

Modelos Lineares com Matriz de Planejamento de Fatores Completos

O modelo Linear Geral na forma matricial pode ser escrito como

$$\underline{Y} = X \underline{\beta} + \underline{\epsilon}$$

$$\underline{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{n \times 1} \quad X = \begin{bmatrix} 1 & x_{11} & \dots & x_{K1} \\ 1 & x_{12} & & x_{K2} \\ \vdots & & & \\ 1 & x_{1n} & & x_{Kn} \end{bmatrix}_{n \times (K+1)} \quad \underline{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_K \end{bmatrix}_{(K+1) \times 1} \quad \underline{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}_{n \times 1}$$

$$\Rightarrow \begin{cases} Y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{21} + \dots + \beta_K x_{K1} + \epsilon_1 \\ \vdots \\ Y_n = \beta_0 + \beta_1 x_{1n} + \beta_2 x_{2n} + \dots + \beta_K x_{Kn} + \epsilon_n \end{cases}$$

$\underline{Y}$ - vetor aleatório observável de variáveis resposta

X - matriz não aleatória de variáveis explicativas (ou preditoras) $n > K+1$

$\underline{\beta}$ - vetor de parâmetros desconhecidos

$\underline{\epsilon}$ - vetor aleatório não observável

$$E(\underline{\varepsilon}) = \underline{0} \Rightarrow E(\underline{Y}) = X\beta$$

$$\text{Var}(\underline{\varepsilon}) = \Sigma$$

$r(X) = n^\circ$ de colunas linearmente independentes de X

Se $r(X) = k+1$, X é de posto completo.

Inferência para $\underline{\varepsilon} \sim N_n(\underline{0}, \sigma^2 I_n)$

$r(X) = k+1$

σ^2 desconhecido

$$\underline{Y} = X\beta + \underline{\varepsilon} \Rightarrow \underline{Y} \sim N_n(X\beta, \sigma^2 I_n)$$

$$E(\underline{Y} | X) = X\beta$$

$$E(Y_i | \underline{X}_i) = \beta_0 + \beta_1 x_{1i} + \dots + \beta_k x_{ki} = \underline{X}_i \beta$$

$\underline{X}_i$ - i -ésima linha da matriz X , $i = 1, 2, \dots, n$

$$\Rightarrow E(\underline{\varepsilon}) = \underline{0} \Rightarrow E(\varepsilon_i) = 0 \quad i = 1, 2, \dots, n$$

$$\text{Var}(\underline{\varepsilon}) = \sigma^2 I_n \Rightarrow \text{Var}(\varepsilon_i) = \sigma^2 \quad \forall i \quad (\text{homocedasticidade})$$

$$\text{Cov}(\varepsilon_i, \varepsilon_l) = 0 \quad i \neq l$$

$$\underline{\varepsilon} \sim N_n \Rightarrow \varepsilon_i, \varepsilon_l \text{ são independentes } \neq$$

$$\underline{\varepsilon} \sim N_n \Rightarrow \varepsilon_i \sim N(0, \sigma^2) \quad i = 1, 2, \dots, n$$

Estimacões de β

$$E(Y_i | X_i) = \beta_0 + \beta_1 x_{1i} + \dots + \beta_K x_{Ki} = X_i \beta \quad (\text{parâmetro})$$

estimado por

$$\begin{aligned} E(\hat{Y}_i | X_i) &= \hat{\beta}_0 + \hat{\beta}_1 x_{1i} + \dots + \hat{\beta}_K x_{Ki} \\ &= X_i \hat{\beta} = \hat{Y}_i \quad \hat{\beta} = [\hat{\beta}_0 \ \hat{\beta}_1 \ \dots \ \hat{\beta}_K] \\ &\quad \hookrightarrow \text{estimador de } \beta \end{aligned}$$

Prever o valor de $Y_i | X_i$ por

$$E(\hat{Y}_i | X_i) = X_i \hat{\beta} = \hat{Y}_i$$

$$\hat{Y}_i \begin{cases} \text{estimador de } E(Y_i | X_i) \\ \text{previsor de } Y | X_i \end{cases}$$

Para os elementos da amostra

$$\text{Resíduos: } e_i = Y_i - \hat{Y}_i \quad i = 1, 2, \dots, n$$

$$\text{Vetor de Resíduos: } \underline{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} = \begin{bmatrix} Y_1 - \hat{Y}_1 \\ Y_2 - \hat{Y}_2 \\ \vdots \\ Y_n - \hat{Y}_n \end{bmatrix} = \underline{Y} - \underline{\hat{Y}}$$

$$\hat{\underline{y}} = \begin{bmatrix} \hat{y}_1 \\ \hat{y}_2 \\ \vdots \\ \hat{y}_n \end{bmatrix} = X \hat{\underline{\beta}}$$

