

# 1a. Prova - Estat para CC

Renato Assunção - DCC, UFMG

Março de 2014

1. Considere um modelo de regressão linear em que a matriz de desenho  $\mathbf{X}$  é de dimensão  $n \times 1$  com apenas uma única coluna. Esta coluna é a coluna de 1's. Isto é,

$$\mathbf{X} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}$$

- Explique geometricamente o que é o espaço  $\mathcal{M}(\mathbf{X})$  neste modelo particular.
- Obtenha a matriz  $\mathbf{H}$  de projeção ortogonal de  $\mathbf{Y}$  no espaço  $\mathcal{M}(\mathbf{X})$ .
- Obtenha o vetor projetado  $\hat{\mathbf{Y}} = \mathbf{H}\mathbf{Y}$ .
- Qual a expressão de  $\hat{\beta}$ ?
- O que é o vetor de resíduos  $\mathbf{r}$  neste caso?

**Solução:**

- $\mathcal{M}(\mathbf{X}) = \{c\mathbf{1} : c \in \mathbb{R}\}$ . Isto é,  $\mathcal{M}(\mathbf{X})$  é formado pelos múltiplos do vetor  $\mathbf{1}$ .
- Por definição,

$$\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' = \mathbf{1}(\mathbf{1}'\mathbf{1})^{-1}\mathbf{1}' \quad \text{e} \quad \mathbf{1}'\mathbf{1} = (1, \dots, 1) \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix} = n$$

Então

$$\mathbf{H} = \frac{1}{n}\mathbf{1}\mathbf{1}' = \frac{1}{n} \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & \dots & 1 \\ \vdots & \vdots & \dots & \vdots \\ 1 & 1 & \dots & 1 \end{bmatrix}$$

- Temos  $\hat{\mathbf{Y}} = \mathbf{H}\mathbf{Y} = \bar{Y}\mathbf{1}$  onde  $\bar{Y} = (Y_1 + \dots + Y_n)/n$ .
- $\hat{\beta} = \bar{Y}$
- Temos

$$\mathbf{r} = \mathbf{Y} - \bar{Y}\mathbf{1} = \begin{bmatrix} Y_1 - \bar{Y} \\ Y_2 - \bar{Y} \\ \vdots \\ Y_n - \bar{Y} \end{bmatrix}$$

2. Considere o modelo de regressão usual com matriz de desenho  $\mathbf{X}$  de dimensão  $n \times p$  cuja primeira coluna é o vetor  $\mathbf{1}$ . Mostre que a soma dos resíduos  $\sum_i r_i$  é igual a zero.

**Solução:** O vetor de resíduos é dado por  $\mathbf{r} = (\mathbf{I} - \mathbf{H}) \mathbf{Y}$  onde  $\mathbf{H}$  é a matriz de projeção ortogonal no espaço das combinações lineares das colunas de  $\mathbf{X}$ .

A soma  $\sum_i r_i$  é igual ao produto interno dos vetores  $\mathbf{1}$  e  $\mathbf{r}$ :

$$\begin{aligned} r_1 + \dots + r_n &= \mathbf{r}' \mathbf{1} \\ &= \mathbf{Y}'(\mathbf{I} - \mathbf{H})' \mathbf{1} \\ &= \mathbf{Y}'(\mathbf{I} - \mathbf{H}) \mathbf{1} \quad \text{pois } \mathbf{H} \text{ é simétrica} \\ &= \mathbf{Y}'(\mathbf{1} - \mathbf{H}\mathbf{1}) \\ &= \mathbf{Y}'(\mathbf{1} - \mathbf{1}) \\ &= 0 \end{aligned}$$

A penúltima passagem é justificada pois  $\mathbf{1}$  pertence ao espaço  $\mathcal{M}(\mathbf{X})$  já que  $\mathbf{1}$  é uma das colunas de  $\mathbf{X}$ . Assim, a projeção ortogonal de  $\mathbf{1}$  em  $\mathcal{M}(\mathbf{X})$  é o próprio  $\mathbf{1}$ .

3. Mostre que o vetor de resíduos  $\mathbf{r}$  é ortogonal ao vetor ajustado  $\hat{\mathbf{Y}}$  e conclua que eles são vetores aleatórios independentes. Assuma o modelo de regressão usual com matriz de desenho  $\mathbf{X}$   $n \times p$  cuja primeira coluna é o vetor  $\mathbf{1}$ .

