

# ESTATÍSTICA MULTIVARIADA

Resolução dos Exercícios

2<sup>a</sup> Edição Revisada e Ampliada

DANIEL FURTADO FERREIRA

# UNIVERSIDADE FEDERAL DE LAVRAS

**REITOR:** Antônio Nazareno Guimarães Mendes

**VICE-REITOR:** Elias Tadeu Fialho

## **Diretoria Executiva**

Renato Paiva (Diretor)

Elias Tadeu Fialho

## **Conselho Editorial**

Renato Paiva (Presidente)

Amauri Alves de Alvarenga

Carlos Alberto Silva

Elias Tadeu Fialho

Luiz Carlos de Oliveira Lima

# ESTATÍSTICA MULTIVARIADA

2<sup>a</sup> Edição Revisada e Ampliada

DANIEL FURTADO FERREIRA



Lavras - MG

© 2011 by Daniel Furtado Ferreira, 1ª edição: 2008. 2ª edição ampliada e revisada

Nenhuma parte desta publicação pode ser reproduzida, por qualquer meio ou forma, sem a autorização escrita e prévia dos detentores do copyright.

Direitos de publicação reservados à Editora UFLA.

Impresso no Brasil - ISBN: **978-85-87692-52-8**

**Editora UFLA**

Campus Histórico - Caixa Postal 3037

37200-000 - Lavras - MG.

Tel: (35) 3829-1115 - Fax: (35) 3829-1551

E-mail: vendas\_editora@ufla.br - editora@ufla.br

Homepage: www.editora.ufla.br

**Projeto Gráfico:** Daniel Furtado Ferreira

**Secretaria:** Glenda Fernanda Morton

**Revisão de Texto:** Jane Cherem

**Revisão de Referências Bibliográficas:** Márcio Barbosa de Assis

**Editoração Eletrônica:** Daniel Furtado Ferreira, Christyane Aparecida Caetano,  
Luciana Carvalho Costa

**Marketing e Comercialização:** Bruna de Carvalho Naves

**Capa:** Daniel Furtado Ferreira, Helder Tobias

Ficha Catalográfica Preparada pela Divisão de Processos Técnicos da  
Biblioteca Central da UFLA

Ferreira, Daniel Furtado.

Estatística multivariada / Daniel Furtado Ferreira. – 2. ed. rev. ampl. –  
Lavras : Ed. UFLA, 2011.

29 p. : il.

Bibliografia.

ISBN **978-85-87692-52-8**

1. Estatística. 2. Normal multivariada. 3. Distância de Mahalanobis.  
4. Máxima verossimilhança. 5. Análise de variância. 6. Covariância.  
I. Título.

CDD - 519.535

# Sumário

<b>1</b>	<b>Álgebra Vetorial e Matricial</b>	<b>7</b>
1.1	Exercícios . . . . .	7
<b>2</b>	<b>Introdução e Conceitos Básicos</b>	<b>21</b>
2.1	Exercícios . . . . .	21




# Capítulo 1

## Álgebra Vetorial e Matricial

### 1.1 Exercícios

1.1.1 Sejam os vetores  $\mathbf{x}^\top = [1, 3]$  e  $\mathbf{y}^\top = [2, -5]$ :

(a) plote os dois vetores;



(b) determine o comprimento de cada vetor, o ângulo  $\theta$  entre  $\mathbf{x}$  e  $\mathbf{y}$  e a distância entre eles, considerando a métrica  $\mathbf{\Psi} = \mathbf{I}$ .

Os comprimentos dos vetores são:

$$\begin{aligned}\|\mathbf{x}\| &= \sqrt{\mathbf{x}^\top \mathbf{x}} = \sqrt{\sum_{i=1}^p x_i^2} = \sqrt{1^2 + 3^2} \\ &= \sqrt{10} = 3,1623.\end{aligned}$$

e

$$\begin{aligned}\|\mathbf{y}\| &= \sqrt{\mathbf{y}^\top \mathbf{y}} = \sqrt{\sum_{i=1}^p y_i^2} = \sqrt{2^2 + (-5)^2} \\ &= \sqrt{29} = 5,3852.\end{aligned}$$

O cosseno do ângulo entre eles é:

$$\begin{aligned}\theta_{\mathbf{x},\mathbf{y}} &= \frac{\mathbf{x}^\top \mathbf{y}}{\sqrt{\mathbf{x}^\top \mathbf{x}} \sqrt{\mathbf{y}^\top \mathbf{y}}} = \frac{\mathbf{x}^\top \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|} = \frac{1 \times 2 + 3 \times (-5)}{\sqrt{10} \times 29} \\ &= -0,7633863,\end{aligned}$$

o que resulta em  $\theta_{\mathbf{x},\mathbf{y}} = 139,76^\circ$ .