Estimador de Mínimos Quadrados de $\underline{\beta}$

Soma de Quadrados dos Resíduos - S

$$S = \sum_{i=1}^n e_i^2 = \underline{e}' \underline{e} = (\underline{y} - \hat{\underline{y}})' (\underline{y} - \hat{\underline{y}}) =$$

$$(\underline{y} - X \hat{\underline{\beta}})' (\underline{y} - X \hat{\underline{\beta}}) = \underline{y}' \underline{y} - \underbrace{\underline{y}' X \hat{\underline{\beta}}}_{1 \times n \quad n \times (k+1) \quad (k+1) \times 1} - \hat{\underline{\beta}}' X' \underline{y} + \hat{\underline{\beta}}' X' X \hat{\underline{\beta}} =$$

$\downarrow$
 1×1

$$= \underline{y}' \underline{y} - 2 \underline{y}' X \hat{\underline{\beta}} + \hat{\underline{\beta}}' X' X \hat{\underline{\beta}}$$

$$f(\underline{x}) = \underline{a}' \underline{x} \Rightarrow \frac{\partial f(\underline{x})}{\partial \underline{x}} = \underline{a}$$

$$f(\underline{x}) = \underline{x}' A \underline{x} \Rightarrow \frac{\partial f(\underline{x})}{\partial \underline{x}} = 2A \underline{x}$$

$$\therefore \frac{\partial S}{\partial \hat{\underline{\beta}}} = -2X' \underline{y} + 2X' X \hat{\underline{\beta}} = \underline{0} \quad k+1 \text{ equações}$$

$\Rightarrow$

$$\Rightarrow X'X\hat{\beta} = X'Y \quad \text{Sistema de equações Normais}$$

$$r(X) = k+1 \Rightarrow r(X'X) = k+1 \Rightarrow$$

$$X'X \text{ é de posto completo } = k+1 \Rightarrow \exists (X'X)^{-1}$$

$$\Rightarrow \hat{\beta} = \underbrace{(X'X)^{-1} X'Y}_{(k+1) \times (k+1) \quad (k+1) \times n \quad n \times 1} \quad \text{est. min. quad. de } \beta$$

$(k+1) \times 1$

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_k \end{bmatrix}$$

Ver exemplo da pág. 65 das notas de aula

Y - renda X_1 - anos de escolaridade X_2 - idade

$$\hat{\beta} = \begin{bmatrix} 2,3 \\ 2,1 \\ -0,2 \end{bmatrix} \quad \hat{Y} = 2,3 + 2,1x_1 - 0,2x_2$$

$x_1 = 7 \quad x_2 = 30 \quad \hat{Y} = 10,7$
 $\left\{ \begin{array}{l} \text{estimativa da renda} \\ \text{média das pessoas com} \\ \text{7 anos de escol/ e 30 anos} \end{array} \right.$

Previsão da renda de um indivíduo com 7 anos de escol/ e 30 anos

Estimadores de Máxima Verossimilhança

$$\hat{\beta}_{mv} = (X'X)^{-1}X'Y$$

$$\hat{\sigma}_{mv}^2 = \frac{(Y - X\hat{\beta})'(Y - X\hat{\beta})}{n} = \frac{\sum_{i=1}^n e_i^2}{n}$$

$\hat{\sigma}_{mv}^2$ é viciado para σ^2

Propriedades de $\hat{\beta}$

$$\hat{\beta} = \underbrace{(X'X)^{-1}X'}_A Y = AY \quad \text{é linear em } Y$$

$A - (k+1) \times n$

$$E(\hat{\beta}) = E(AY) = (X'X)^{-1}X'E(Y) = (X'X)^{-1}X'X\beta = \beta$$

$$\begin{aligned} \text{Var}(\hat{\beta}) &= A \text{Var}(Y) A' = (X'X)^{-1}X' \sigma^2 I X (X'X)^{-1} \\ &= (X'X)^{-1} \sigma^2 \end{aligned}$$

$$Y \sim N_n \Rightarrow AY \sim N_{k+1}(\beta, (X'X)^{-1}\sigma^2) \Rightarrow$$

