf{X}^T \mathbf{y} = \begin{bmatrix} 1 & \dots & 1 \\ x_{11} & \dots & x_{n1} \\ x_{12} & \dots & x_{n2} \end{bmatrix} \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_{1i} y_i \\ \sum x_{2i} y_i \end{bmatrix}$$

Considerando o estimador $\hat{\theta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$, precisamos da inversa da matriz $\mathbf{X}^T \mathbf{X}$.

Como calcular as inversas?

- Matriz 2×2

$$Q = \begin{bmatrix} a & b \\ c & d \end{bmatrix} \quad Q^{-1} = \frac{1}{\det(Q)} \begin{bmatrix} d & -b \\ -c & a \end{bmatrix} \text{ em que } \det(Q) = ad - bc$$

- Matriz 3×3

$$Q = \begin{bmatrix} a & b & c \\ b & e & f \\ c & f & h \end{bmatrix} \quad Q^{-1} = \begin{bmatrix} A & B & C \\ B & E & F \\ C & F & H \end{bmatrix}$$

em que:

$$\begin{aligned} A &= (eh - f^2)/z & E &= (ah - c^2)/z \\ B &= -(bh - cf)/z & F &= -(af - bc)/z \\ C &= (bf - ce)/z & H &= (ae - b^2)/z \end{aligned}$$

$$z = aeh + 2bcf - af^2 - b^2h - c^2e \Rightarrow \det(Q)$$

Vamos verificar as matrizes e cálculos com o RLS!

Considerando o RLS

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i \quad i=1, \dots, n$$

$$\underset{\sim}{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \quad \underset{\sim}{x} = \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \quad \underset{\sim}{\theta} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} \quad \underset{\sim}{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

$$\underset{\sim}{x}^T \underset{\sim}{x} = \begin{bmatrix} 1 & \dots & 1 \\ x_1 & \dots & x_n \end{bmatrix} \begin{bmatrix} 1 & x_1 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} = \begin{bmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{bmatrix} \quad \underset{\sim}{x}^T \underset{\sim}{y} = \begin{bmatrix} 1 & \dots & 1 \\ x_1 & \dots & x_n \end{bmatrix} \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix}$$

$$(\underset{\sim}{x}^T \underset{\sim}{x})^{-1} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix}$$

$$\underset{\sim}{\hat{\theta}} = (\underset{\sim}{x}^T \underset{\sim}{x})^{-1} \underset{\sim}{x}^T \underset{\sim}{y} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix} \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix}$$

$$\underset{\sim}{\hat{\theta}} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 \cdot \sum y_i - \sum x_i \sum x_i y_i \\ -\sum x_i \sum y_i + n \sum x_i y_i \end{bmatrix}$$

$$\underset{\sim}{\hat{\theta}} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{bmatrix} = \begin{bmatrix} \frac{\sum x_i^2 \sum y_i - \sum x_i \sum x_i y_i}{n \sum x_i^2 - (\sum x_i)^2} \\ \frac{n \sum x_i y_i - \sum x_i \sum y_i}{n \sum x_i^2 - (\sum x_i)^2} \end{bmatrix}$$

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

→ equivalente $\hat{\beta}_1 = \frac{SP_{XY}}{SQ_X}$

Propriedades:

i) Os elementos de $\hat{\theta}_{\sim}$ são combinações lineares dos y_i

$$\hat{\theta}_{\sim} = \begin{bmatrix} \hat{\beta}_0 \\ \vdots \\ \hat{\beta}_k \end{bmatrix} \Rightarrow \hat{\beta}_j = \sum_{i=1}^n c_{ij} y_i$$

$$\hat{\theta}_{\sim} = \underbrace{(X^T X)^{-1} X^T}_{C_n} y_{\sim}$$

$C_n \Rightarrow$ matriz de coeficientes

$$C = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ \vdots & \vdots & & \vdots \\ c_{p1} & c_{p2} & \dots & c_{pn} \end{bmatrix}_{p \times n}$$

$$\hat{\theta}_{\sim} = C y_{\sim} = \begin{bmatrix} c_{11} & c_{12} & \dots & c_{1n} \\ c_{21} & c_{22} & \dots & c_{2n} \\ \vdots & \vdots & & \vdots \\ c_{p1} & c_{p2} & \dots & c_{pn} \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum c_{1i} y_i \\ \sum c_{2i} y_i \\ \vdots \\ \sum c_{pi} y_i \end{bmatrix}$$

ii) $\hat{\theta}_{\sim}$ é um estimador não viesado para θ_{\sim} .

