

# Tópicos de matrizes e Distribuição Normal Multivariada

---

---

## CAPÍTULO 1

# Alguns resultados importantes

---

### 1.1 definições

$I_n$  : matriz Identidade de dimensão  $(n \times n)$

$J_n$  :  $11^t$

#### 1.1.1 Traço

Sejam  $A_{p \times p}, B_{p \times p}, C_{p \times p}, D_{p \times p}, x_{p \times p}$  e  $\alpha$  :escalar.

Propriedades

1.  $Tr(\alpha) = \alpha$
2.  $Tr(A + B) = Tr(A) + Tr(B)$
3.  $Tr(\alpha A) = \alpha Tr(A)$
4.  $Tr(CD) = Tr(DC) = \sum_{i,j} c_{ij}d_{ji}$
5.  $\sum_i x_i^t A x_i = tr(AT)$  onde  $T = \sum_i x_i x_i^t$
6.  $tr(B^{-1}AB) = tr(A)$

#### 1.1.2 Determinantes

$A_{(p \times p)}, C$  (constante)

1. Se  $A$  é diagonal ou triangular  $|A| = \prod_{i=1}^p a_{ii}$
2.  $|CA| = C^p |A|$
3.  $|AB| = |A| |B|$
4.  $|A| = |A^t|$
5. Se cada elemento de uma linha (coluna) de  $A$  é zero,  $|A| = 0$
6. Se quaisquer duas linhas (colunas) de  $A$  é zero,  $|A| = 0$
7. Se quaisquer duas linhas (colunas) de  $A$  são idênticas,  $|A| = 0$
8. Se  $A$  é não-singular,  $|A| = 1/|A^{-1}|$  ou seja,  $|A| |A^{-1}| = 1$
9. Se  $A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$  onde  $A_{11}$  e  $A_{22}$  são matrizes quadradas,  $|A| = |A_{11}| |A_{22} - A_{21} A_{11}^{-1} A_{12}| = |A_{22}| |A_{11} - A_{12} A_{22}^{-1} A_{21}|$

10. Sejam  $B_{(p \times n)}$ ,  $C_{(n \times p)}$  e  $A_{(p \times p)}$  não-singular. Temos  $|A + BC| = |A^{-1}| |I_p + A^{-1}BC| = |A^{-1}| |I_n + CA^{-1}B|$
11. Sejam  $b_{(p \times 1)}$ ,  $A_{(p \times p)}$  não-singular,  $|A + bb^t| = |A| |1 + b^t A^{-1}b|$
12. Se  $B_{(p \times n)}$  e  $C_{(n \times p)}$  então  $|I_p + BC| = |I_n + CB|$

### 1.1.3 Inversa

#### Propriedades

1.  $(AB)^{-1} = B^{-1}A^{-1}$
2. A única solução de  $Ax = b$  é  $x = A^{-1}b$
3. Sejam  $A_{(p \times p)}$ ,  $B_{(p \times n)}$ ,  $C_{(n \times n)}$  e  $D_{(n \times p)}$ . Se todas as inversas necessárias existem, então  $(A + BCD)^{-1} = A^{-1} - A^{-1}B(C^{-1} + DA^{-1}B)^{-1}DA^{-1}$   
caso particular  $A_{(p \times p)}$ ,  $b_{(p \times 1)}$  e  $c_{(p \times 1)}$ , se  $A^{-1}$  existe  $(A + bc^t)^{-1} = A^{-1} - \frac{A^{-1}bc^tA^{-1}}{1 + c^tA^{-1}b}$
4. Se todas as matrizes inversas necessárias existem, então a matriz particionada  $A^{-1}$  é dada por :

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} A^{-1} = \begin{pmatrix} A^{11} & A^{12} \\ A^{21} & A^{22} \end{pmatrix}$$

$$A^{11} = (A_{11} - A_{12}A_{22}^{-1}A_{21})^{-1}$$

$$A^{12} = -A^{11}A_{12}A_{22}^{-1} = -A_{11}^{-1}A_{12}A^{22}$$

$$A^{21} = -A^{22}A_{21}A_{11}^{-1} = -A_{22}^{-1}A_{21}A^{11}$$

$$A^{22} = (A_{22} - A_{21}A_{11}^{-1}A_{12})^{-1}$$

### 1.1.4 Produto de Kronecker

*Definição* Sejam  $A = (a_{ij})$  e  $B = (b_{ij})$  matrizes de dimensão  $(m \times n)$  e  $(p \times q)$ , respectivamente. O produto de Kronecker, indicado por  $A \otimes B = (a_{ij}B) =$

$$\begin{pmatrix} a_{11}B & a_{12}B & \dots & a_{1n}B \\ \vdots & \vdots & \vdots & \vdots \\ a_{m1}B & a_{m2}B & \dots & a_{mn}B \end{pmatrix}$$

*Def:*  $Vec(A)$  Seja  $A$  uma matriz de dimensão  $(m \times n)$  e  $a_{(i)}$  a  $i$ -ésima coluna de  $A$ .  $Vec(A)$  é um vetor de dimensão  $(mn \times 1)$  definido por :

$$Vec(A) = \begin{pmatrix} a_{(1)} \\ a_{(2)} \\ \vdots \\ a_{(n)} \end{pmatrix}$$

Propriedades  $A, B, C, D$  : matrizes,  $x, y$  : vetores,  $\alpha$  : escalar

1.  $\alpha(A \otimes B) = (\alpha A) \otimes B = A \otimes (\alpha B)$
2.  $A \otimes (B \otimes C) = (A \otimes B) \otimes C = A \otimes B \otimes C$

3.  $(A \otimes B)^t = A^t \otimes B^t$
4.  $(A \otimes B)(C \otimes D) = (AC) \otimes (BD)$
5.  $(A \otimes B)^{-1} = (A^{-1} \otimes B^{-1})$
6.  $(A + B) \otimes C = (A \otimes C) + (B \otimes C)$
7.  $A \otimes (B + C) = (A \otimes B) + (A \otimes C)$
8.  $A_{(p \times p)}, B_{(q \times q)}, |A \otimes B| = |A|^q |B|^p$
9.  $Vec(ABC) = (C^t \otimes A)Vec(B)$ , se  $ABC$  existe
10.  $x \otimes y = vec(yx^t)$
11.  $x \otimes y^t = xy^t = y^t \otimes x$
12.  $(Vec(A))^t vec(B) = tr(A^t B)$
13.  $(Vec(A))^t (B \otimes C) Vec(D) = tr(A^t C D B^t)$

### 1.1.5 Matrizes especiais

#### 1. Matrizes ortogonais

Se  $A$  uma matriz quadrada,  $A$  é ortogonal se  $AA^t = I$

Propriedades

- (a)  $A^{-1} = A^t$
- (b)  $A^t A = I$
- (c)  $|A| = \pm 1$
- (d)  $a_{(i)}^t a_{(j)} = 0$  se  $i \neq j$   
 $a_{(i)}^t a_{(j)} = 1$  se  $i = j$
- (e) Se  $A$  e  $B$  são ortogonais  $C = AB$  é ortogonal.