A distância entre os vetores é

$$\begin{aligned}\|\mathbf{x} - \mathbf{y}\| &= \sqrt{(\mathbf{x} - \mathbf{y})^\top (\mathbf{x} - \mathbf{y})} = \sqrt{\sum_{i=1}^p (x_i - y_i)^2} = \sqrt{(1 - 2)^2 + [3 - (-5)]^2} \\ &= \sqrt{65} = 8,0623,\end{aligned}$$

representado em azul na figura.

1.1.2 Considere a matriz  $\mathbf{X}$  ( $5 \times 4$ ) dada por

$$\mathbf{X} = \begin{bmatrix} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{bmatrix}.$$

- (a) ortonormalize as colunas de  $\mathbf{X}$ , utilizando o processo de Gram-Schmidt e determine o seu posto; O vetor  $\mathbf{e}_1$  é

$$\mathbf{e}_1 = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix},$$

cuja norma é  $\|e_1\| = \sqrt{5}$ .

O vetor  $e_2$  é

$$e_2 = v_2 - \frac{v_2^\top e_1}{\|e_1\|^2} e_1 = \begin{bmatrix} 1 \\ 1 \\ 0 \\ 0 \\ 0 \end{bmatrix} - \frac{2}{5} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} = \frac{1}{5} \begin{bmatrix} 3 \\ 3 \\ -2 \\ -2 \\ -2 \end{bmatrix},$$

em que  $v_i$  representa o vetor correspondente à  $i$ -ésima coluna de  $\mathbf{X}$ , sendo nesse caso  $i = 2$ . A norma quadrática de  $e_2$  é  $\|e_2\|^2 = 6/5$ .

O vetor  $e_3$  é

$$e_3 = v_3 - \frac{v_3^\top e_2}{\|e_2\|^2} e_2 - \frac{v_3^\top e_1}{\|e_1\|^2} e_1 = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 1 \\ 0 \end{bmatrix} + \frac{2}{15} \begin{bmatrix} 3 \\ 3 \\ -2 \\ -2 \\ -2 \end{bmatrix} - \frac{2}{5} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \\ = \frac{1}{3} \begin{bmatrix} 0 \\ 0 \\ 1 \\ 1 \\ -2 \end{bmatrix},$$

A norma quadrática de  $e_3$  é  $\|e_3\|^2 = 2/3$ .

O vetor  $e_4$  é

$$e_4 = v_4 - \frac{v_4^\top e_3}{\|e_3\|^2} e_3 - \frac{v_4^\top e_2}{\|e_2\|^2} e_2 - \frac{v_4^\top e_1}{\|e_1\|^2} e_1 \\ = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} + \frac{1}{3} \begin{bmatrix} 0 \\ 0 \\ 1 \\ 1 \\ -2 \end{bmatrix} + \frac{1}{15} \begin{bmatrix} 3 \\ 3 \\ -2 \\ -2 \\ -2 \end{bmatrix} - \frac{1}{5} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix},$$

A norma quadrática de  $e_4$  é  $\|e_4\|^2 = 0$ , o que indica que esse vetor é linearmente dependente dos demais.

No segundo estágio, obtivemos os vetores normalizados  $e_i/\|e_i\|$ . Assim, o vetor  $\mathbf{x}_1$  é

$$\mathbf{x}_1 = \frac{1}{\|e_1\|} e_1 = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} = \frac{\sqrt{5}}{5} \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}.$$

O vetor  $\mathbf{x}_2$  é

$$\mathbf{x}_2 = \frac{1}{\|e_2\|} e_2 = \frac{\sqrt{30}}{30} \begin{bmatrix} 3 \\ 3 \\ -2 \\ -2 \\ -2 \end{bmatrix}.$$

Finalmente, o vetor  $\mathbf{x}_3$  é

$$\mathbf{x}_3 = \frac{1}{\|e_3\|} e_3 = \frac{\sqrt{6}}{6} \begin{bmatrix} 0 \\ 0 \\ 1 \\ 1 \\ -2 \end{bmatrix}.$$

Como um dos 4 vetores colunas foi linearmente dependente dos demais, podemos afirmar que o posto da matriz  $\mathbf{X}$  é igual a 3. O posto refere-se ao número de colunas ou de linhas que são linearmente independentes.

- (b) determine o(s) vetor(es) coluna que é (são) linearmente dependente(s); Apenas o vetor  $\mathbf{v}_4$  é linearmente dependente dos três primeiros vetores.
- (c) se em vez de ortonormalizar as colunas, as linhas de  $\mathbf{X}$  fossem ortonormalizadas, haveria alguma mudança no posto da matriz? Qual será o número de linhas linearmente dependentes?