$$E(A y_{\sim}) = A E(y_{\sim})$$

$$E(\hat{\theta}_{\sim}) = E \left[\underbrace{(X^T X)^{-1} X^T}_A y_{\sim} \right] = (X^T X)^{-1} X^T E(y_{\sim}) = \underbrace{(X^T X)^{-1} X^T X}_I \theta_{\sim} = \theta_{\sim}$$

iii) A matriz de covariâncias de $\hat{\theta}_{\sim}$ é dada por:

$$\text{Var}(A y) = A \text{Var}(y) A^T$$

$$\begin{aligned} \text{Var}(\hat{\theta}_{\sim}) &= \text{Var} \left[\underbrace{(X^T X)^{-1} X^T}_A y \right] = (X^T X)^{-1} X^T \text{Var}(y) X (X^T X)^{-1} \\ &= (X^T X)^{-1} X^T I \sigma^2 X (X^T X)^{-1} \\ &= \underbrace{(X^T X)^{-1} X^T X}_I (X^T X)^{-1} \sigma^2 \\ &= (X^T X)^{-1} \sigma^2 \end{aligned}$$

Para o modelo RLS, temos:

$$\text{Var}[\hat{\beta}] = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix} \cdot \sigma^2$$

$n \sum x_i^2$ $(X^T X)^{-1}$

$$= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{bmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{bmatrix} \sigma^2$$

$$= \begin{bmatrix} \frac{\sum x_i^2}{n \sum x_i^2} & \frac{-\sum x_i}{n \sum x_i^2} \\ \frac{-\sum x_i}{n \sum x_i^2} & \frac{n}{n \sum x_i^2} \end{bmatrix} \sigma^2$$

$$= \begin{bmatrix} \frac{\sum x_i^2 + n\bar{x}}{n \sum x_i^2} & -\frac{\sum x_i/n}{\sum x_i^2} \\ -\frac{\sum x_i/n}{\sum x_i^2} & \frac{1}{\sum x_i^2} \end{bmatrix} \sigma^2$$

$$= \begin{bmatrix} \frac{1}{n} + \frac{\bar{x}}{\sum x_i^2} & -\frac{\bar{x}}{\sum x_i^2} \\ -\frac{\bar{x}}{\sum x_i^2} & \frac{1}{\sum x_i^2} \end{bmatrix} \sigma^2$$

$\text{Var}(\hat{\beta}_0)$ $\text{Var}(\hat{\beta}_1)$

$\text{Cov}(\hat{\beta}_0, \hat{\beta}_1)$

$$\begin{aligned} (*) \sum x_i^2 &= \sum x_i^2 - \frac{2(\sum x_i)^2}{n} + \frac{2(\sum x_i)^2}{n} \\ &= \sum x_i^2 - 2\bar{x}(\sum x_i) + 2\bar{x}(\sum x_i) \cdot \frac{n}{n} \\ &= \sum x_i^2 - 2\bar{x}(\sum x_i) + 2n\bar{x}^2 \\ &= \underbrace{\sum x_i^2 - 2\bar{x}(\sum x_i) + n\bar{x}}_{\sum (x_i - \bar{x})^2} + n\bar{x} \\ &= \sum (x_i - \bar{x})^2 + n\bar{x} \\ &= \sum x_i^2 + n\bar{x} \end{aligned}$$

Vimos que:

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

$$\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum x_i^2}$$

$$\text{Cov}(\hat{\beta}_0, \hat{\beta}_1) = -\frac{\bar{x} \sigma^2}{\sum x_i^2}$$

iv) Como resultado dos itens i, ii e iii e que $\underline{y} \sim N(\underline{x}\underline{\theta}, \sigma^2)$ 8

temos que: $\hat{\underline{\theta}} \sim N(\underline{\theta}, (\underline{x}^T \underline{x})^{-1} \sigma^2)$

v) Dada uma combinação linear dos parâmetros

$$\underline{c}^T \hat{\underline{\theta}} = [c_0 \ c_1 \ \dots \ c_k] \begin{bmatrix} \theta_0 \\ \theta_1 \\ \vdots \\ \theta_k \end{bmatrix} = c_0 \theta_0 + c_1 \theta_1 + \dots + c_k \theta_k$$

Um estimador de mínimos quadrados, não viesado e de variância mínima é dado por: $\underline{c}^T \hat{\underline{\theta}}$

$$E(\underline{c}^T \hat{\underline{\theta}}) = \underline{c}^T E(\hat{\underline{\theta}}) = \underline{c}^T \underline{\theta}$$

$$\text{Var}(\underline{c}^T \hat{\underline{\theta}}) = \underline{c}^T \text{Var}(\hat{\underline{\theta}}) \underline{c} = \underline{c}^T (\underline{x}^T \underline{x})^{-1} \underline{c} \sigma^2$$