#### 2. Matriz de equicorrelação

$$E = (1 - \rho)I_p + \rho J_p,$$

$$E = \begin{pmatrix} 1 & \rho & \dots & \rho \\ \rho & 1 & \dots & \rho \\ \vdots & \vdots & \ddots & \vdots \\ \rho & \rho & \dots & 1 \end{pmatrix}, \rho : \text{número real}$$

$$E^{-1} = (1 - \rho)^{-1} [(I_p - \rho\{1 + (p-1)\rho\})^{-1} J_p]$$

$$|E| = (1 - \rho)^{p-1} \{1 + \rho(p-1)\}$$

De uma forma mais geral,

$$A = \begin{pmatrix} c+b & c & \dots & c \\ c & c+b & \dots & c \\ \vdots & \vdots & \ddots & \vdots \\ c & c & \dots & c+b \end{pmatrix}, A = cJ_n + bI_n$$

$$A^{-1} = \frac{1}{b}I_n - \frac{c}{(nc+b)b}J_n$$

## 3. Matriz Idempotente

$A$  é idempotente de  $A^2 = A$

## 4. Matriz Positiva definida e positiva semi-definida

$A$  é positiva definida se  $x^tAx > 0, \forall x \neq 0$

$A$  é positiva semi-definida se  $x^tAx \geq 0, \forall x \neq 0$

## 1.1.6 Posto de uma matriz

O posto de uma matriz  $A_{(n \times p)}$  é definida como o número máximo linhas (colunas) linearmente independentes de  $A$ ; ou é a ordem da maior submatriz quadrada de  $A$  com determinante não-nulo.  $Posto(A) : r(A)$

*Propriedades* Seja uma matriz  $A_{(n \times p)}$

1.  $0 \leq r(A) \leq \min(n, p)$
2.  $r(A) = r(A^t)$
3.  $r(A + B) \leq r(A) + r(B)$
4.  $r(AB) \leq \min\{r(A), r(B)\}$
5.  $r(A^tA) = r(AA^t) = r(A)$
6. Se  $B_{(n \times n)}$  e  $C_{(p \times p)}$  são não-singular, então  $r(BAC) = r(A)$
7. Se  $n = p$  então  $r(A) = p$  se, e somente se,  $A$  é não singular.

Posto de alguns matrizes

1.  $A = \text{diag}(a_i), r(A) = \text{números de } a_i \neq 0$
2.  $r(H) = n - 1$
3.  $A$  idempotente,  $r(A) = \text{tr}(A)$

## 1.1.7 Autovalores e autovetores

*Definição*

Autovalores. Seja  $A$  uma matriz de dimensão  $(p \times p)$ .  $\lambda_1, \dots, \lambda_p$  que satisfazem a equação  $|A - \lambda I_p| = 0$  são denominados autovalores da matriz  $A$ . Os autovalores podem ser complexos ou múltiplos.

Autovetores. Para todo autovalor  $\lambda_i$  existe um vetor  $\gamma \neq 0$  tal que  $A\gamma = \lambda_i\gamma$  onde  $\gamma$  é denominado autovetor de  $A$  associado ao autovalor  $\lambda_i$ .

Em geral vamos usar os autovetores normalizados ou seja  $\gamma^t\gamma = 1$

$$A = \begin{pmatrix} 1 & 2 \\ 2 & 4 \end{pmatrix} \quad \lambda_1 = 0; \lambda_2 = 5$$

$$\gamma_1 = \begin{pmatrix} -2/\sqrt{5} \\ 1/\sqrt{5} \end{pmatrix} \quad \text{e} \quad \gamma_2 = \begin{pmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{pmatrix}$$

*Propriedades*

1. Seja  $C_{(p \times p)}$  uma matriz não-singular  $A$  e  $CAC^{-1}$  tem os mesmos autovalores. Se  $\gamma$  é um autovetor de  $A$  para  $\lambda_i$  então  $\nu = C\gamma$  é um autovetor de  $CAC^{-1}$  para  $\lambda_i$ .

*Prova.*  $CAC^{-1} - \lambda I = CAC^{-1} - \lambda CC^{-1}CC^{-1} = C(A - \lambda I)C^{-1}$

$$|CAC^{-1} - \lambda I| = |C| |A - \lambda I| |C^{-1}| = |A - \lambda I|$$

$$A\gamma = \lambda_i\gamma$$

$$CA\gamma = \lambda_i C\gamma$$

$$CAC^{-1}C\gamma = \lambda_i C\gamma$$

$$CAC^{-1}\nu = \lambda_i\nu \quad \square$$

1. Seja  $\alpha$  escalar. Então  $A + \alpha I$  tem autovalores  $\lambda_i + \alpha$ . Além disso,  $A$  e  $A + \alpha I$  tem os mesmos autovetores.
2. Se  $A_{(p \times p)}$  é simétrica então todos os autovalores são reais.

## 1.2 Decomposição Espectral

Qualquer matriz simétrica  $A_{(p \times p)}$  pode ser escrita como  $A = \Gamma\Lambda\Gamma^t = \sum_{i=1}^p \lambda_i \gamma_{(i)} \gamma_{(i)}^t$  onde  $\Lambda$  é a matriz diagonal dos autovalores de  $A$  e  $\Gamma$  é uma matriz ortogonal cujas colunas são os autovetores normalizados de  $A$ .

### 1.2.1 Propriedade

1. Se  $A_{(p \times p)}$  é uma matriz simétrica não-singular então para qualquer inteiro  $n$ ,  $\Lambda^n = \text{diag}(\lambda_i^n)$  e  $A^n = \Gamma\Lambda^n\Gamma^t$ .
2. Se todos os autovalores de  $A$  são positivos,  $A^{r/s} = \Gamma\Lambda^{r/s}\Gamma^t$  onde  $\Lambda^{r/s} = \text{diag}(\lambda_i^{r/s})$ , para inteiros  $s > 0$  e  $r$ .

obs: Se alguns dos autovalores de  $A$  são iguais a zero, então os resultados anteriores são válidos se os expoentes forem não-negativos.

*Prova.* por indução

$\square$

*Casos Especiais*  $A^2 = \Gamma\Lambda^2\Gamma^t$  ;  $A^{-1} = \Gamma\Lambda^{-1}\Gamma^t$  ;  $A^{-1/2} = \Gamma\Lambda^{-1/2}\Gamma^t$ .

Propriedades de  $A^{-1/2}$

1.  $(A^{-1/2})^t = A^{-1/2}$
2.  $A^{1/2}A^{1/2} = A$
3.  $A^{1/2}A^{-1/2} = A^{-1/2}A^{1/2} = I$
4.  $A^{-1/2}A^{-1/2} = A^{-1}$
5. Seja  $A$  simétrica então o posto de  $A$  é igual ao número de autovalores não nulo de  $A$

*Prova.*  $A = \Gamma \Lambda \Gamma^t$

$$r(A) = r(\Gamma \Lambda \Gamma^t) = r(\Lambda)$$

□

1. Se  $A_{(p \times p)}$  é simétrica, então :
2.  $tr(A) = \sum_{i=1}^p \lambda_i$
3.  $\det(A) = \prod_{i=1}^p \lambda_i$
4. Uma matriz simétrica  $A$  tem posto 1 se, e somente se,  $A = xx^t$  para algum  $x$ .  
Então, o único autovalor de  $A$  não-nulo é dado por  $tr(A) = tr(xx^t) = xx^t$ .
5. Seja  $J = 11^t$ . Temos que  $r(J) = 1$  e que o único autovalor não-nulo de  $J$  é  $1^t 1 = p$  e o autovetor correspondente é  $1_p$ .  
Seja  $E = (1 - p)I + \rho J$ , os autovalores de  $E$  são  $\lambda_1 = 1 + (p - 1)\rho, \lambda_2 = \dots = \lambda_p = 1 - \rho$  e seus autovetores de  $E$  são os mesmos de  $J$
6. Se  $A$ , é simétrica e idempotente então  $\lambda_i = 0$  ou  $1, \forall i$ .