O posto coluna de uma matriz é igual ao posto linha. Desta forma, temos que apenas 3 linhas são linearmente independentes e o posto é o mesmo, ou seja, é igual a 3. Podemos verificar facilmente que a linha 1 é igual linha 2 e a linha 3 é igual a linha 4. Assim, podemos afirmar, após

simples verificação usando o processo de ortonormalização, que as linhas 1, 3 e 5 são linearmente independentes e as linhas 2 e 4 são linearmente dependentes.

1.1.3 Sejam as matrizes

$$\mathbf{A} = \begin{bmatrix} 4 & 2 & 2 \\ 2 & 2 & 0 \\ 2 & 0 & 4 \end{bmatrix} \quad \text{e} \quad \mathbf{B} = \begin{bmatrix} 6 & 4 & 2 \\ 4 & 4 & 0 \\ 2 & 0 & 6 \end{bmatrix}.$$

- (a) determine as inversas de  $\mathbf{A}$  e de  $\mathbf{B}$ , utilizando o algoritmo de Gauss-Jordan;

Para a matriz  $\mathbf{A}$ , usando o pivô  $a_{11} = 4$ , temos

$$\mathbf{A}^{(1)} = \left[ \begin{array}{ccc|ccc} \frac{1}{4} & & & \frac{1}{2} & & \frac{1}{2} \\ -\frac{1}{2} & & & 1 & & -1 \\ -\frac{1}{2} & & & -1 & & 3 \end{array} \right].$$

Escolhendo como pivô  $a_{22}^{(1)} = 1$  temos

$$\mathbf{A}^{(2)} = \left[ \begin{array}{ccc|ccc} \frac{1}{2} & & -\frac{1}{2} & & & 1 \\ -\frac{1}{2} & & 1 & & & -1 \\ -1 & & 1 & & & 2 \end{array} \right].$$

O último possível pivô é  $a_{33}^{(2)} = 2$ . Assim,

$$\mathbf{A}^{(3)} = \left[ \begin{array}{ccc|ccc} 1 & & -1 & & & -\frac{1}{2} \\ -1 & & \frac{3}{2} & & & \frac{1}{2} \\ -\frac{1}{2} & & \frac{1}{2} & & & \frac{1}{2} \end{array} \right],$$

que é a inversa

$$\mathbf{A}^{-1} = \begin{bmatrix} 1 & -1 & -\frac{1}{2} \\ -1 & \frac{3}{2} & \frac{1}{2} \\ -\frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix}.$$

Para a matriz  $\mathbf{B}$ , usando o pivô  $b_{11} = 6$ , temos

$$\mathbf{B}^{(1)} = \left[ \begin{array}{c|cc} \frac{1}{6} & \frac{2}{3} & \frac{1}{3} \\ \hline -\frac{2}{3} & \frac{4}{3} & -\frac{4}{3} \\ \hline -\frac{1}{3} & -\frac{4}{3} & \frac{16}{3} \end{array} \right].$$

Escolhendo como pivô  $b_{22}^{(1)} = 4/3$  temos

$$\mathbf{B}^{(2)} = \left[ \begin{array}{c|cc} \frac{1}{2} & -\frac{1}{2} & 1 \\ \hline -\frac{1}{2} & \frac{3}{4} & -1 \\ \hline -1 & 1 & 4 \end{array} \right].$$

O último possível pivô é  $b_{33}^{(2)} = 4$ . Assim,

$$\mathbf{B}^{(3)} = \left[ \begin{array}{cc|c} \frac{3}{4} & -\frac{3}{4} & -\frac{1}{4} \\ \hline -\frac{3}{4} & 1 & \frac{1}{4} \\ \hline -\frac{1}{4} & \frac{1}{4} & \frac{1}{4} \end{array} \right],$$

que é a inversa

$$\mathbf{B}^{-1} = \frac{1}{4} \begin{bmatrix} 3 & -3 & -1 \\ -3 & 4 & 1 \\ -1 & 1 & 1 \end{bmatrix}.$$

(b) determine  $\mathbf{AB}$  e sua inversa  $(\mathbf{AB})^{-1}$ ;

A matriz  $\mathbf{AB}$  é

$$\mathbf{AB} = \begin{bmatrix} 4 & 2 & 2 \\ 2 & 2 & 0 \\ 2 & 0 & 4 \end{bmatrix} \begin{bmatrix} 6 & 4 & 2 \\ 4 & 4 & 0 \\ 2 & 0 & 6 \end{bmatrix} = \begin{bmatrix} 36 & 24 & 20 \\ 20 & 16 & 4 \\ 20 & 8 & 28 \end{bmatrix}.$$

A inversa, aplicando o algoritmo anterior, é

$$(\mathbf{AB})^{-1} = \frac{1}{8} \begin{bmatrix} 13 & -16 & -7 \\ -15 & 19 & 8 \\ -5 & 6 & 3 \end{bmatrix}.$$

(c) verifique numericamente que  $(\mathbf{AB})^{-1} = \mathbf{B}^{-1}\mathbf{A}^{-1}$ .