**Solução:** Temos

$$\begin{aligned} \langle \mathbf{r}, \hat{\mathbf{Y}} \rangle &= \mathbf{r}' \hat{\mathbf{Y}} \\ &= \mathbf{Y}'(\mathbf{I} - \mathbf{H})' \mathbf{H} \mathbf{Y} \\ &= \mathbf{Y}'(\mathbf{I} - \mathbf{H}) \mathbf{H} \mathbf{Y} \quad \text{pois } \mathbf{H} \text{ é simétrica} \\ &= \mathbf{Y}'(\mathbf{H} - \mathbf{H}^2) \mathbf{Y} \\ &= \mathbf{Y}'(\mathbf{H} - \mathbf{H}) \mathbf{Y} \\ &= 0 \end{aligned}$$

Como  $\mathbf{r}$  e  $\hat{\mathbf{Y}}$  são transformações lineares do vetor gaussiano multivariado  $\mathbf{Y}$ , a distribuição conjunta do vetor  $(\mathbf{r}, \hat{\mathbf{Y}})$  de dimensão  $2n$  é uma normal gaussiana com matriz de covariância  $2n \times 2n$ . O bloco  $(1, 2)$  de dimensão  $n \times n$  desta matriz representa a matriz de covariância entre  $\mathbf{r}$  e  $\hat{\mathbf{Y}}$  e ele é dado por

$$\begin{aligned} \text{Cov}(\mathbf{r}, \hat{\mathbf{Y}}) &= \text{Cov}((\mathbf{I} - \mathbf{H})\mathbf{Y}, \mathbf{H} \mathbf{Y}) \\ &= (\mathbf{I} - \mathbf{H})\text{Cov}(\mathbf{Y}, \mathbf{Y})\mathbf{H}' \\ &= (\mathbf{I} - \mathbf{H})\sigma^2 \mathbf{I} \mathbf{H}' \\ &= \sigma^2(\mathbf{I} - \mathbf{H})\mathbf{H} \\ &= \sigma^2(\mathbf{H} - \mathbf{H}^2) \\ &= \sigma^2(\mathbf{H} - \mathbf{H}) \\ &= \mathbf{0} \end{aligned}$$

No caso gaussiano, covariância (ou correlação) nula implica independência. Assim, concluímos que  $\mathbf{r}$  e  $\hat{\mathbf{Y}}$  são independentes.

4. Seja  $X_1, \dots, X_n$  v.a.'s i.i.d.  $N(0, 1)$ . Defina  $Y_1 = X_1$  e  $Y_i = X_i - X_{i-1}$  para  $i = 2, \dots, n$ . Encontre a distribuição do vetor  $\mathbf{Y} = (Y_1, \dots, Y_n)'$ .

**Solução:** O vetor  $\mathbf{X}$  segue uma distribuição gaussiana multivariada  $N_n(\mathbf{0}, \mathbf{I})$  e

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \\ Y_4 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 & \dots & 0 & 0 \\ -1 & 1 & 0 & 0 & \dots & 0 & 0 \\ 0 & -1 & 1 & 0 & \dots & 0 & 0 \\ 0 & 0 & -1 & 1 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & -1 & 1 \end{bmatrix} \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ \vdots \\ X_n \end{bmatrix} = \mathbf{A}\mathbf{X}$$

Portanto,  $\mathbf{Y}$  também é um vetor gaussiano  $N_n(\mathbf{A}\mathbf{0}, \mathbf{A}\mathbf{I}\mathbf{A}') = N_n(\mathbf{0}, \mathbf{A}\mathbf{A}')$ . A matriz de covariância é dada por

$$\mathbf{A}\mathbf{A}' = \begin{bmatrix} 1 & -1 & 0 & 0 & \dots & 0 & 0 \\ -1 & 2 & -1 & 0 & \dots & 0 & 0 \\ 0 & -1 & 2 & -1 & \dots & 0 & 0 \\ 0 & 0 & -1 & 2 & \dots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \dots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \dots & -1 & 2 \end{bmatrix}$$

5. Se  $X_1, \dots, X_n$  são v.a.'s tais que  $\mathbb{V}(X_1) = \sigma^2$  e satisfazendo  $X_{i+1} = \rho X_i$  onde  $\rho \in (0, 1)$  é uma constante e  $i = 2, \dots, n$ . Encontre a matriz de covariância  $\mathbb{V}(\mathbf{X})$  do vetor  $\mathbf{X}$ .