### 1.3 Formas Quadráticas

Definição

Uma forma quadrática no vetor  $x$  é uma função da forma :

$$Q(x) = x^t A x = \sum_i \sum_j x_i a_{ij} x_j \text{ onde } A \text{ é um matriz simétrica.}$$

*Propriedades*

1.  $Q(0) = 0$
2.  $Q(x)$  é positiva definida se  $Q(x) > 0, \forall x \neq 0$
3. A simétrica é p.d. (p.s.d) se  $Q(x)$  é p.d. (p.s.d.)

Para qualquer matriz simétrica  $A$ , existe uma transformação ortogonal  $y = \Gamma^t x$  tal que  $x^t A x = \sum_i \lambda_i y_i^2$ .

*Prova.* Sabemos que  $A = \Gamma \Lambda \Gamma^t$ , seja  $y = \Gamma^t x$ . Logo

$$\Gamma y = \Gamma \Gamma^t x \Rightarrow x^t = y^t \Gamma^t.$$

$$x^t A x = y^t \Gamma^t A \Gamma y = y^t \Gamma^t \Gamma \Lambda \Gamma^t \Gamma y = y^t \Lambda y = \sum_i \lambda_i y_i^2.$$

□

4. Se  $A > 0$  então  $\lambda_i > 0, \forall i$
5. Se  $A \geq 0$  então  $\lambda_i \geq 0, \forall i$
6. Se  $A > 0$  então  $A$  é não-singular e  $|A| > 0$
7. Se  $A > 0$  então  $A^{-1} > 0$

*Prova.*  $A^{-1} = \Gamma \Lambda^{-1} \Gamma^t$

$$y = \Gamma^t x \text{ tal que } x^t A^{-1} x = \sum_i \frac{1}{\lambda_i} y_i^2.$$

$$x^t A^{-1} x = y^t \Gamma^t A^{-1} \Gamma y = y^t \Gamma^t \Gamma \Lambda^{-1} \Gamma^t \Gamma y = y^t \Lambda^{-1} y = \sum_i \frac{1}{\lambda_i} y_i^2 > 0, \text{ pois } \lambda_i > 0, y \neq 0.$$

□

8. Qualquer matriz  $A \geq 0$  pode ser escrita como  $A = B^2$  onde  $B$  é uma matriz simétrica.

*Prova.* Sabemos que  $A = \Gamma \Lambda \Gamma^t$ , seja  $B = \Gamma \Lambda^{1/2} \Gamma^t$  então  $B^2 = \Gamma \Lambda^{1/2} \Gamma^t \Gamma \Lambda^{1/2} \Gamma^t = \Gamma \Lambda \Gamma^t = A$

□

9. Se  $A \geq 0, A_{(p \times p)}$  então para qualquer matriz  $C$  de ordem  $(p \times n)$  temos  $C^t A C \geq 0$   
 10. Se  $A > 0$  e  $C$  não-singular  $(p = n)$  então  $C^t A C > 0$   
 11. Se  $A \geq 0$  e  $B > 0$  matrizes de ordem  $(p \times p)$  então todas as raízes características não-nulas de  $B^{-1} A$  são positivas.

*Interpretação Geométrica* Seja  $A$  uma matriz positiva definida. Então  $(x - \alpha)^t A^{-1} (x - \alpha) = C^2$  representa um elipsóide em dimensão  $p$ . O centro do elipsóide é  $x = \alpha$ .

### 1.4 Inversa Generalizada

Definição : Seja a matriz  $A_{(n \times p)}$ .  $A^-$  é a g-inversa ou inversa generalizada de  $A$  se  $AA^-A = A$ . A g-inversa sempre existe, embora possa não ser única

1. Se  $r(A) = r$  e  $A_{(n \times p)}$  então as linhas e colunas podem ser rearranjadas de modo que  $A_{11}(r \times r)$  seja não-singular . Logo uma g-inversa é dada por

$$A^- = \begin{pmatrix} A_{11}^{-1} & 0 \\ 0 & 0 \end{pmatrix}$$

2. Se  $A_{(p \times p)}$  é não-singular então  $A^- = A^{-1}$  e é única

*Teorema* Seja  $G$  uma g-inversa de  $X^t X$

1.  $G^t$  é uma g-inversa de  $X^t X$
2.  $G X^t$  é uma g-inversa de  $X$
3.  $X G X^t$  não varia com  $G$
4.  $X G X^t$  é simétrica mesmo que  $G$  não o seja.

### 1.5 Diferenciação de Vetores e Matrizes

1. Seja  $a$  um vetor de constantes

$$a^t x = x^t a = \lambda; \lambda = a_1 x_1 + a_2 x_2 + \dots + a_p x_p$$

$$\frac{\partial \lambda}{\partial x} = \begin{pmatrix} a_1 \\ \vdots \\ a_p \end{pmatrix}$$



$$2. \ x = \begin{pmatrix} x_1 \\ \vdots \\ x_p \end{pmatrix} \text{ e } A = \begin{pmatrix} a_{11} & \dots & a_{1p} \\ \vdots & \vdots & \vdots \\ a_{p1} & \dots & a_{pp} \end{pmatrix}$$

$$x^t A = \begin{pmatrix} \lambda_1 & \lambda_2 & \dots & \lambda_p \end{pmatrix} \text{ onde } \lambda_i = \sum_{j=1}^p x_j a_{ji}$$

$$\frac{\partial x^t A}{\partial x} = \begin{pmatrix} \frac{\partial \lambda_1}{\partial x_1} & \dots & \frac{\partial \lambda_p}{\partial x_1} \\ \vdots & \vdots & \vdots \\ \frac{\partial \lambda_1}{\partial x_p} & \dots & \frac{\partial \lambda_p}{\partial x_p} \end{pmatrix} = A$$

### 3. Formas Quadráticas

$$Q(x) = x^t A x, \ A \text{ simétrica}$$

$$x^t A x = a_{11}x_1^2 + \dots + a_{pp}x_p^2 + 2a_{12}x_1x_2 + \dots + 2a_{(p-1)p}x_{p-1}x_p$$

$$\frac{\partial x^t A x}{\partial x} = \begin{pmatrix} \frac{\partial x^t A x}{\partial x_1} \\ \vdots \\ \frac{\partial x^t A x}{\partial x_p} \end{pmatrix} = \begin{pmatrix} 2a_{11}x_1 + 2a_{12}x_2 + \dots + 2a_{1p}x_p \\ \vdots \\ 2a_{p1}x_1 + 2a_{p2}x_2 + \dots + 2a_{pp}x_p \end{pmatrix} = 2AX$$