Desta forma, $\underline{c}^T \hat{\underline{\theta}} \sim N(\underline{c}^T \underline{\theta}, \underline{c}^T (\underline{x}^T \underline{x})^{-1} \underline{c} \sigma^2)$

vi) A aproximação de mínimos quadrados ($\hat{\underline{y}}$) para \underline{y} é dada por:

$$\hat{\underline{y}} = \underline{x} \hat{\underline{\theta}} = \underline{x} (\underline{x}^T \underline{x})^{-1} \underline{x}^T \underline{y} = \underline{H} \underline{y}$$

↗ Hat matrix

Hat matrix (matriz de projeção)

$$E(\hat{\underline{y}}) = E(\underline{H} \underline{y}) = \underline{H} E(\underline{y}) = \underline{H} \underline{x} \underline{\theta} = \underline{x} \underbrace{(\underline{x}^T \underline{x})^{-1} \underline{x}^T \underline{x}}_{\underline{I}} \underline{\theta} = \underline{x} \underline{\theta} = \underline{y}$$

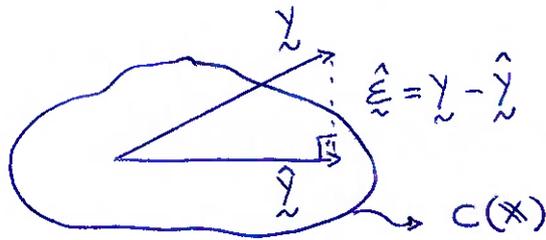
$$\begin{aligned} \text{Var}(\hat{\underline{y}}) &= \text{Var}(\underline{H} \underline{y}) = \underline{H} \text{Var}(\underline{y}) \underline{H}^T \\ &= \underline{x} (\underline{x}^T \underline{x})^{-1} \underline{x}^T \underbrace{\sigma^2}_{\text{circled}} \underline{x} (\underline{x}^T \underline{x})^{-1} \underline{x}^T \\ &= \underline{x} \underbrace{(\underline{x}^T \underline{x})^{-1} \underline{x}^T \underline{x} (\underline{x}^T \underline{x})^{-1} \underline{x}^T}_{\underline{I}} \sigma^2 \\ &= \underbrace{\underline{x} (\underline{x}^T \underline{x})^{-1} \underline{x}^T}_{\underline{H}} \sigma^2 = \underline{H} \sigma^2 \end{aligned}$$

$$\hat{\underline{y}} \sim N(\underline{y}, \underline{H} \sigma^2) \Rightarrow \hat{\underline{y}} \sim N(\underline{x} \underline{\theta}, \underline{x} (\underline{x}^T \underline{x})^{-1} \underline{x}^T \sigma^2)$$

ANÁLISE DE VARIÂNCIA E TESTE F

Relembrando!

A matriz $H = X(X^T X)^{-1} X^T$ é o projetor ortogonal de \underline{y} no espaço coluna de $X \Rightarrow C(X)$.



Pelo teorema de Pitágoras, temos:

$$\|\underline{y}\|^2 = \|\hat{\underline{y}}\|^2 + \|\hat{\underline{\epsilon}}\|^2$$

* O vetor de observações \underline{y} , pode ser decomposto na soma de dois vetores ortogonais

↳ o vetor $\hat{\underline{y}}$ do espaço de estimação;

↳ o vetor $\hat{\underline{\epsilon}}$ do espaço residual.

Essa decomposição é o fundamento da análise de variância.

Considerando a decomposição,

$$\|\underline{y}\|^2 = \|\hat{\underline{y}}\|^2 + \|\hat{\underline{\epsilon}}\|^2, \text{ temos:}$$

$$\|\underline{y}\|^2 = \underline{y}^T \underline{y}$$

$$\|\hat{\underline{y}}\|^2 = \|\underline{X} \hat{\underline{\theta}}\|^2 = (\underline{X} \hat{\underline{\theta}})^T (\underline{X} \hat{\underline{\theta}})$$

$$\|\hat{\underline{\epsilon}}\|^2 = \|\underline{y} - \underline{X} \hat{\underline{\theta}}\|^2 = (\underline{y} - \underline{X} \hat{\underline{\theta}})^T (\underline{y} - \underline{X} \hat{\underline{\theta}})$$

Desta forma,

$$\begin{aligned} \underline{y}^T \underline{y} &= (\underline{X} \hat{\underline{\theta}})^T (\underline{X} \hat{\underline{\theta}}) + (\underline{y} - \underline{X} \hat{\underline{\theta}})^T (\underline{y} - \underline{X} \hat{\underline{\theta}}) \\ &= (\hat{\underline{\theta}}^T \underline{X}^T) (\underline{X} \hat{\underline{\theta}}) + (\underline{y}^T - \hat{\underline{\theta}}^T \underline{X}^T) (\underline{y} - \underline{X} \hat{\underline{\theta}}) \\ &= \hat{\underline{\theta}}^T \underline{X}^T \underline{X} \hat{\underline{\theta}} + \underline{y}^T \underline{y} - \underline{y}^T \underline{X} \hat{\underline{\theta}} - \hat{\underline{\theta}}^T \underline{X}^T \underline{y} + \hat{\underline{\theta}}^T \underline{X}^T \underline{X} \hat{\underline{\theta}} \end{aligned}$$