**Solução:** Como  $X_2 = \rho X_1$ ,  $X_3 = \rho X_2 = \rho^2 X_1$  e, em geral,  $X_i = \rho^{i-1} X_1$  para  $i > 1$ , temos as variâncias dadas por

$$\mathbb{V}(X_i) = \mathbb{V}(\rho^{i-1} X_1) = \rho^{2(i-1)} \mathbb{V}(X_1) = \rho^{2(i-1)} \sigma^2.$$

Quanto às covariâncias, temos

$$\text{Cov}(X_i, X_j) = \text{Cov}(\rho^{i-1} X_1, \rho^{j-1} X_1) = \rho^{i-1} \text{Cov}(X_1, X_1) \rho^{j-1} = \rho^{i+j-2} \mathbb{V}(X_1) = \rho^{i+j-2} \sigma^2$$

6. No modelo abaixo,

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

onde a matriz de desenho  $\mathbf{X}$  tem dimensão  $n \times p$ , o vetor  $\boldsymbol{\varepsilon}$  tem distribuição normal multivariada com vetor esperado  $\boldsymbol{\mu} = (0, \dots, 0)'$  e matriz de covariância igual a matriz diagonal com elementos

$$\text{diag}(\mathbb{V}(\boldsymbol{\varepsilon})) = \sigma^2(c_1, c_2, \dots, c_n)$$

onde  $c_i > 0$  são constantes CONHECIDAS. Assim, os erros não possuem variância constante.

Ignorando a matriz de covariância diferente da usual, aplica-se a fórmula matricial para obter o estimador de mínimos quadrados de  $\boldsymbol{\beta}$ . Mostre que este estimador é não viciado para estimar  $\boldsymbol{\beta}$ . EXTRA BONUS: Obtenha a matriz de covariância do estimador  $\hat{\boldsymbol{\beta}}$ .

**Solução:** Como os erros  $\boldsymbol{\varepsilon}$  possuem esperança zero, temos

$$\mathbb{E}(\mathbf{Y}) = \mathbb{E}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = \mathbf{X}\boldsymbol{\beta} + \mathbb{E}(\boldsymbol{\varepsilon}) = \mathbf{X}\boldsymbol{\beta}$$

e portanto

$$\mathbb{E}(\hat{\boldsymbol{\beta}}) = \mathbb{E}\left((\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}\right) = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbb{E}(\mathbf{Y}) = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \boldsymbol{\beta}$$

BONUS:

$$\mathbb{V}(\hat{\boldsymbol{\beta}}) = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbb{V}(\mathbf{Y})\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{V}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}$$

7. Suponha que  $\mathbf{Y} = (Y_1, Y_2)$  seja uma vetor aleatório gaussiano com valor esperado  $\boldsymbol{\mu} = (10, 15)$  e matriz de covariância

$$\mathbb{V}(\mathbf{Y}) = \begin{bmatrix} 4 & 1.6 \\ 1.6 & 1 \end{bmatrix}$$

Dois pontos que fazem da amostra são  $\mathbf{y}_1 = (12, 15)$  e  $\mathbf{y}_2 = (10, 17)$ , ambos a uma distância euclidiana de 2 unidades de  $\boldsymbol{\mu}$ . Qual deles está a uma distância estatística maior de  $\boldsymbol{\mu}$ ?

**Solução:**

$$d^2(\mathbf{y}_1, \boldsymbol{\mu}) = (\mathbf{y}_1 - \boldsymbol{\mu})' \mathbb{V}(\mathbf{Y})^{-1} (\mathbf{y}_1 - \boldsymbol{\mu}) = (2, 0) \mathbb{V}(\mathbf{Y})^{-1} \begin{pmatrix} 2 \\ 0 \end{pmatrix} = (2)^2 [\mathbb{V}(\mathbf{Y})^{-1}]_{11}$$

Uma fórmula similar para o segundo ponto.

8. Se colocarmos mais atributos na matriz  $\mathbf{X}$  (sempre mantendo as colunas lineamente independentes), podemos garantir que o  $R^2$  vai sempre aumentar. Explique porque isto acontece.

**Solução:** Seja  $\mathbf{X}^*$  a matriz de desenho aumentada. O espaço vetorial  $\mathcal{M}(\mathbf{X}^*)$  inclui  $\mathcal{M}(\mathbf{X})$  como sub-espaço vetorial. Assim, minimizar a distância entre  $\mathbf{Y}$  e um elemento de  $\mathbf{X}^*$  inclui todas as possíveis soluções restritas apenas a  $\mathcal{M}(\mathbf{X})$  e o comprimento do vetor de resíduos deve ser, no mínimo, a solução encontrada usando apenas  $\mathcal{M}(\mathbf{X})$ . Como o  $R^2$  é obtido como 1 menos a razão entre o comprimento ao quadrado do vetor de resíduos sobre  $\sum_i (Y_i - \bar{Y})^2$ , e este denominador não muda nos dois casos, devemos ter  $R^2$  aumentando a medida que colocamos mais atributos na matriz de desenho.