#### 1.5.1 Resultados

1.  $\partial A = 0$
2.  $\partial(\alpha U) = \alpha U$
3.  $\partial(U \pm V) = \partial U \pm \partial V$
4.  $\partial(UV) = (\partial U)V + U(\partial V)$
5.  $\partial U^t = (\partial U)^t$
6.  $\partial \text{vec}(U) = \text{vec}(\partial U)$
7.  $\partial \text{tr}(U) = \text{tr}(\partial U)$
8.  $\partial A^{-1} = -A^{-1} \partial A A^{-1}$
9.  $\partial(B^t X) = B$
10.  $\partial(X^t A y) = A y$
11.  $\partial(X^t X) = 2X$
12.  $\partial(X^t A X) = 2AX$  se  $X$  é simétrica
13.  $\partial(Y^t A X) = Y B^t$
14.  $\partial(Y^t X Y) = Y Y^t$

$A$  é simétrica e  $a$  um vetor

1.  $\partial(a^t X A X^t a) = 2a a^t X A$
2.  $\partial(a^t X A Y^t a) = a a^t Y A$
3.  $\partial(\text{tr}(Y X)) = Y^t$
4.  $\partial(\text{tr}(Y X B)) = Y^t B^t$

---

## CAPÍTULO 2

# Vetores Aleatórios

---

Um vetor aleatório é um vetor cujos elementos são variáveis aleatórias. Similarmente, uma matriz aleatória é uma matriz cujos elementos são variáveis aleatórias. Os vetores aleatórios são também chamados de variáveis aleatórias multidimensionais. O Valor esperado de uma matriz aleatória é uma matriz consistindo dos valores esperados de cada um de seus elementos. Seja  $X$  uma matriz aleatória  $p \times n$ ,  $X = (X_{ij})$ , se existem os valores esperados  $E(X_{ij})$ ,

Se (a matriz de valores esperados) $X$  e  $Y$  têm mesma dimensão  $p \times n$  e são matrizes aleatórias e  $A$  e  $B$  são adequadas matrizes constantes,

$$E(X + Y) = E(X) + E(Y)$$

$$E(AXB) = AE(X)B$$

### 2.1 Vetor de médias e Matriz de covariâncias

Seja  $X$ ,  $p \times 1$  e  $E(X_i) = \mu_i$ ,  $i = 1, \dots, p$ ,  $Cov(X_i, X_j) = \sigma_{ij}$ ,  $i, j = 1, 2, \dots, p$ , então

denotamos  $E(X)$  por  $\mu = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{pmatrix}$  e  $Cov(X)$  por  $\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_{pp} \end{pmatrix}$ .

Se  $X_i$  e  $X_j$  são independentes então  $Cov(X_i, X_j) = 0$ . Há situações em que  $Cov(X_i, X_j) = 0$  mas  $X_i$  e  $X_j$  não são independentes.

Por definição  $E(X) = E \begin{pmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{pmatrix} = \begin{pmatrix} E(X_1) \\ E(X_2) \\ \vdots \\ E(X_p) \end{pmatrix} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{pmatrix} = \mu$  e  $Cov(X) =$

$$E(X - \mu)(X - \mu)^t = E \begin{pmatrix} X_1 - \mu_1 \\ X_2 - \mu_2 \\ \vdots \\ X_p - \mu_p \end{pmatrix} \begin{pmatrix} (X_1 - \mu_1) & (X_2 - \mu_2) & \dots & (X_p - \mu_p) \end{pmatrix} =$$
$$= E \begin{pmatrix} (X_1 - \mu_1)(X_1 - \mu_1) & (X_1 - \mu_1)(X_2 - \mu_2) & \dots & (X_1 - \mu_1)(X_p - \mu_p) \\ (X_2 - \mu_2)(X_1 - \mu_1) & (X_2 - \mu_2)(X_2 - \mu_2) & \dots & (X_2 - \mu_2)(X_p - \mu_p) \\ \vdots & \vdots & \ddots & \vdots \\ (X_p - \mu_p)(X_1 - \mu_1) & (X_p - \mu_p)(X_2 - \mu_2) & \dots & (X_p - \mu_p)(X_p - \mu_p) \end{pmatrix} =$$

$$=E \begin{pmatrix} (X_1 - \mu_1)^2 & (X_1 - \mu_1)(X_2 - \mu_2) & \dots & (X_1 - \mu_1)(X_p - \mu_p) \\ (X_2 - \mu_2)(X_1 - \mu_1) & (X_2 - \mu_2)^2 & \dots & (X_2 - \mu_2)(X_p - \mu_p) \\ \vdots & \vdots & \ddots & \vdots \\ (X_p - \mu_p)(X_1 - \mu_1) & (X_p - \mu_p)(X_2 - \mu_2) & \dots & (X_p - \mu_p)^2 \end{pmatrix} =$$

$$\begin{pmatrix} \sigma_{11} & \sigma_{11} & \dots & \sigma_{11} \\ \sigma_{11} & & \dots & \sigma_{11} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{11} & \sigma_{11} & \dots & \sigma_{11} \end{pmatrix}$$

onde  $\sigma_{ii} = \sigma_i^2, \sigma_{ij} = \sigma_{ji}$ .

### 2.1.1 Matriz de Correlação

Uma medida de correlação linear entre  $X_i$  e  $X_j$  é dada pelo coeficiente de correlação linear simples  $\rho_{ij} = \frac{\sigma_{ij}}{\sqrt{\sigma_{ii}\sigma_{jj}}}$ . O coeficiente de correlação é obtido da matriz de

covariância-variância  $\Sigma$ . A Matriz de correlação  $\rho = \begin{pmatrix} 1 & \rho_{12} & \dots & \rho_{1p} \\ \vdots & 1 & \ddots & \vdots \\ \rho_{p1} & \rho_{p2} & \dots & 1 \end{pmatrix}$  pode

ser obtida por  $\rho = [(V^{1/2})^{-1}\Sigma(V^{1/2})^{-1}]$  onde

$$V^{1/2} = \begin{pmatrix} \sqrt{\sigma_{11}} & 0 & \dots & 0 \\ 0 & \sqrt{\sigma_{22}} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sqrt{\sigma_{pp}} \end{pmatrix} e$$

$$V^{-1/2} = \begin{pmatrix} \sigma_{11}^{-1/2} & 0 & \dots & 0 \\ 0 & \sigma_{22}^{-1/2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{pp}^{-1/2} \end{pmatrix}.$$

Outra relação importante é  $\Sigma = V^{1/2}\rho V^{1/2}$ . Assim  $\Sigma$  pode ser obtida de  $\rho$  e  $V^{1/2}$  enquanto  $\rho$  pode ser obtida de  $\Sigma$ .