$$\Rightarrow \hat{\beta}_j \sim N(\beta_j, a_{jj}\sigma^2)$$

$$(X'X)^{-1} = \begin{bmatrix} a_{00} & a_{01} & \dots & a_{0K} \\ a_{10} & a_{11} & \dots & a_{1K} \\ \vdots & \vdots & \ddots & \vdots \\ a_{K0} & a_{K1} & \dots & a_{KK} \end{bmatrix}$$

$$\text{Cov}(\hat{\beta}_i, \hat{\beta}_j) = a_{ij} \sigma^2 \quad i, j = 0, 1, 2, \dots, K$$

$$\hat{\beta} \sim N_{K+1} \Rightarrow \begin{bmatrix} \hat{\beta}_i \\ \hat{\beta}_j \end{bmatrix} \sim N_2 \Rightarrow$$

$$\hat{\beta}_i \text{ e } \hat{\beta}_j \text{ são independentes} \Leftrightarrow a_{ij} = 0$$

Ver exemplo, pag 68 $\rightarrow$ Onde está y usar Y

Estamos utilizando o Modelo com intercepto.

Neste caso, as somas de quadrados são dadas por:

SST - soma de quadrados total (corrigida pela média)

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

na forma matricial

$$= \underline{y}' \underline{y} - \frac{\underline{y}' \underline{1} \underline{1}' \underline{y}}{n} = \underline{y}' \left[\underline{I} - \frac{\underline{1} \underline{1}'}{n} \right] \underline{y}$$

↳ forma quadrática em $\underline{y}$

SSE - soma de quadrados dos resíduos

$$\begin{aligned} SSE &= \sum_{i=1}^n (y_i - \hat{y}_i)^2 = (\underline{y} - \underline{X} \hat{\beta})' (\underline{y} - \underline{X} \hat{\beta}) = \\ &= \underline{y}' \underline{y} - 2 \underline{y}' \underline{X} \hat{\beta} + \hat{\beta}' \underbrace{\underline{X}' \underline{X} \hat{\beta}}_{\underline{X}' \underline{y}} = \underline{y}' \underline{y} - \hat{\beta}' \underline{X}' \underline{y} \end{aligned}$$

Para escrever como forma quadrática em $\underline{y}$

$$SSE = \underline{y}' \underline{y} - \underline{y}' \underline{X} (\underline{X}' \underline{X})^{-1} \underline{X}' \underline{y} = \underline{y}' \left[\underline{I} - \underline{X} (\underline{X}' \underline{X})^{-1} \underline{X}' \right] \underline{y}$$

SSR - Soma de Quadrados da Regressão

$$SSR = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \sum \hat{Y}_i^2 - 2\bar{Y} \sum \hat{Y}_i + n\bar{Y}^2$$

$$= n\bar{Y}$$

Resultados 1, 2 ~~XXX~~ Pag 70

Como $\sum_{i=1}^n \hat{Y}_i = \sum_{i=1}^n Y_i$ (Resultado 2) então
em todo modelo com intercepto

$$SSR = \sum_{i=1}^n \hat{Y}_i^2 - n\bar{Y}^2$$

Devido ao resultado 2

~~$$\sum_{i=1}^n (\hat{Y}_i - Y_i) = \sum e_i$$~~

$$\sum (Y_i - \hat{Y}_i) = \sum e_i = 0 \text{ em todo modelo com intercepto}$$

Na forma matricial

$$SSR = \hat{\beta}' X' Y - n\bar{Y}^2 \rightarrow \text{Consequência 1}$$

Pag 71

fórmula mais conhecida
para cálculos

SSR escrita como forma quadrática em $\tilde{Y}$
(Consequência 2)

$$SSR = \tilde{Y}' \left[X(X'X)^{-1}X' - \frac{\tilde{1}\tilde{1}'}{n} \right] \tilde{Y}$$

Lembrando que $SSE = \tilde{Y}' [I - X(X'X)^{-1}X'] \tilde{Y}$

e $SST = \tilde{Y}' \left[I - \frac{\tilde{1}\tilde{1}'}{n} \right] \tilde{Y}$

temos que $SST = SSR + SSE$

↙
Variabilidade ~~da~~ ~~das~~
total da variável Y

↓
Variabilidade em Y
que a equação de
regressão não
consegue explicar

$$R^2 = \frac{SSR}{SST}$$

coeficiente de explicação ou coeficiente de
correlação múltipla do modelo

$$0 \leq R^2 \leq 1$$

Proporção da variabilidade em Y
que a equação de regressão consegue
explicar.