Usando o resultado do SEN $\underline{X}^T \underline{X} \hat{\underline{\theta}} = \underline{X}^T \underline{y}$, teremos:

$$\tilde{y}^T \tilde{y} = \hat{\theta}^T X^T \tilde{y} + \tilde{y}^T \tilde{y} - \tilde{y}^T X \hat{\theta} - \hat{\theta}^T X^T \tilde{y} + \hat{\theta}^T X^T \tilde{y}$$

$$\tilde{y}^T \tilde{y} = \hat{\theta}^T X^T \tilde{y} + (\tilde{y}^T \tilde{y} - \tilde{y}^T X \hat{\theta})$$

↓ SQ Parâmetros → SQ Resíduos
 SQ Total (não corrigida)

OBS: $SQ_{Total} = \sum y_i^2 - \frac{(\sum y_i)^2}{n}$
 ↓ SQ Total (Ncorr)

↳ correção
 ↳ está embutida na SQ Parâmetros *
 veja a seguir

$SQ_{Parâmetros} = SQ_{Regressão} + Correção$

ou seja,

$SQ_{Total} (NC) = SQ_{Parâmetros} + SQ_{Resíduos}$

ou

$SQ_{Total} = SQ_{Regressão} + SQ_{Resíduos}$

* Considerando a RLS com variável X centrada

$y_i = \alpha + \beta_1 (x_i - \bar{x}) + \epsilon_i$
 ↳ x_i

$SQ_{Param} = \hat{\theta}^T X^T \tilde{y} = [\hat{\alpha} \hat{\beta}_1] \begin{bmatrix} \sum y_i \\ \sum x_i y_i \end{bmatrix}$

$\hat{\alpha} = \bar{y}$
 $\hat{\beta}_1 = \frac{\sum x_i y_i}{\sum x_i^2}$

$= \hat{\alpha} \sum y_i + \hat{\beta}_1 \sum x_i y_i$
 $= \frac{\sum y_i}{n} \sum y_i + \frac{\sum x_i y_i \sum x_i y_i}{\sum x_i^2}$
 $= \frac{(\sum y_i)^2}{n} + \frac{(\sum x_i y_i)^2}{\sum x_i^2}$
 ↓ ↓
 correção + SQ Regressão

$SQ_{Total} (NC) = SQ_{Param} + SQ_{Resíduos}$

$SQ_{Total} (NC) = Correção + SQ_{Reg} + SQ_{Resíduos}$

$SQ_{Total} (NC) - Correção = SQ_{Reg} + SQ_{Resíduos}$

$SQ_{Total} = SQ_{Regressão} + SQ_{Resíduos}$

NÚMERO DE GRAUS DE LIBERDADE

1) número de graus de liberdade associados à uma SQ é dado pela característica da matriz idempotente de sua forma quadrática.

$SQ \Rightarrow \tilde{y}^T A \tilde{y}$ sendo A uma matriz idempotente ($A^2=A$) então, o traço(A) = gl da SQ.

- O traço de uma matriz corresponde a soma dos elementos de sua diagonal principal.

- propriedades do traço:

$$\begin{aligned} \text{tr}(A) &= \text{tr}(A^T) & \text{tr}(A+B) &= \text{tr}(A) + \text{tr}(B) \\ \text{tr}(cA) &= c \text{tr}(A) & \text{tr}(A \cdot B) &= \text{tr}(BA) \end{aligned}$$

SQ Total (NC)

$$SQ_{Total}(NC) = \tilde{y}^T \tilde{y} = \tilde{y}^T I \tilde{y} \Rightarrow \text{FORMA QUADRÁTICA}$$

↳ É IDEMPOTENTE?
I · I = I sim.

Então, $\text{tr}(I) = n$ é o grau de liberdade associado à $SQ_{Total}(NC)$

Correcção

$$C = \frac{(\sum y_i)^2}{n}$$

$$C = [y_1 \dots y_n] \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \begin{bmatrix} 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \cdot \frac{1}{n}$$

↓ ↓
 $\tilde{1}$ $\tilde{1}^T$
↓ ↓
 $\tilde{1}$ $\tilde{1}$

$$C = \underbrace{\tilde{y}^T \tilde{1} \tilde{1}^T \tilde{y}}_{\tilde{J}} \cdot \frac{1}{n} = \tilde{y}^T \tilde{J} \tilde{y} \cdot \frac{1}{n}$$

$$\tilde{J} = \begin{bmatrix} 1 & \dots & 1 \\ \vdots & & \vdots \\ 1 & \dots & 1 \end{bmatrix}_n$$

