

b

$$x_1 = \begin{bmatrix} x_{11} \\ x_{12} \\ \vdots \\ x_{1n} \end{bmatrix}$$

$$x_2 = \begin{bmatrix} x_{21} \\ x_{22} \\ \vdots \\ x_{2n} \end{bmatrix}$$

$\theta$  - ângulo formado  
por  $x_1$  e  $x_2$

$$\cos \theta = \frac{x_1' x_2}{L_{x_1} L_{x_2}} = \frac{x_1' x_2}{\sqrt{x_1' x_1} \sqrt{x_2' x_2}}$$

Sejam  $e_1 = \begin{bmatrix} x_{11} - \bar{x}_1 \\ x_{12} - \bar{x}_1 \\ \vdots \\ x_{1n} - \bar{x}_1 \end{bmatrix}$   $e_2 = \begin{bmatrix} x_{21} - \bar{x}_2 \\ x_{22} - \bar{x}_2 \\ \vdots \\ x_{2n} - \bar{x}_2 \end{bmatrix}$

$$L_{e_1}^2 = e_1' e_1 = \sum_{i=1}^n (x_{1i} - \bar{x}_1)^2$$

$$L_{e_2}^2 = \sum_{i=1}^n (x_{2i} - \bar{x}_2)^2$$

$$e_1' e_2 = \sum_{i=1}^n (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)$$

$$\therefore L_{e_j}^2 = n s_j \quad s_j: \text{variância amostral de } X_j \quad j=1, 2.$$

c

$$e_1' e_2 = n \Delta_{12} \quad \Delta_{12}: \text{covariância amostral} \\ \text{entre } X_1 \text{ e } X_2$$

Seja  $\theta_{12}$ : ângulo formado por  $e_1$  e  $e_2$ .

$$\cos(\theta_{12}) = \frac{e_1' e_2}{L_{e_1} L_{e_2}} =$$

$$= \frac{\sum_{i=1}^n (x_{1i} - \bar{x}_1)(x_{2i} - \bar{x}_2)}{\sqrt{\sum_{i=1}^n (x_{1i} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{2i} - \bar{x}_2)^2}}$$

$$= r_{12} \quad \text{Coeficiente de correlação amostral} \\ \text{entre } X_1 \text{ e } X_2.$$

Se  $x_1$  e  $x_2$  forem centralizadas ou já tiverem média amostral igual a zero, então

$$\cos(\theta_{12}) = \frac{\sum_{i=1}^n x_{1i} x_{2i}}{\sqrt{\sum_{i=1}^n x_{1i}^2} \sqrt{\sum_{i=1}^n x_{2i}^2}} = \frac{x_1' x_2}{L_{x_1} L_{x_2}}$$

$\theta_{12}$ : ângulo formado por  $x_1$  e  $x_2$ .

# Diferenciação de funções de vetores

20

$$x' = [x_1, \dots, x_p]$$

Seja  $f(x)$  uma função contínua de  $x$  tal que

$$f: \mathbb{R}^p \rightarrow \mathbb{R} \quad \text{e} \quad \frac{\partial f(x)}{\partial x_i} \quad \text{e} \quad \frac{\partial^2 f(x)}{\partial x_i \partial x_j} \quad \text{existam.}$$

O vetor de derivadas parciais de  $f(x)$  com relação a cada  $x_i$  é definido como

$$\frac{\partial f(x)}{\partial x} = \begin{bmatrix} \frac{\partial f(x)}{\partial x_1} \\ \frac{\partial f(x)}{\partial x_2} \\ \vdots \\ \frac{\partial f(x)}{\partial x_p} \end{bmatrix}$$

$$i) \text{ Se } f(x) = a'x \quad a' = [a_1 \ a_2 \ \dots \ a_p]$$

$$f(x) = a_1 x_1 + a_2 x_2 + \dots + a_p x_p \quad \Rightarrow \quad \frac{\partial f(x)}{\partial x} = a = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{bmatrix}$$

ii) Se  $f(x) = x'Ax$

A matriz quadrada  $p \times p$ , simétrica  $\Rightarrow \frac{\partial f(x)}{\partial x} = 2Ax$