Vamos verificar numericamente essa afirmativa por:

$$\begin{aligned}
 (\mathbf{AB})^{-1} &= \mathbf{B}^{-1} \mathbf{A}^{-1} \\
 \frac{1}{8} \begin{bmatrix} 13 & -16 & -7 \\ -15 & 19 & 8 \\ -5 & 6 & 3 \end{bmatrix} &= \frac{1}{4} \begin{bmatrix} 3 & -3 & -1 \\ -3 & 4 & 1 \\ -1 & 1 & 1 \end{bmatrix} \begin{bmatrix} 1 & -1 & -\frac{1}{2} \\ -1 & \frac{3}{2} & \frac{1}{2} \\ -\frac{1}{2} & \frac{1}{2} & \frac{1}{2} \end{bmatrix} \\
 \frac{1}{8} \begin{bmatrix} 13 & -16 & -7 \\ -15 & 19 & 8 \\ -5 & 6 & 3 \end{bmatrix} &= \frac{1}{8} \begin{bmatrix} 13 & -16 & -7 \\ -15 & 19 & 8 \\ -5 & 6 & 3 \end{bmatrix},
 \end{aligned}$$

CQM. ■

1.1.4 Seja a matriz

$$\mathbf{A} = \begin{bmatrix} 4 & 2 \\ 2 & 2 \end{bmatrix}.$$

(a) determine seus autovalores e autovetores pelo método da potência;

Escolhendo um vetor inicial  $\mathbf{v}^{(0)} = [1, 1]^T$ , temos

$$\mathbf{v}^{*(1)} = \mathbf{A}\mathbf{v}^{(0)} = \begin{bmatrix} 6 \\ 4 \end{bmatrix}.$$

Normalizando pelo valor absoluto máximo, temos

$$\mathbf{v}^{(1)} = \mathbf{v}^{*(1)} / \max[\text{abs}(\mathbf{v}^{*(1)})] = \begin{bmatrix} 1,0000 \\ 0,6667 \end{bmatrix}$$

Devemos obter um novo vetor e normalizá-lo, pois o vetor encontrado difere de novo vetor inicial arbitrário. Assim, temos

$$\begin{aligned}
 \mathbf{v}^{(2)*} &= \mathbf{A}\mathbf{v}^{(1)} = \begin{bmatrix} 5,3333 \\ 3,3333 \end{bmatrix} \\
 \mathbf{v}^{(2)} &= \mathbf{v}^{(2)*} / \max[\text{abs}(\mathbf{v}^{(2)*})] = \begin{bmatrix} 1,0000 \\ 0,6250 \end{bmatrix}.
 \end{aligned}$$

Novamente, escolhendo uma precisão de  $1 \times 10^{-6}$ , no oitavo passo obtivemos a convergência. O vetor normalizado pelo máximo valor absoluto

é

$$\mathbf{v}^{(8)} = \begin{bmatrix} 1,000000 \\ 0,618034 \end{bmatrix}.$$

O próximo passo é obtermos o primeiro autovetor normalizando  $\mathbf{v}^{(8)}$ . Logo,

$$\mathbf{x}_1 = \frac{\mathbf{v}^{(8)}}{\|\mathbf{v}^{(8)}\|} = \begin{bmatrix} 0,8506508 \\ 0,5257311 \end{bmatrix}.$$

O autovalor correspondente é dado por

$$\begin{aligned} \lambda_1 = \mathbf{x}_1^\top \mathbf{A} \mathbf{x}_1 &= \begin{bmatrix} 0,8506508 & 0,5257311 \end{bmatrix} \begin{bmatrix} 4 & 2 \\ 2 & 2 \end{bmatrix} \begin{bmatrix} 0,8506508 \\ 0,5257311 \end{bmatrix} \\ &= 5,236068. \end{aligned}$$

Para o próximo ciclo de iterações devemos obter

$$\begin{aligned} \mathbf{A}^{(1)} &= \mathbf{A} - \lambda_1 \mathbf{x}_1 \mathbf{x}_1^\top \\ &= \begin{bmatrix} 4 & 2 \\ 2 & 2 \end{bmatrix} - 5,236068 \begin{bmatrix} 0,8506508 \\ 0,5257311 \end{bmatrix} \begin{bmatrix} 0,8506508 & 0,5257311 \end{bmatrix} \\ &= \begin{bmatrix} 0,2111458 & -0,3416409 \\ -0,3416409 & 0,5527862 \end{bmatrix}. \end{aligned}$$

Escolhendo um vetor inicial  $\mathbf{v}^{(0)} = [1, -1]^\top$ , temos

$$\mathbf{v}^{*(1)} = \mathbf{A}^{(1)} \mathbf{v}^{(0)} = \begin{bmatrix} 0,5527865 \\ -0,8944272 \end{bmatrix}.$$