### Matriz de covariância Particionada

Frequentemente as características observadas num experimento podem ser classificadas em dois grupos. Por exemplo, em observando-se estudantes as variáveis sócio-econômicas podem formar um grupo, enquanto o desempenho acadêmico é composto por outro grupo de variáveis. Em geral, particionando o vetor  $X$  em dois grupos de variáveis, digamos,  $X^{(1)}, (q \times 1)$  e  $X^{(2)}, (p - q) \times 1$ , obtém-se

$$E(X) = E \begin{pmatrix} X^{(1)} \\ \dots \\ X^{(2)} \end{pmatrix} = \begin{pmatrix} E(X^{(1)}) \\ \dots \\ E(X^{(2)}) \end{pmatrix} = \begin{pmatrix} \mu^{(1)} \\ \dots \\ \mu^{(2)} \end{pmatrix}$$

$$\begin{aligned}
 Cov(X) &= Cov \begin{pmatrix} X^{(1)} \\ \dots \\ X^{(2)} \end{pmatrix} = E(X - \mu)(X - \mu)^t \\
 &= E \begin{pmatrix} X^{(1)} - \mu^{(1)} \\ \dots \\ X^{(2)} - \mu^{(2)} \end{pmatrix} \left( (X^{(1)} - \mu^{(1)})^t; (X^{(2)} - \mu^{(2)})^t \right) \\
 &= E \begin{pmatrix} (X^{(1)} - \mu^{(1)})(X^{(1)} - \mu^{(1)})^t & \vdots & (X^{(1)} - \mu^{(1)})(X^{(2)} - \mu^{(2)})^t \\ \dots & \dots & \dots \\ (X^{(2)} - \mu^{(2)})(X^{(1)} - \mu^{(1)})^t & \vdots & (X^{(2)} - \mu^{(2)})(X^{(2)} - \mu^{(2)})^t \end{pmatrix} = \begin{pmatrix} \Sigma_{11} & \vdots & \Sigma_{12} \\ \dots & \dots & \dots \\ \Sigma_{21} & \vdots & \Sigma_{22} \end{pmatrix} \\
 \Sigma_{12} &= \Sigma_{12}^t
 \end{aligned}$$

**2.2 Lista de exercícios**

1. Seja a variável aleatória bidimensional  $X$ ,  $p \times 1$ ,  $p = 2$ .  $X_1$  e  $X_2$  são v.a. discretas independentes com as seguintes funções de probabilidade,

(a)

$x_1$	-1	0	1	$x_2$	0	1
$p(x_i)$	0,3	0,3	0,4	$p(x_i)$	0,8	0,2

Calcule :

- (b)  $E(X)$ ,  $Cov(X)$   
 (c)  $E(AX)$ ,  $Cov(AX)$  para  $A = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$   
 (d)  $\rho_x$

Comente

1. Verifique que para o vetor aleatório  $X = (X_1, \dots, X_p)^t$
- (a)  $Cov(X_i + a, X_j + b) = Cov(X_i, X_j)$ , a e b constantes  
 (b)  $Cov(aX_i, bX_j) = abCov(X_i, X_j)$ , a e b constantes  
 (c) Para combinações lineares das variáveis componentes de  $X$ ,  $a^t X$  e  $b^t X$ ,  $Cov(a^t X, b^t X) = a^t \Sigma b$ , forma bilinear.
2. Se  $A$  e  $B$  são matrizes constantes ( $r \times p$ ) e ( $s \times p$ ), respectivamente e  $Y = AX$ ,  $Z = BX$  são duas transformações da variável aleatória  $X$  então :
- $Cov(Y, Y) = A \Sigma A^t$ ,  $Cov(Z, Z) = B \Sigma B^t$ ,  $Cov(Y, Z) = A \Sigma B^t$
3. Dado  $E(X) = \mu$ ,  $Var(X) = \Sigma$ ,  $Cov(X_i, X_j) = 0, \forall i \neq j$   
 Calcule  $|\Sigma|$ ,  $(X - \mu)^t \Sigma^{-1} (X - \mu)$   
 Verifique que  $\rho = (V^{(1/2)})^{-1} \Sigma (V^{(1/2)})^{-1}$  com  $V^{(1/2)} = diag(\sqrt{\sigma_{ii}})$ ,  $i = 1, \dots, p$
4. Seja  $X$  tal que  $\Sigma = \begin{pmatrix} 25 & -2 & 4 \\ -2 & 4 & 1 \\ 4 & 1 & 9 \end{pmatrix}$
- (a) Calcule  $\rho$ ,  $V^{(1/2)}$  e  $\Sigma^{-1}$ .  
 (b) Encontre os valores e vetores próprios de  $\Sigma$   
 (c) Verifique que  $\Sigma = V^{(1/2)} \rho V^{(1/2)}$   
 (d) Encontre a correlação entre  $X_1$  e  $\frac{X_2 + X_3}{2}$ .

## Distribuição Normal Multivariada

---

A generalização da familiar densidade normal para várias dimensões tem um fundamental papel na análise multivariada. Enquanto dados reais nunca são exatamente normal multivariados, a densidade normal é frequentemente uma útil aproximação para a verdadeira distribuição da população.

Uma vantagem da distribuição normal multivariada é que ela é matematicamente atrativa, dela obtendo-se excelentes resultados. Mas estatisticamente, duas outras razões são as que indicam o uso da distribuição normal.

Primeira, distribuições amostrais de muitos estatísticos multivariados são aproximadamente normais, devido ao efeito do teorema do limite central. Em segundo lugar, a distribuição normal serve como modelo aproximado para certos fenômenos naturais.

### 3.1 Densidade e propriedades da distribuição normal multivariada

#### 3.1.1 Definição 1

Sabemos que a distribuição normal univariada, com média  $\mu$  e variância  $\sigma^2$ , tem função de densidade de probabilidade  $f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}$ ,  $-\infty < x < \infty$ .

$X \sim N(\mu, \sigma^2)$  implica que  $P(\mu - \sigma \leq X \leq \mu + \sigma) \cong 0,68$  e  $P(\mu - 2\sigma \leq X \leq \mu + 2\sigma) \cong 0,95$ .

A densidade normal multivariada é a generalização da densidade normal univariada para dimensões  $p \geq 2$ . O termo  $\left(\frac{x-\mu}{\sigma}\right)^2 = (x-\mu)(\sigma^2)^{-1}(x-\mu)$  é generalizado para  $(x-\mu)^t \Sigma^{-1} (x-\mu)$  que é a distância quadrada generalizada (distância de Mahalanobis), quando  $\Sigma$  admite inversa. Em outro caso a densidade não é bem definida. Também o termo  $\frac{1}{\sqrt{2\pi\sigma^2}} = (2\pi)^{-1/2}(\sigma^2)^{-1/2}$  deve ser modificado para uma constante mais geral para tornar o ‘volume’ (no caso multivariado as probabilidades são representadas por volumes sob a superfícies na região definida) sob a superfície da função de densidade multivariada unitária para qualquer  $p$ . Essa constante será  $(2\pi)^{-p/2} |\Sigma|^{-1/2}$ .

Consequentemente, para  $\Sigma$  definida positiva, a função de densidade de uma variável  $X \sim N_p(\mu, \Sigma)$  será

$$f(x) = (2\pi)^{-p/2} |\Sigma|^{-1/2} \exp \left\{ -\frac{1}{2} (x - \mu)^t \Sigma^{-1} (x - \mu) \right\},$$

$$-\infty < x_i < \infty, i = 1, 2, \dots, p.$$

### 3.1.2 Definição 2

Dizemos que  $X$  tem uma distribuição normal multivariada  $p$ -variada se e somente se  $a^t x$  tem distribuição normal univariada para todo  $a$  fixado.

Se  $X$  tem distribuição normal multivariada  $p$ -variada então cada um dos elementos de  $X$ , ou seja,  $X_i$ ,  $i = 1, \dots, p$  tem distribuição normal univariada.