Ex:  $x' = [x_1 \ x_2]$   $A = \begin{bmatrix} a_{11} & a \\ a & a_{22} \end{bmatrix}$   $x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$

$$x'Ax = \begin{bmatrix} x_1 a_{11} + x_2 a & x_1 a + x_2 a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} =$$

$$= a_{11}x_1^2 + ax_1x_2 + ax_1x_2 + a_{22}x_2^2 = a_{11}x_1^2 + 2ax_1x_2 + a_{22}x_2^2$$

$$\frac{\partial f(x)}{\partial x} = \begin{bmatrix} \frac{\partial f(x)}{\partial x_1} \\ \frac{\partial f(x)}{\partial x_2} \end{bmatrix} = \begin{bmatrix} 2a_{11}x_1 + 2ax_2 \\ 2ax_1 + 2a_{22}x_2 \end{bmatrix}$$

$$2Ax = \begin{bmatrix} 2a_{11}x_1 + 2ax_2 \\ 2ax_1 + 2a_{22}x_2 \end{bmatrix}$$

A matriz de segundas derivadas parciais de  $f(x)$  é definida como

$$H(x) = \frac{\partial^2 f(x)}{\partial x' \partial x} = \begin{bmatrix} \frac{\partial^2 f(x)}{\partial x_1^2} & \dots & \frac{\partial^2 f(x)}{\partial x_1 \partial x_p} \\ \vdots & & \vdots \\ \frac{\partial^2 f(x)}{\partial x_p \partial x_1} & \dots & \frac{\partial^2 f(x)}{\partial x_p^2} \end{bmatrix}$$

$H(x)$  - matriz Hessiana

Máximos e Mínimos de  $f(x)$

Se  $x = x_0$  é ponto de máximo ou de mínimo de  $f(x)$  então  $\left. \frac{\partial f(x)}{\partial x} \right|_{x=x_0} = 0$   $\rightarrow$  vetor nulo

a) Se  $\left. \frac{\partial f(x)}{\partial x} \right|_{x=x_0} = 0$  e  $H(x_0)$  é positiva definida

então  $x_0$  é ponto de mínimo de  $f(x)$ .

b) Se  $\frac{\partial f(x)}{\partial x} \Big|_{x=x_0} = 0$  e  $H(x_0)$  é negativa definida

$[x' H(x) x < 0, \forall x \neq 0]$ , então  $x_0$  é ponto de máximo de  $f(x)$ .

Example

$x_{p \times 1}$   $C_{m \times p}$   $K_{n \times n}$  simétrica  $a_{n \times 1}$

$$f(x) = (a - Cx)' K (a - Cx)$$

$$= a' K a - a' K C x - x' C' K a + x' C' K C x$$

Obs:  $a' K C x = x' C' K a$  porque  $a' K C x = (x' C' K a)'$   
e ambos são escalares

$$\therefore f(x) = a' K a - 2a' K C x + x' C' K C x$$

$$\frac{\partial f(x)}{\partial x} = -2 \underbrace{C' K a}_{p \times 1} + 2 C' K C x$$

$$\frac{\partial f(x)}{\partial x} = 0_{p \times 1} \Rightarrow \underbrace{C' K C}_{p \times p} x = C' K a$$

Se  $C'KC$  é de posto completo ( $\Rightarrow$  inversível)

$$x_0 = (C'KC)^{-1}C'Ka \text{ é solução de } \frac{\partial f(x)}{\partial x} = 0.$$

Verifica-se que se  $K$  é positiva definida e

$$C \text{ é de posto } p \text{ então } \frac{\partial^2 f}{\partial x^2} = H(x) = 2C'KC$$

é positiva definida e  $x_0$  é ponto de mínimo de  $f(x)$ .

Maximizações sujeitas a constantes

Maximizar ou minimizar  $f(x)$  sujeito à restrição  $g(x) = c \forall x$ .

Constrói-se a nova função

$$h(x, \lambda) = f(x) - \lambda [g(x) - c]$$

$\lambda$  - multiplicador de Lagrange ( $\lambda$  escalar).

Obs; Maximizar ou minimizar  $f(x)$  é equivalente a " " " "  $h(x, \lambda)$  pois, válida a restrição,  $g(x) = c$  e  $h(x, \lambda) = f(x)$ .

$$\frac{\partial h(x, \lambda)}{\partial x} = \frac{\partial f(x)}{\partial x} - \lambda \frac{\partial g(x)}{\partial x} = 0_{p \times 1}.$$

$$\frac{\partial h(x, \lambda)}{\partial \lambda} = -g(x) + c = 0 \left[ \vec{g}(x) = c, \text{restrição} \right].$$

Resolve-se em  $x$  a equação  $\frac{\partial h(x, \lambda)}{\partial x} = 0$ ,

após eliminação de  $\lambda$  através de manipulações algébricas.