Normalizando pelo valor absoluto máximo, temos

$$\mathbf{v}^{(1)} = \mathbf{v}^{*(1)} / \max[\text{abs}(\mathbf{v}^{*(1)})] = \begin{bmatrix} 0,618034 \\ -1,000000 \end{bmatrix},$$

que difere bastante do vetor arbitrário original. Após a 2ª iteração temos

$$\mathbf{v}^{(2)*} = \mathbf{A}^{(1)}\mathbf{v}^{(1)} = \begin{bmatrix} 0,4721363 \\ -0,7639320 \end{bmatrix}$$

$$\mathbf{v}^{(2)} = \mathbf{v}^{(2)*} / \max[\text{abs}(\mathbf{v}^{(2)*})] = \begin{bmatrix} 0,6180344 \\ -1,0000000 \end{bmatrix}.$$

Para a precisão adotada, temos convergência nesse segundo passo do processo iterativo. Normalizando o vetor obtido temos o segundo autovetor dado por

$$\mathbf{x}_2 = \frac{\mathbf{v}^{(2)}}{\|\mathbf{v}^{(2)}\|} = \begin{bmatrix} 0,5257314 \\ -0,8506506 \end{bmatrix}$$

e o autovalor correspondente é dado por

$$\begin{aligned} \lambda_2 &= \mathbf{x}_2^\top \mathbf{A}^{(1)} \mathbf{x}_2 \\ &= \begin{bmatrix} 0,52573 & -0,85065 \end{bmatrix} \begin{bmatrix} 0,2111458 & -0,3416409 \\ -0,3416409 & 0,5527862 \end{bmatrix} \begin{bmatrix} 0,52573 \\ -0,85065 \end{bmatrix} \\ &= 0,763932. \end{aligned}$$

- (b) construa uma matriz  $\mathbf{P}$  com cada coluna formada dos autovetores de  $\mathbf{A}$ ;  
A matriz  $\mathbf{P}$  é

$$\mathbf{P} = \begin{bmatrix} 0,8506508 & 0,5257314 \\ 0,5257311 & -0,8506506 \end{bmatrix}$$

- (c) verifique se  $\mathbf{P}$  é uma matriz ortogonal;

Podemos verificar facilmente que

$$\mathbf{P}^\top \mathbf{P} = \begin{bmatrix} 0,8506508 & 0,5257311 \\ 0,5257314 & -0,8506506 \end{bmatrix} \begin{bmatrix} 0,8506508 & 0,5257314 \\ 0,5257311 & -0,8506506 \end{bmatrix} = \mathbf{I}$$

e

$$\mathbf{P}\mathbf{P}^\top = \begin{bmatrix} 0,8506508 & 0,5257314 \\ 0,5257311 & -0,8506506 \end{bmatrix} \begin{bmatrix} 0,8506508 & 0,5257311 \\ 0,5257314 & -0,8506506 \end{bmatrix} = \mathbf{I},$$

exceto por arredondamentos numéricos, comprovando que  $\mathbf{P}$  é ortogonal.

- (d) construa uma matriz  $\mathbf{\Lambda} = \text{diag}(\lambda_i)$  e verifique se as seguintes igualdades valem:  $\mathbf{A} = \mathbf{P}\mathbf{\Lambda}\mathbf{P}^\top$  e  $\mathbf{\Lambda} = \mathbf{P}^\top\mathbf{A}\mathbf{P}$ .

A matriz  $\mathbf{\Lambda}$  é

$$\mathbf{\Lambda} = \begin{bmatrix} 5,236068 & 0,000000 \\ 0,000000 & 0,763932 \end{bmatrix}.$$

Podemos verificar numericamente que

$$\mathbf{P}^\top\mathbf{A} = \begin{bmatrix} 4,4540655 & 2,7527638 \\ 0,4016228 & -0,6498394 \end{bmatrix}$$

e, portanto,

$$\begin{aligned} \mathbf{P}^\top\mathbf{A}\mathbf{P} &= \mathbf{\Lambda} \\ &= \begin{bmatrix} 5,236068 & 0,000000 \\ 0,000000 & 0,763932 \end{bmatrix}. \end{aligned}$$

Da mesma forma, temos que

$$\mathbf{P}\mathbf{\Lambda} = \begin{bmatrix} 4,454065 & 0,4016228 \\ 2,752764 & -0,6498394 \end{bmatrix}$$

e, portanto,

$$\begin{aligned} \mathbf{P}\mathbf{\Lambda}\mathbf{P}^\top &= \mathbf{A} \\ &= \begin{bmatrix} 4 & 2 \\ 2 & 2 \end{bmatrix}, \end{aligned}$$

CQM. ■

1.1.5 Seja a matriz

$$\mathbf{A} = \begin{bmatrix} 4,6 & 7,2 \\ 7,2 & 0,4 \end{bmatrix}.$$

- (a) obtenha  $|\mathbf{A}|$ ;

O determinante é dado por

$$|\mathbf{A}| = 4,6 \times 0,4 - 7,2^2 = -50.$$

- (b) é possível afirmar com base no resultado de  $|\mathbf{A}|$  se a matriz  $\mathbf{A}$  é positiva definida? Por quê?