Se todas as  $p(p - 1)/2$  covariâncias são nulas, as  $p$  componentes de  $x$  são independentemente distribuídas e

$$f(x) = f_1(x_1)f_2(x_2) \dots f_p(x_p), \text{ consequentemente,}$$

$$F(x) = \int_{-\infty}^{x_1} \dots \int_{-\infty}^{x_p} f(x) dx_1 \dots dx_p =$$

$$= \int_{-\infty}^{x_1} f(x_1) dx_1 \int_{-\infty}^{x_2} f(x_2) dx_2 \dots \int_{-\infty}^{x_p} f(x_p) dx_p =$$

$$= F_1(x_1)F_1(x_1) \dots F_p(x_p).$$

A densidade normal multivariada é constante nas superfícies onde a distância  $(x - \mu)^t \Sigma^{-1} (x - \mu)$  é constante. Esse corte é chamado de *contorno*.

O contorno de uma densidade de probabilidade constante é a superfície de um elipsóide centrado em  $\mu$  e é igual ao conjunto de pontos  $\{x : (x - \mu)^t \Sigma^{-1} (x - \mu) = c^2\}$ . Esses elipsóides têm eixos  $\pm c\sqrt{\lambda_i}e_i$ , onde  $(\lambda_i e_i)$  é um par de autovalor-autovetor da matriz  $\Sigma$ .

As figuras a<sub>1</sub> e a<sub>2</sub> mostram as distribuições de duas binormais, na primeira  $X_1$  e  $X_2$  são independentes, na segunda  $X_1$  e  $X_2$  tem correlação de 0,75. As figuras b<sub>1</sub> e b<sub>2</sub> são contornos de 50% e 90% para duas  $N_2(\mu, \Sigma)$ ,  $X_1$  e  $X_2$  independentes ou correlacionadas. A figura b<sub>3</sub> mostra contorno de densidade constante para uma normal bivariada com  $\sigma_{11} = \sigma_{22}$  e  $\rho_{12} > 0$ .

O elipsóide sólido dos  $x$  tais que  $(x - \mu)^t \Sigma^{-1} (x - \mu) \leq \chi_p^2(\alpha)$  tem probabilidade  $(1 - \alpha)$ , para  $X \sim N_p(\mu, \Sigma)$  e  $\chi_p^2$  sendo o  $\alpha$ -quantil superior da qui-quadrado com  $p$  graus de liberdade.

### 3.1.3 Propriedades da Distribuição normal multivariada

Seja  $X \sim N_p(\mu, \Sigma)$ , então são verdades

1. Combinações lineares de componentes de  $X$  são distribuídas normalmente :

$$X \sim N_p(\mu, \Sigma) \Rightarrow a^t X \sim N(a^t \mu, a^t \Sigma a)$$

2. Todo subconjunto de componentes de  $X$  tem distribuição normal multivariada.

$$X \sim N_p(\mu, \Sigma), A_{(q \times p)} \Rightarrow AX \sim N_q(A\mu, A\Sigma A^t)$$

3. Covariância zero implica que as correspondentes componentes são independentemente distribuídas.

$$X \sim N_p(\mu, \Sigma) \Rightarrow [cov(X_i, X_j) \iff X_i \text{ independente } X_j]$$

- (a) Seja  $X \sim N_p(\mu, \Sigma)$  e  $Y = \Sigma^{-1/2}(X - \mu)$  onde  $\Sigma^{-1/2}$  é a raiz quadrada simétrica positiva definida de  $\Sigma^{-1}$ . Então  $Y_1, Y_2, \dots, Y_p$  são independentes e  $Y_i \sim N(0, 1)$  para todo  $i$ .
- (b) Se  $X \sim N_p(\mu, \Sigma)$  então  $E(X) = \mu$ ,  $Var(X) = \Sigma$
- (c) Se  $X \sim N_p(\mu, \Sigma)$  então  $U = (X - \mu)^t \Sigma^{-1} (X - \mu) \sim \chi_p^2$
- (d) Se  $X \sim N_p(\mu, \Sigma)$ ,  $A_{(q \times p)}$ ,  $C_{(q \times 1)}$  e  $Y = AX + C \Rightarrow Y \sim N_q(A\mu + C, A\Sigma A^t)$

Função característica

Seja  $X$  um vetor aleatório ( $p \times 1$ ). A função característica de  $X$  é definida como :

$$\phi_x(s) = E(e^{is^t x})$$

4. Seja  $X^t = (X_1^t, X_2^t)$ . Os vetores aleatórios  $X_1$  e  $X_2$  são independentes se, e somente se,

$$\phi_x(s) = \phi_{X_1}(s_1) \phi_{X_2}(s_2) \text{ onde } s^t = (s_1^t, s_2^t).$$



5. Se  $X$  e  $Y$  são vetores aleatórios ( $p \times 1$ ) independentes então  $\phi_{X+Y}(s) = \phi_X(s) + \phi_Y(s)$
6. Se  $X \sim N_p(\mu, \Sigma) \iff \phi_X(s) = \exp \left\{ i s^t \mu - \frac{1}{2} s^t \Sigma s \right\}$
7. Dois vetores conjuntamente multinormais são independentes se, e somente se são não correlacionados.
8. Se  $X \sim N_p(\mu, \Sigma)$  então  $AX$  e  $BX$  são independentes se, e somente se  $A\Sigma B^t = 0$ .
9. Distribuições condicionais das componentes são multinormais :

$$X \sim N_p(\mu, \Sigma) \Rightarrow X^{(1)} | X^{(2)} \sim N_q(\mu_{1|2}, \Sigma_{1|2}),$$

$$\text{onde } \mu_{1|2} = \mu_1 + \Sigma_{12}\Sigma_{22}^{-1}(x_2 - \mu_2),$$

$$\Sigma_{1|2} = \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21}.$$

10.  $X \sim N_p(\mu, \Sigma)$ ,  $d$  um vetor de constantes  $\Rightarrow (X + d) \sim N_p(\mu + d, \Sigma)$ .
11. Todos os subconjuntos de componentes de  $X$  são normalmente distribuídas. Se particionamos  $X$ , seu vetor de médias  $\mu$  e matriz de covariância  $\Sigma$ . Seja  $X_1$  e  $X_2$  com dimensão  $q$  e  $p-q$  respectivamente, isto é

$$X = \begin{pmatrix} X_1 \\ \cdots \\ X_2 \end{pmatrix}, \mu = \begin{pmatrix} \mu_1 \\ \cdots \\ \mu_2 \end{pmatrix}, \Sigma = \begin{pmatrix} \Sigma_{11} & \vdots & \Sigma_{12} \\ \cdots & \cdots & \cdots \\ \Sigma_{21} & \vdots & \Sigma_{22} \end{pmatrix} \text{ então } X_1 \sim N_q(\mu_1, \Sigma_{11}) \text{ e}$$

$$X_2 \sim N_q(\mu_2, \Sigma_{22})$$

12.  $X_1$  e  $X_2$  são independentes se e somente se  $Cov(X_1, X_2) = \Sigma_{12} = 0$ .
13. Se  $X_1$  e  $X_2$  são independentes e  $X_1 \sim N_{q_1}(\mu_1, \Sigma_{11})$  e  $X_2 \sim N_{q_2}(\mu_2, \Sigma_{22})$  respec-

$$\text{tivamente, então } \begin{pmatrix} X_1 \\ \cdots \\ X_2 \end{pmatrix} \sim N_{q_1+q_2} \left( \begin{pmatrix} \mu_1 \\ \cdots \\ \mu_2 \end{pmatrix}, \Sigma = \begin{pmatrix} \Sigma_{11} & \vdots & 0 \\ \cdots & \cdots & \cdots \\ 0 & \vdots & \Sigma_{22} \end{pmatrix} \right).$$