Desta forma,

$$SQ_{Total} = \tilde{y}^T \tilde{y} - \tilde{y}^T \tilde{J} \tilde{y} \frac{1}{n}$$

$$= \tilde{y}^T \tilde{I} \tilde{y} - \tilde{y}^T \tilde{J} \tilde{y} \cdot \frac{1}{n}$$

$$= \tilde{y}^T \left[\tilde{I} - \frac{1}{n} \tilde{J} \right] \tilde{y} \Rightarrow \text{FORMA QUAD.}$$

É IDEMPOTENTE?

$$\left[\tilde{I} - \frac{1}{n} \tilde{J} \right] \left[\tilde{I} - \frac{1}{n} \tilde{J} \right] = \tilde{I} \tilde{I} - \tilde{I} \frac{1}{n} \tilde{J} - \frac{1}{n} \tilde{J} \tilde{I} + \frac{1}{n^2} \tilde{J} \tilde{J}$$

$$= \tilde{I} - \frac{1}{n} \tilde{J} - \frac{1}{n} \tilde{J} + \frac{\tilde{J} \tilde{J}}{n^2}$$

$$= \tilde{I} - \frac{1}{n} \tilde{J} - \frac{1}{n} \tilde{J} + \frac{\tilde{J}}{n}$$

$$= \tilde{I} - \frac{1}{n} \tilde{J} \rightarrow \text{idempotente}$$

$$\begin{aligned} * \tilde{J} \tilde{J} &= \begin{bmatrix} 1 & \dots & 1 \\ \vdots & & \vdots \\ 1 & \dots & 1 \end{bmatrix} \begin{bmatrix} 1 & \dots & 1 \\ \vdots & & \vdots \\ 1 & \dots & 1 \end{bmatrix} = \begin{bmatrix} n & \dots & n \\ \vdots & & \vdots \\ n & \dots & n \end{bmatrix} \\ &= n \begin{bmatrix} 1 & \dots & 1 \\ \vdots & & \vdots \\ 1 & \dots & 1 \end{bmatrix} = n \tilde{J} \end{aligned}$$

$$\text{Então } \text{tr} \left(\tilde{I} - \frac{1}{n} \tilde{J} \right) = \text{tr}(\tilde{I}) - \text{tr} \left(\frac{1}{n} \tilde{J} \right)$$

$$= \text{tr}(\tilde{I}) - \frac{1}{n} \text{tr}(\tilde{J})$$

$$= n - \frac{1}{n} \cdot n = n - 1 \text{ gl associadas à } \underline{SQ_{Total}}$$

SQ Regressão

$$SQ_{Reg} = SQ_{Param} - C$$

$$= \hat{\theta}^T \tilde{X}^T \tilde{y} - \frac{1}{n} \tilde{y}^T \tilde{J} \tilde{y}$$

$$= \left[(\tilde{X}^T \tilde{X})^{-1} \tilde{X}^T \tilde{y} \right]^T \tilde{X}^T \tilde{y} - \frac{1}{n} \tilde{y}^T \tilde{J} \tilde{y}$$

$$= \tilde{y}^T \underbrace{\tilde{X}^T (\tilde{X}^T \tilde{X})^{-1} \tilde{X}^T}_{\tilde{H}} \tilde{y} - \frac{1}{n} \tilde{y}^T \tilde{J} \tilde{y}$$

$$= \tilde{y}^T \tilde{H} \tilde{y} - \frac{1}{n} \tilde{y}^T \tilde{J} \tilde{y}$$

$$= \tilde{y}^T \left[\tilde{H} - \frac{1}{n} \tilde{J} \right] \tilde{y}$$

É IDEMPOTENTE?

$$\begin{aligned} \left[\tilde{H} - \frac{1}{n} \tilde{J} \right] \left[\tilde{H} - \frac{1}{n} \tilde{J} \right] &= \\ &= \tilde{H} \tilde{H} - \tilde{H} \frac{1}{n} \tilde{J} - \frac{1}{n} \tilde{J} \tilde{H} + \frac{1}{n^2} \tilde{J} \tilde{J} \end{aligned}$$

OBS:
HJ = JH = J
H² = H
JJ = nJ

$$= \tilde{H} - \frac{1}{n} \tilde{J} - \frac{1}{n} \tilde{J} + \frac{\tilde{J} \tilde{J}}{n^2}$$

$$= \tilde{H} - \frac{1}{n} \tilde{J} - \frac{1}{n} \tilde{J} + \frac{\tilde{J}}{n}$$

$$= \tilde{H} - \frac{1}{n} \tilde{J}$$

↳ IDEMPOTENTE!