Como  $\mathbf{A}$  é uma matriz  $2 \times 2$ , o seu determinante pode ser expresso por  $|\mathbf{A}| = \lambda_1 \times \lambda_2$ , em que  $\lambda_1$  e  $\lambda_2$  são os autovalores de  $\mathbf{A}$ . Como esse produto resultou em um número negativo, então podemos concluir que um dos autovalores é negativo, pois a única possibilidade para o produto de dois autovalores dar negativo é que um deles seja positivo e o outro negativo. Sendo assim, como  $\mathbf{A}$  possui um autovalor negativo, podemos afirmar que  $\mathbf{A}$  não é positiva definida e, portanto, não admite fator de Cholesky. De uma maneira geral, se  $|\mathbf{A}| < 0$ , podemos afirmar que há um autovalor ao menos negativo e a matriz não é positiva definida. Se por outro lado, o determinante for positivo, não poderemos afirmar nada sobre a possibilidade de a matriz ser ou não ser positiva definida, pois poderíamos ter um número par de autovalores negativos, que resultaria em um produtório positivo.

- (c) verifique se  $\mathbf{A}$  possui fator de Cholesky. De acordo com o resultado obtido, como a matriz  $\mathbf{A}$  é classificada?

Como, nesse exemplo, um dos autovalores é sabidamente positivo e outro negativo, a matriz não admite fator de Cholesky e é classificada como indefinida.

- (d) determine os autovalores e autovetores de  $\mathbf{A}$ ;

Usando o método da potência, obtivemos  $\lambda_1 = 10$  e  $\lambda_2 = -5$  com os autovetores correspondentes apresentados como colunas da matriz  $\mathbf{P}$  dada por

$$\mathbf{P} = \begin{bmatrix} 0,8 & 0,6 \\ 0,6 & -0,8 \end{bmatrix}$$

- (e) obtenha a decomposição espectral de  $\mathbf{A}$ ;

Logo, a decomposição espectral de  $\mathbf{A}$  é

$$\mathbf{A} = \lambda_1 \mathbf{x}_1 \mathbf{x}_1^\top + \lambda_2 \mathbf{x}_2 \mathbf{x}_2^\top$$

$$\begin{bmatrix} 4,6 & 7,2 \\ 7,2 & 0,4 \end{bmatrix} = \begin{bmatrix} 6,4 & 4,8 \\ 4,8 & 3,6 \end{bmatrix} + \begin{bmatrix} -1,8 & 2,4 \\ 2,4 & -3,2 \end{bmatrix}$$

(f) encontre  $\mathbf{A}^{-1}$ ;

$$\mathbf{A}^{-1} = -\frac{1}{50} \begin{bmatrix} 0,4 & -2,4 \\ -2,4 & 4,8 \end{bmatrix} = \begin{bmatrix} -0,008 & 0,144 \\ 0,144 & -0,092 \end{bmatrix}.$$

(g) encontre os autovalores de  $\mathbf{A}^{-1}$  e verifique a relação que eles têm com os autovalores de  $\mathbf{A}$ .

Utilizando o método da potência encontramos  $\lambda_1 = 0,1$  e  $\lambda_2 = -0,2$ . Podemos verificar facilmente que os autovalores de  $\mathbf{A}^{-1}$  são exatamente os recíprocos dos autovalores de  $\mathbf{A}$ .

1.1.6 É possível afirmar que se o determinante de uma matriz está muito próximo de 0 é porque a matriz está próxima da singularidade?

Não. Determinante próximo de zero não implica necessariamente na quase singularidade. No exercício a seguir, isso fica muito claro. É claro que a maior parte das vezes que o determinante aproxima-se de zero, é indicativo de que algumas linhas ou colunas da matriz está próxima de ser uma combinação linear das demais, embora isso não seja verdade sempre. Então, afirmar algo sobre a singularidade de uma matriz baseado no seu determinante é uma prática com risco de falhar muito alto.

1.1.7 Observe as seguintes matrizes

$$\mathbf{A} = \begin{bmatrix} n & 0 \\ 0 & \frac{1}{n} \end{bmatrix} \quad \text{e} \quad \mathbf{B} (n \times n) = \begin{bmatrix} 0,1 & 0 & \cdots & 0 \\ 0 & 0,1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0,1 \end{bmatrix}.$$

Se fizermos  $n \rightarrow \infty$  o que podemos afirmar sobre a singularidade de ambas as matrizes? O que podemos afirmar sobre seu determinante? Existe alguma

relação entre quasi-singularidade e determinante?