14. Se  $X \sim N_p(\mu, \Sigma)$  e  $|\Sigma| > 0$ , então  $(x - \mu)^t \Sigma^{-1} (x - \mu) \sim \chi_p^2$
15. Se  $X \sim N_p(\mu, \Sigma)$  e  $|\Sigma| > 0$ , então o elipsóide sólido  $\{ (x - \mu)^t \Sigma^{-1} (x - \mu) \leq \chi_p^2(\alpha) \}$  tem probabilidade  $(1 - \alpha)$ , com  $\chi_p^2(\alpha)$  sendo o  $\alpha$ -quantil superior da distribuição qui-quadrado com  $p$  graus de liberdade.
16. Se  $X_1, X_2, \dots, X_n$  são mutuamente independentes com  $X_j \sim N_p(\mu_j, \Sigma)$ , com mesma matriz de covariância  $\Sigma$  então  $V_1 = c_1 X_1 + c_2 X_2 + \dots + c_n X_n \sim N_p(\mu_{V_1}, \Sigma_{V_1})$  com  $\mu_{V_1} = \sum_{j=1}^n c_j \mu_j$  e  $\Sigma_{V_1} = (\sum_{j=1}^n c_j^2) \Sigma$ . Além do mais  $V_1$  e  $V_2 = \sum_{j=1}^n b_j X_j$  são conjuntamente normais multivariadas com matriz de covariâncias

$$\begin{pmatrix} (\sum_{j=1}^n c_j^2) \Sigma & b^t c \Sigma \\ b^t c \Sigma & (\sum_{j=1}^n b_j^2) \Sigma \end{pmatrix}$$

Consequentemente  $V_1$  e  $V_2$  são independentes se  $b^t c = \sum_{j=1}^n b_j c_j = 0$ , isto é, os vetores  $b$  e  $c$  são perpendiculares.

Considerando todos os possíveis valores de  $x_2$ , podemos escrever a variável  $\mu_1 + \Sigma_{12}\Sigma_{22}^{-1}(x_2 - \mu_2)$  como predição da distribuição condicional de  $X_1$ . A diferença entre  $X_1$  e a predição da média da distribuição condicional de  $X_1$  é o vetor  $X_{1.2}$  é chamado de conjunto de variáveis residuais.

$$X_{1.2} = X_1 - \mu_1 - \Sigma_{12}\Sigma_{22}^{-1}(x_2 - \mu_2)$$

Em populações multinormais as variáveis residuais e as fixadas são distribuídas independentemente.

**3.2 Lista 2 de exercícios de Análise Multivariada**

1. Considere uma população normal bivariada com  $\mu_1 = 0$ ,  $\mu_2 = 2$ ,  $\sigma_{11} = 2$ ,  $\sigma_{22} = 1$  e  $\rho_{12} = 0,5$ .
  - (a) Escreva a densidade desta normal
  - (b) Apresente a expressão da distância quadrada generalizada  $(x - \mu)^t \Sigma^{-1} (x - \mu)$  como uma função de  $x_1$  e  $x_2$ .
  - (c) Determine o contorno de densidade constante que contém 50% de probabilidade. Esboce o gráfico do contorno.
  - (d) Especifique a distribuição condicional de  $X_1$ , dado  $X_2 = x_2$  para a distribuição
  
2. Sejam  $X_1 \sim N(0, 1)$  e  $X_2 = \begin{cases} -X_1 & , \text{ se } -1 \leq X_1 \leq 1 \\ X_1 & , \text{ em outro caso.} \end{cases}$ 
  - (a) Mostre que  $X_2$  tem também distribuição normal
  - (b) Mostre que  $X_1$  e  $X_2$  não tem distribuição normal bivariada
  
3. Seja  $X \sim N_3(\mu, \Sigma)$  com  $\mu = (2, -3, 1)^t$  e  $\Sigma = \begin{pmatrix} 1 & 1 & 1 \\ 1 & 3 & 2 \\ 1 & 2 & 2 \end{pmatrix}$ 
  - (a) Encontre a distribuição de  $3X_1 - 2X_2 + X_3$
  - (b) Determine um vetor  $a_{(2 \times 1)}$ , tal que  $X_2$  e  $\left[ X_2 - a^t \begin{pmatrix} X_1 \\ X_3 \end{pmatrix} \right]$  são independentes.
  - (c) Determine a distribuição de  $X_3$  dado  $X_1 = x_1$  e  $X_2 = x_2$
  - (d) Verifique que na questão acima  $(X_1, X_2)$  é independente da variável residual.

---

## CAPÍTULO 4

# Amostras Aleatórias

---

### 4.1 Introdução

Uma observação multivariada é o conjunto de medidas de  $p$  diferentes variáveis na mesma unidade de análise. Tomando-se  $n$  observações, a massa de dados pode ser arranjada em uma matriz de dados  $X$  como

$$X_{(p \times n)} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \cdots & \cdots & \vdots & \cdots \\ x_{p1} & x_{p2} & \cdots & x_{pn} \end{pmatrix} = (x_1, x_2, \dots, x_n)$$

Cada coluna de  $X$  representa uma observação multivariada e a matriz  $X$  é uma amostra de tamanho  $n$  de uma população  $n$  de uma população  $p$ -variada. Cada coluna representa um ponto num espaço  $p$ -dimensional, fornecendo informação sobre sua localização e variabilidade além de associação linear.

O vetor média amostral  $\bar{x}$  é obtido como combinação linear das colunas de  $X$ , ou seja,

$$\bar{x}_{(p \times 1)} = \frac{1}{n} \sum_{i=1}^n x_i = X \begin{pmatrix} 1/n \\ 1/n \\ \vdots \\ 1/n \end{pmatrix} = \frac{1}{n} X \mathbf{1}$$

Se os pontos são considerados esferóides o vetor de médias,  $\bar{x}$ , é o centro de gravidade. A matriz  $S$  de variância e covariâncias amostral indica a variação nas várias direções do sistema. O determinante da matriz de variância e covariâncias amostral é uma medida numérica da variabilidade total.

$$S = \left[ \frac{1}{n-1} \sum_{i=1}^n x_i x_i^t - n \bar{x} \bar{x}^t \right] = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^t = \begin{pmatrix} s_{11} & s_{12} & \cdots & s_{1p} \\ s_{21} & s_{22} & \cdots & s_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ s_{p1} & s_{p2} & \cdots & s_{pp} \end{pmatrix}$$

A matriz de covariância amostral contém  $p$  variâncias e  $\frac{1}{2}p(p-1)$  covariâncias. A variância amostral generalizada é o determinante de  $S$  e representa a variação

expressa em  $S$ . A fragilidade da variância generalizada pode ser mostrada nas seguintes três matrizes de covariâncias as quais tem mesma variância generalizada e diferente estrutura de correlação, não detectada por  $\det(S)$ ,

$$S_1 = \begin{pmatrix} 5 & 4 \\ 4 & 5 \end{pmatrix}, S_2 = \begin{pmatrix} 5 & -4 \\ -4 & 5 \end{pmatrix}, S_3 = \begin{pmatrix} 3 & 0 \\ 0 & 3 \end{pmatrix}$$

$$\rho_1 > 0, \rho_2 < 0 \text{ e } \rho_3 = 0$$

A matriz de dados  $X$  pode ser considerada como uma observação da matriz aleatória  $\begin{pmatrix} X_{11} & X_{12} & \cdots & X_{1n} \\ X_{21} & X_{22} & \cdots & X_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ X_{p1} & X_{p2} & \cdots & X_{pn} \end{pmatrix}$  composta dos vetores colunas  $(X_1 \ X_2 \ \cdots \ X_n)$ .