$$\begin{aligned}
 \text{Então, } \text{tr}(H - \frac{1}{n}J) &= \text{tr}(H) - \frac{1}{n} \text{tr}(J) \\
 &= \text{tr}(\underbrace{X(X^T X)^{-1} X^T}_A \underbrace{J}_B) - \frac{1}{n} \text{tr}(J) \\
 &\quad \times \text{tr}(AB) = \text{tr}(BA) \text{ ver propriedades} \\
 &= \text{tr}(\underbrace{X^T X (X^T X)^{-1}}_I) - \frac{1}{n} \text{tr}(J) \\
 &= \text{tr}(I) - \frac{1}{n} \text{tr}(J) \\
 &= p - \frac{1}{n} n = \underline{p-1} \parallel \text{gl associado à SQ Reg}
 \end{aligned}$$

SQ Resíduo

$$\begin{aligned}
 \text{SQ Resíduo} &= \text{SQ Total} - \text{SQ Reg} \\
 &= \text{SQ Total (NC)} - \text{SQ Param} \\
 &= \tilde{y}^T I \tilde{y} - \tilde{y}^T H \tilde{y} \\
 &= \tilde{y}^T [I - H] \tilde{y}
 \end{aligned}$$

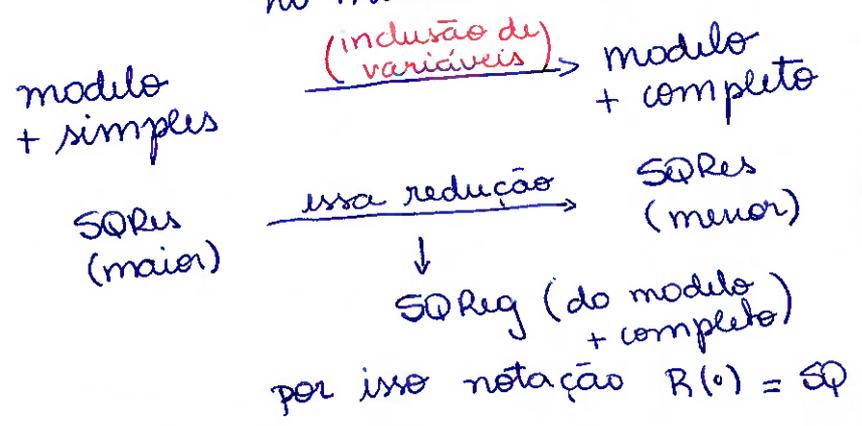
↳ É IDEMPOTENTE?

$$\begin{aligned}
 [I - H][I - H] &= II - IH - HI + HH \\
 &= I - H - H + H \\
 &= I - H \rightarrow \text{IDEMPOTENTE!}
 \end{aligned}$$

$$\begin{aligned}
 \text{Então, } \text{tr}(I - H) &= \text{tr}(I) - \text{tr}(H) \\
 &= \underline{n - p} \parallel \text{gl associado à SQ Resíduo}
 \end{aligned}$$

TABELA ANAVA e TESTE F

SQ Regressão ⇒ o quanto reduz a SQ Resíduo quando incluímos um parâmetro (ou variável) no modelo.



Vamos considerar 3 modelos

- M1: $Y_i = \beta_0 + \epsilon_i$ $R(\beta_0) =$ Soma Quadrada de parâmetros do M1
- M2: $Y_i = \beta_0 + \beta_1 X_i + \epsilon_i$ $R(\beta_0, \beta_1) =$ SQ Parâmetros do M2
- M3: $Y_{ij} = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \epsilon_i$ $R(\beta_0, \beta_1, \beta_2) =$ SQ Parâmetros do M3

Vimos que:

$$SQ_{Total}(NC) = SQ_{Parâmetros} + SQ_{Resíduos}$$

$\sum y_i^2 \rightarrow$ é sempre a mesma

quanto maior o número de parâmetros no modelo $\uparrow SQ_{Param}$ e $\downarrow SQ_{Res}$

Logo, a SQ_{Reg} (considerando $M1 \rightarrow M2$) é dada por

$$\begin{aligned}
 R(\beta_1 | \beta_0) &= R(\beta_0, \beta_1) - R(\beta_0) \\
 &= SQ_{Param}(M2) - SQ_{Param}(M1) \\
 &= [SQ_{Total}(NC) - SQ_{Res}(M2)] - [SQ_{Total}(NC) - SQ_{Res}(M1)] \\
 &= SQ_{Total}(NC) - SQ_{Res}(M2) - SQ_{Total}(NC) + SQ_{Res}(M1) \\
 &= SQ_{Res}(M1) - SQ_{Res}(M2)
 \end{aligned}$$

* A $SQ_{Regressão}$, ao considerar o M2, equivale à redução na $SQ_{Resíduos}$ devido a inclusão do parâmetro β_1 no modelo $Y_i = \beta_0 + \epsilon_i$ (com apenas β_0)