Os determinantes das matrizes são

$$|\mathbf{A}| = n \times \frac{1}{n} = 1 \quad \text{e} \quad |\mathbf{B}| = 0,1^n.$$

Se  $n \rightarrow \infty$ , a matriz  $\mathbf{A}$  tende para a singularidade, embora seu determinante fique inalterado em 1, pois

$$\lim_{n \rightarrow \infty} n \times \frac{1}{n} = 1.$$

Assim, a matriz  $\mathbf{A}$  caminha para a singularidade, uma vez que a segunda linha ou segunda coluna tende para um vetor nulo, enquanto seu determinante fica inalterado em 1, bem distante de se aproximar de zero.

Por outro lado se  $n \rightarrow \infty$ , a matriz  $\mathbf{B}$  fica longe da não-singularidade, pois sua diagonal fica com elementos iguais a 0,1, embora sua dimensão é que aumente. Entretanto,

$$\lim_{n \rightarrow \infty} |\mathbf{B}| = \lim_{n \rightarrow \infty} 0,1^n = 0.$$

Assim, o determinante de  $\mathbf{B}$  tem seu limite igual a zero quando  $n \rightarrow \infty$ , mas  $\mathbf{B}$  é muito distante de ser uma matriz singular.

Esses contra-exemplos nos permitem afirmar que não há relação entre valor do determinante e singularidade de uma matriz.

1.1.8 Sejam as matrizes

$$\mathbf{A} = \begin{bmatrix} 4 & 1 \\ 1 & 2 \end{bmatrix} \quad \text{e} \quad \mathbf{B} = \begin{bmatrix} 2 & -1 \\ -1 & 1 \end{bmatrix}.$$

Determine os autovalores e autovetores que maximizam a razão

$$\lambda(\mathbf{x}) = \frac{\mathbf{x}^\top \mathbf{A} \mathbf{x}}{\mathbf{x}^\top \mathbf{B} \mathbf{x}}, \quad |\mathbf{B}| \neq 0.$$

1.1.9 Seja a função  $g(\boldsymbol{\mu}, \boldsymbol{\Sigma}; \mathbf{x}) = -\frac{np}{2} \ln(2\pi) - \frac{n}{2} \ln(|\boldsymbol{\Sigma}|) - \frac{1}{2} \sum_{j=1}^n (\mathbf{x}_j - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x}_j - \boldsymbol{\mu})$ , com  $n, p \in \mathbb{N}$ ,  $\mathbf{x}_j$  ( $p \times 1$ ) conhecidos e  $\boldsymbol{\Sigma}$  ( $p \times p$ ) e  $\boldsymbol{\mu}$  ( $p \times 1$ ) desconhecidos. Obtenha a derivada  $\partial g(\boldsymbol{\mu}, \boldsymbol{\Sigma}; \mathbf{x}) / \partial \boldsymbol{\mu}$ . Iguale a função resultante a zero e encontre a solução para  $\boldsymbol{\mu}$ . Substitua a solução encontrada em  $g(\boldsymbol{\mu}, \boldsymbol{\Sigma}; \mathbf{x})$  e obtenha

a derivada  $\partial g(\Sigma; \mathbf{x}, \hat{\boldsymbol{\mu}})/\partial \Sigma$ , sendo  $\hat{\boldsymbol{\mu}}$  a solução encontrada de  $\boldsymbol{\mu}$  anteriormente. Iguale a função resultante a zero e encontre a solução para  $\Sigma$ .

## Capítulo 2

# Introdução e Conceitos Básicos

### 2.1 Exercícios


2.1.1 Seja a função de distribuição bivariada dada pela seguinte expressão  $F(y_1, y_2) = k \left( \frac{2}{5} y_1^4 y_2 + \frac{1}{5} y_1 y_2^3 \right)$ , no domínio  $0 \leq y_1 \leq 1$  e  $0 \leq y_2 \leq 1$ . Determine:

(a) A constante  $k$  para que  $F(y_1, y_2)$  seja uma função de distribuição legítima.

Para que  $F(y_1, y_2)$  seja uma genuína função de distribuição de probabilidade bivariada  $F(1, 1) = 1$  e  $F(0, 0) = 0$ . Assim, qualquer que seja  $k \in \mathbb{R}$ ,  $F(0, 0) = 0$ . Para o outro caso temos

$$F(1, 1) = 1 = k \left( \frac{2}{5} \times 1^4 \times 1 + \frac{1}{5} \times 1 \times 1^3 \right) = \frac{3k}{5}.$$

Portanto,  $k = 5/3$ . O gráfico da função de distribuição é



A função de distribuição é


$$F(y_1, y_2) = \frac{2}{3}y_1^4y_2 + \frac{1}{3}y_1y_2^3.$$

(b) A função densidade de probabilidade conjunta  $f(y_1, y_2)$ .