Se os vetores colunas  $X_1, \dots, X_n$  representam independentes observações de uma distribuição comum, com função de densidade  $f(x) = f(x_1, \dots, x_p)$ , então  $X_1, X_2, \dots, X_n$  formam uma amostra aleatória de  $f(x)$ . Então  $f(x_1, \dots, x_n) = f(x_1) \cdot f(x_2) \cdot \dots \cdot f(x_n)$  onde  $f(x_j) = f(x_{1j}, x_{2j}, \dots, x_{pj})$

As medidas das  $p$  variáveis em uma única observação  $X_j^t = (X_{1j}, \dots, X_{pj})$ , serão em geral correlacionadas.

As medidas de diferentes observações devem ser no entanto independentes.

A violação da hipótese de independência entre cada observação pode causar sérios impactos na qualidade da inferência estatística. Observações através do tempo são um exemplo desta situação.

#### 4.1.1 Resultados sobre a variância generalizada, $|S|$ :

1. Em qualquer análise estatística,  $|S| = 0$  significa que as medidas de algumas variáveis devem ser removidas do estudo.
2. Se  $n \leq p$  ( isto é, o número de observações é menor ou igual ao número de variáveis observadas), então  $|S| = 0$  para todas as amostras.
3. Se a combinação linear  $a^t X_j$  tem variância positiva para cada vetor constante  $a \neq 0$  e se  $p < n$ , então  $S$  tem posto completo com probabilidade 1 e  $|S| > 0$ .

#### 4.1.2 Variância Total Amostral

Outra generalização da variância é definida como a soma dos elementos sa diagonal principal e é chamada de variância total amostral,  $\sum_{i=1}^p s_{ii} = s_{11} + s_{12} + \dots + s_{pp}$ .

## 4.2 Amostras Aleatórias de uma Distribuição Multinormal

Seja  $X_1, X_2, \dots, X_n$  uma amostra aleatória de uma população  $p$ -variada com o vetor de médias  $\mu$  e matriz de covariância  $\Sigma$ . Desde que  $X_1, X_2, \dots, X_n$  são mu-

tuamente independentes e com uma distribuição comum  $N_p(\mu, \Sigma)$ , a função de densidade conjunta de todas as observações é o produto das densidades normais marginais,

$$\begin{aligned} f_{X_1, \dots, X_p}(x_1, \dots, x_n) &= f_{X_1}(x_1) \cdot f_{X_2}(x_2) \cdot \dots \cdot f_{X_n}(x_n) = \prod_{j=1}^n f_{X_j}(x_j) = \\ &= \prod_{j=1}^n \left\{ \frac{1}{(2\pi)^{p/2} |\Sigma|^{n/2}} \exp \left\{ -\frac{1}{2} \sum_{j=1}^n (x_j - \mu)^t \Sigma^{-1} (x_j - \mu) \right\} \right\} \end{aligned}$$

Quando considerada como uma função de  $\mu$  e  $\Sigma$  esta função de densidade conjunta é a função de verossimilhança.

### 4.3 Estimação de Máxima verossimilhança de $\mu$ e $\Sigma$ para $N_p(\mu, \Sigma)$ .

Consideremos uma amostra aleatória de uma  $N_p(\mu, \Sigma)$ . A função de verossimilhança dada acima será denotada por  $L(\mu, \Sigma)$  para ressaltar que é uma função de  $\mu$  e  $\Sigma$ . Após algumas manipulações algébricas, podemos reescrever esta função como

$$L(\mu, \Sigma) = (2\pi)^{-np/2} |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \text{tr} \left[ \Sigma^{-1} \left( \sum_{j=1}^n (x_j - \bar{x})(x_j - \bar{x})^t + n(\bar{x} - \mu)(\bar{x} - \mu)^t \right) \right] \right\}$$

Seja  $X_1, X_2, \dots, X_n$  uma amostra aleatória de uma população normal com média  $\mu$  e covariância  $\Sigma$ . Então ,

$$\hat{\mu} = \bar{X} \text{ e } \hat{\Sigma} = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})(X_j - \bar{X})^t = \frac{n-1}{n} S,$$

são os estimadores de máxima verossimilhança de  $\mu$  e  $\Sigma$ , respectivamente. Seus valores observados são

$$\bar{x} \text{ e } \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})(x_j - \bar{x})^t$$

Pela propriedade da invariância, se  $\hat{\theta}$  é um estimador máxima verossimilhança de  $\theta$ , então o estimador máxima verossimilhança de uma função de  $\theta$ , seja  $h(\theta)$ , é dado por  $h(\hat{\theta})$ . Assim sendo o estimador máxima verossimilhança de  $\rho$ , matriz de correlação de  $X$  é  $\hat{\rho}$ , ou seja,

$$\begin{aligned} \rho &= \text{diag}(\sigma_{ii}^{-1/2}) \Sigma \text{diag}(\sigma_{ii}^{-1/2}) = f(\Sigma) \\ \hat{\rho} &= f(\hat{\Sigma}) = \text{diag}(\hat{\sigma}_{ii}^{-1/2}) \Sigma \text{diag}(\hat{\sigma}_{ii}^{-1/2}), \text{ onde} \\ \hat{\rho}_{ij} &= \frac{\hat{\sigma}_{ij}}{(\hat{\sigma}_{ii} \hat{\sigma}_{jj})^{1/2}} \end{aligned}$$

*Propriedades*

1. Se  $X_{(p \times n)}$  é uma matriz de dados da  $N_p(\mu, \Sigma)$  e  $\bar{X} = n^{-1}X1$  então  $\bar{X} = N_p(\mu, n^{-1}\Sigma)$
2.  $E(\bar{X}) = \mu$  e  $Var(\bar{X}) = \frac{1}{n}\Sigma$
3.  $E(\hat{\Sigma}) = \frac{n}{n-1}\Sigma$ ,  $E(S) = \Sigma$
4. Se  $X$  é uma matriz de dados da  $N_p(\mu, \Sigma)$  e se  $Y = AXB$  e  $Z = CXD$ , então os elementos de  $Y$  são independentes dos de  $Z$  se, e somente se,

$$B\Sigma D^t = 0 \text{ ou } A^t C = 0$$

*Teorema do Limite Central*

Sejam  $X_1, X_2, \dots$ , uma sequência infinita de vetores aleatórios indenticamente independentemente distribuidas de uma distribuição com média  $\mu$  e  $\Sigma$ . Então

$$n^{-1/2} \sum_{r=1}^n (X_r - \mu) = n^{-1/2}(\bar{x} - \mu) \xrightarrow{D} N_p(0, \Sigma)$$