Ex: Obter o máximo da forma quadrática <sup>26</sup>

$f(x) = x'Ax$ , onde  $A$  é  $p \times p$  simétrica, positiva definida, sujeito à restrição  $x'x = 1$ .

$$h(x, \lambda) = x'Ax - \lambda [x'x - 1]$$

$$\frac{\partial h(x, \lambda)}{\partial x} = \underset{p \times p}{2Ax} - \underset{p \times 1}{2\lambda x} = \underset{p \times 1}{0}.$$

$$\left[ A - \lambda \underset{p}{I} \right] x = 0_{p \times 1}.$$

As soluções em  $x$  dessa equação são os vetores característicos de  $A$ . (e  $\lambda$  é a raiz característica) Pre-multiplicando por  $x'$  temos

$$x'Ax - \lambda \underbrace{x'x}_1 = 0_{1 \times 1} \Rightarrow$$

$$\Rightarrow \lambda = x'Ax.$$

Como  $x'Ax$  é a quantidade a ser maximizada, tomar  $\lambda$  como a maior raiz característica de  $A$  e  $x_0$ , ponto de máximo de  $f(x)$  é o vetor característico associado.

Para minimizar  $f(x)$ ,  $x_0$  seria o vetor característico associado à menor raiz característica de  $A$ .

## Decomposição de Matrizes

### 1) Decomposição Espectral

Qualquer matriz simétrica  $A$ ,  $p \times p$ , pode ser escrita como

$$A = T D T^{-1}$$

$$D = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$$

$$T = [x_1 \ x_2 \ \dots \ x_p]$$

$[A - \lambda_i I] x_i = 0$  tem infinitas soluções,

$x_i$  solução  $\Rightarrow k x_i$  soluções

onde  $\lambda_1, \lambda_2, \dots, \lambda_p$  são as raízes características de  $A$  e  $x_1, x_2, \dots, x_p$  são os correspondentes vetores característicos "normalizados"  $[x_i^T x_i = 1, i = 1, 2, \dots, p]$

$$T = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & & x_{2p} \\ \vdots & \vdots & & \vdots \\ x_{p1} & x_{p2} & & x_{pp} \\ x_1 & x_2 & & x_p \end{bmatrix}$$

Verifica-se que

$$T^T D T = \lambda_1 \underbrace{x_1 x_1^T}_{\substack{p \times 1 \quad 1 \times p \\ p \times p}} + \lambda_2 x_2 x_2^T + \dots + \lambda_p x_p x_p^T$$

Obs; a) Se  $x_i$  e  $x_j$  são dois vetores característicos associados a raízes características diferentes de uma matriz simétrica, então

$$\underbrace{x_i^T}_{1 \times p} \underbrace{x_j}_{p \times 1} = \underbrace{0}_{1 \times 1}$$

Dizemos que  $x_i$  e  $x_j$  são ortogonais.

b) A matriz  $T$  é ortogonal.

$$T \text{ é matriz ortogonal} \Leftrightarrow \begin{aligned} x_i^T x_i &= 1 \\ x_i^T x_j &= 0 \quad i \neq j. \end{aligned}$$

Propriedades da Matriz ortogonal

$$P_{n \times n} \text{ ortogonal} \Leftrightarrow P^{-1} = P^T$$

$$P \text{ é ortogonal} \Leftrightarrow P^T P = I$$

$$P \text{ é ortogonal} \Rightarrow \det(P) = \pm 1$$

## 2) Decomposições de Cholesky

Toda matriz positiva definida  $A$  pode ser escrita como

$$A = WW'$$

onde  $W$  é não singular.

Essa decomposição é a base do procedimento de mínimos quadrados generalizados da regressão.

## 3) Decomposições em Valores Singulares

Toda matriz  $X$   $n \times p$  pode ser decomposta como

$$X = UDT'$$

em que  $U$  é  $n \times p$ ,  $T$  é  $p \times p$ ,  $U'U = I$ ,  $T'T = I$

e  $D$  é uma matriz diagonal  $p \times p$  com elementos da diagonal principal  $M_j > 0$   $j = 1, 2, \dots, p$ .

$M_j$  são denominados valores singulares de  $X$ .

$T$  é a matriz cujas colunas são os vetores característicos de  $X'X$

$U$  é a matriz cujas colunas são os vetores característicos de  $XX'$ .

Além disso, verifica-se que o quadrado dos valores singulares de  $X$  ( $\mu_j^2$ ) são as raízes características de  $X'X$ .

$$X'X = (UDT')' UDT' = TD' \underbrace{U'U}_I DT' = TD' \underbrace{DT'}_{D \text{diag}} =$$

$$= \underbrace{TD^2T'}_{\text{Decomposição espectral de } X'X}$$

Decomposição espectral de  $X'X$

Decomposições singulares são úteis na análise de multicolinearidade em modelos de regressão.

### Exercício

Determine uma decomposição singular da matriz

$$A = \begin{bmatrix} 3 & 1 & 1 \\ -1 & 3 & 1 \end{bmatrix}$$