A SQ_{Reg} (considerando $M2 \rightarrow M3$) é dada por:

$$\begin{aligned}
 R(\beta_2 | \beta_0, \beta_1) &= R(\beta_0, \beta_1, \beta_2) - R(\beta_0, \beta_1) \\
 &= SQ_{Param}(M3) - SQ_{Param}(M2) \\
 &= [SQ_{Total}(NC) - SQ_{Res}(M3)] - [SQ_{Total}(NC) - SQ_{Res}(M2)] \\
 &= SQ_{Res}(M2) - SQ_{Res}(M3)
 \end{aligned}$$

* A SQ_{Reg} , ao considerar o M3, equivale à redução na $SQ_{Resíduos}$ devido a inclusão do parâmetro β_2 no modelo $Y_{ij} = \beta_0 + \beta_1 X_i + \epsilon_i$

Análise de Variância SEQUENCIAL

15

Nessa análise os parâmetros vão sendo adicionados sequencialmente.

Considerando uma variável resposta Y e duas variáveis regressoras (X_1 e X_2), temos o seguinte esquema de ANAVA.

FV	GL	SQ	QM	Fc
Parâmetros	$p = 3$	$R(\beta_0, \beta_1, \beta_2)$	QM_{Par}	$F_{par} = \frac{QM_{Par}}{QM_{Res}}$
β_0	1	$R(\beta_0) = C$	—	
$\beta_1 \beta_0$	1	$R(\beta_0, \beta_1) - R(\beta_0)$	QM_1	$F_1 = QM_1 / QM_{Res}$
$\beta_2 \beta_0, \beta_1$	1	$R(\beta_0, \beta_1, \beta_2) - R(\beta_0, \beta_1)$	QM_2	$F_2 = QM_2 / QM_{Res}$
Resíduos	$n - p = n - 3$	per diferença	QM_{Res}	
Total (NC)	n	$SQ_{Total(NC)} = Y^T Y$		

Em F_{par} , temos:

$$H_0: \beta_0 = \beta_1 = \beta_2 = 0 \quad \text{vs} \quad H_a: \beta_j \neq 0, \text{ para pelo menos } 1 j.$$

Em F_1 , temos

$$H_0: \beta_1 = 0 \quad \text{vs} \quad H_a: \beta_1 \neq 0$$

(ignorando a presença da X_2)

Em F_2 , temos:

$$H_0: \beta_2 = 0 \quad \text{vs} \quad H_a: \beta_2 \neq 0$$

(ajustado para X_1)

Muito importante \Rightarrow depende da ordem da variável no modelo

Considerando as Somas de Quadrados "Corrigidas"

FV	GL	SQ	QM	Fc
Regressão ↳ Par - C	$p-1 = 2$	$R(\beta_0, \beta_1, \beta_2) - R(\beta_0)$	QM _{Reg}	F _{reg}
$\beta_1 \beta_0$	1	$R(\beta_0, \beta_1) - R(\beta_0)$	QM ₁	F ₁
$\beta_2 \beta_0, \beta_1$	1	$R(\beta_0, \beta_1, \beta_2) - R(\beta_0, \beta_1)$	QM ₂	F ₂
Resíduos	$n-p = n-3$	por diferença	QM _{Res}	—
Total	$n-1$	$\underline{X^T Y} - C$ ↳ $R(\beta_0)$	—	—

Em F_{reg}, temos:

H₀: $\beta_1 = \beta_2 = 0$ vs H_a: β_1 ou $\beta_2 \neq 0$

Em F₁ e F₂ não há alterações (Tabela anterior)

Análise de Variância PARCIAL

Nessa análise verifica-se a contribuição de cada variável, dado que todas as outras já estão no modelo.

$$R(\beta_k | \beta_0, \dots, \beta_{k-1}, \beta_{k+1}, \dots, \beta_m) = \frac{\hat{\beta}_{kk}^2}{(X_{kk}^T X)^{-1}}$$

TESTE DE HIPÓTESES

Seja, $c^T \theta$ uma combinação linear dos parâmetros e seu estimador $c^T \hat{\theta}$. Então,

$$c^T \hat{\theta} \sim N(c^T \theta; c^T (X^T X)^{-1} c \sigma^2)$$

Hipóteses como:

H₀: $c^T \theta = c^T \theta_0$ vs

- H_a: $c^T \theta \neq c^T \theta_0 \rightarrow$ BILATERAL
- H_a: $c^T \theta > c^T \theta_0 \rightarrow$ UNI. DIREITA
- H_a: $c^T \theta < c^T \theta_0 \rightarrow$ UNI. ESQUERDA

Podem ser testadas com a estatística:

$$t_c = \frac{c^T \hat{\theta} - c^T \theta_0}{\sqrt{\widehat{\text{var}}(c^T \hat{\theta})}} = \frac{c^T \hat{\theta} - c^T \theta_0}{\sqrt{c^T (X^T X)^{-1} c \text{QM}_{Res}}} \sim t_{n-p}$$

de resíduos

Exemplos:

1) $H_0: \beta_1 = 0$ ignorando $X_2 \Rightarrow \underline{C}^T = (0, 1, 0)$
 $\underline{\theta}^T = (\beta_0, \beta_1, \beta_2)$

$\underline{C}^T \underline{\theta}_0 \Rightarrow (0, 1, 0) \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{bmatrix} = 0 \Rightarrow \beta_1 = 0$

2) $H_0: \beta_1 = \beta_2 \Rightarrow \beta_1 - \beta_2 = 0 \Rightarrow \underline{C}^T = (0, 1, -1)$
 $\underline{\theta}^T = (\beta_0, \beta_1, \beta_2)$

$\underline{C}^T \underline{\theta}_0 \Rightarrow [0, 1, -1] \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \end{bmatrix} = 0 \Rightarrow \beta_1 - \beta_2 = 0$

PRINCÍPIO DO RESÍDUO CONDICIONAL (PRC)

Testes de hipóteses mais gerais podem ser feitos por meio da comparação de modelos e uso do PRC.



EXEMPLO: Considerar n observações e k variáveis regressoras.

O modelo completo é dado por:

$Y_{ij} = \beta_0 + \beta_1 W_{i1} + \beta_2 W_{i2} + \dots + \beta_k W_{ik} + \epsilon_{ij}$, em que

→ W_{ij} são as próprias X_{ij} ou funções deles (Ex: X_{i1}^2 ou $X_{i1} X_{i2} \dots$)

→ $\underline{\epsilon} \sim N(\phi, I\sigma^2)$

Matricialmente, $\underline{Y} = \underline{W}_c \underline{\theta}_c + \underline{\epsilon}_c$ $p = k+1$ parâmetros
 \downarrow $n \times 1$ \downarrow $n \times p$ \downarrow $p \times 1$ \downarrow $n \times 1$

Pelo método de mínimos quadrados, temos:

$\hat{\theta}_c = (W_c^T W_c)^{-1} W_c^T Y$

$SQ_{Total}(NC) = \underline{Y}^T \underline{Y}$ (n gl)

$\hat{Y}_c = W_c \hat{\theta}_c$

$SQ_{Parc} = \hat{\theta}_c^T W_c^T Y$ (p gl)

$SQ_{Resc} = SQ_{Total}(NC) - SQ_{Parc}$ (n-p gl)

Agora, considere o teste da seguinte hipótese

$$H_0: \beta_{m+1} = \beta_{m+2} = \dots = \beta_k = 0$$

Sob H_0 , o modelo reduzido é dado por:

$$Y_i = \beta_0 + \beta_1 W_{i1} + \dots + \beta_m W_{im} + \epsilon_i$$

Matricialmente, $\underset{\sim}{Y} = \underset{\sim}{W} \underset{\sim}{\hat{\theta}}_r + \underset{\sim}{\epsilon}_r$ $q = m+1$ parâmetros

\downarrow
 $n \times 1$

\downarrow
 $n \times q$

\downarrow
 $q \times 1$

\downarrow
 $n \times 1$

$q < p$

Pelo método dos mínimos quadrados, temos:

$$\hat{\theta}_r = (W_r^T W_r)^{-1} W_r^T Y$$

$$SQ_{Total}(NC) = Y^T Y \quad (n \text{ gl})$$

$$\hat{Y}_r = W_r \hat{\theta}_r$$

$$SQ_{Par}_r = \hat{\theta}_r^T W_r^T Y \quad (q \text{ gl} \Rightarrow q = m+1)$$

$$SQ_{Res}_r = SQ_{Total}(NC) - SQ_{Par}_r \quad (n-q)$$

Logo, quando passamos do modelo reduzido (q parâmetros) para o modelo completo (p parâmetros) há uma redução na soma de Quadrados de Resíduos, dada por:

$$\begin{aligned}
 R(\beta_{m+1}, \beta_{m+2}, \dots, \beta_k | \beta_0, \beta_1, \dots, \beta_m) &= R(\beta_0, \dots, \beta_k) - R(\beta_0, \dots, \beta_m) \\
 &= SQ_{Par}_c - SQ_{Par}_r \\
 &= SQ_{Res}_r - SQ_{Res}_c \quad \left. \vphantom{R(\beta_{m+1}, \dots, \beta_k)} \right\} (p-q \text{ gl})
 \end{aligned}$$

Temos ainda que:

$$F = \frac{\frac{SQ_{Res}_r - SQ_{Res}_c}{p-q}}{QM_{Res}_c} \sim F_{p-q, n-p; p} \text{ e rejeita-se a hipótese } H_0 \text{ com um nível } 100\% \text{ de significância se } F > F_{p-q, n-p; p}$$

VER OS DEMAIS EXEMPLOS NA APOSTILA.