Para obtermos a função densidade probabilidade conjunta bivariada devemos obter as derivadas parciais de primeira ordem em relação a cada uma das variáveis, dado  $k = 5/3$ . Logo,

$$\begin{aligned} f(y_1, y_2) &= \frac{\partial^2 F(y_1, y_2)}{\partial y_1 \partial y_2} = \frac{\partial}{\partial y_2} \frac{8}{3}y_1^3y_2 + \frac{1}{3}y_2^3 \\ &= \frac{8}{3}y_1^3 + y_2^2, \end{aligned}$$

cujo gráfico correspondente é



(c) O vetor de médias populacionais.

A média da primeira variável é dada por

$$\begin{aligned} E(Y_1) = \mu_1 &= \int_0^1 \int_0^1 y_1 \left( \frac{8}{3}y_1^3 + y_2^2 \right) dy_2 dy_1 = \int_0^1 \left[ \frac{8}{3}y_1^4y_2 + \frac{1}{3}y_2^3y_1 \right]_0^1 dy_1 \\ &= \int_0^1 \frac{8}{3}y_1^4 + \frac{1}{3}y_1 dy_1 = \left[ \frac{8}{15}y_1^5 + \frac{1}{6}y_1^2 \right]_0^1 = \frac{8}{15} + \frac{1}{6} = \frac{7}{10}. \end{aligned}$$

Para a variável  $Y_2$ , temos

$$\begin{aligned} E(Y_2) = \mu_2 &= \int_0^1 \int_0^1 y_2 \left( \frac{8}{3}y_1^3 + y_2^2 \right) dy_2 dy_1 = \int_0^1 \left[ \frac{4}{3}y_1^3 y_2^2 + \frac{1}{4}y_2^4 \right]_0^1 dy_1 \\ &= \int_0^1 \frac{4}{3}y_1^3 + \frac{1}{4}dy_1 = \left[ \frac{1}{3}y_1^4 + \frac{1}{3}y_1 \right]_0^1 = \frac{1}{3} + \frac{1}{4} = \frac{7}{12}. \end{aligned}$$

Logo, o vetor de médias de  $\mathbf{Y}$  é

$$E(\mathbf{Y}) = \begin{bmatrix} \mu_1 \\ \mu_2 \end{bmatrix} = \begin{bmatrix} \frac{7}{10} \\ \frac{7}{12} \end{bmatrix}.$$

(d) A matriz de covariâncias populacional.

A matriz de covariância é obtida da seguinte forma. Devemos calcular as variâncias e as covariâncias por meio das esperanças matemáticas apresentadas a seguir, para as quais omitimos os detalhes dos cálculos. Assim,

$$\begin{aligned} E(Y_1 - \mu_1)^2 = \sigma_{11} &= \int_0^1 \int_0^1 \left( y_1 - \frac{7}{10} \right)^2 \left( \frac{8}{3}y_1^3 + y_2^2 \right) dy_1 dy_2 \\ &= \frac{59}{900}, \end{aligned}$$

$$\begin{aligned} E(Y_2 - \mu_2)^2 = \sigma_{22} &= \int_0^1 \int_0^1 \left( y_2 - \frac{7}{12} \right)^2 \left( \frac{8}{3}y_1^3 + y_2^2 \right) dy_1 dy_2 \\ &= \frac{59}{720} \end{aligned}$$

e

$$\begin{aligned} E(Y_1 - \mu_1)(Y_2 - \mu_2) = \sigma_{12} = \sigma_{21} &= \int_0^1 \int_0^1 \left( y_1 - \frac{7}{10} \right) \left( y_2 - \frac{7}{12} \right) \left( \frac{8}{3}y_1^3 + y_2^2 \right) dy_1 dy_2 \\ &= -\frac{1}{60}. \end{aligned}$$

Portanto, a matriz de covariâncias é

$$\Sigma = \begin{bmatrix} \frac{59}{900} & -\frac{1}{60} \\ -\frac{1}{60} & \frac{59}{720} \end{bmatrix}$$

(e) A matriz de correlações populacional.

A correlação populacional entre as duas variáveis é

$$\rho_{12} = \frac{-1/60}{\sqrt{59/900}\sqrt{59/720}} = -0,2273967435.$$

Assim, a matriz de correlação é

$$\boldsymbol{\rho} = \begin{bmatrix} 1,0000 & -0,2274 \\ -0,2274 & 1,0000 \end{bmatrix}$$

(f) O coeficiente de assimetria e curtose.

Esse é o procedimento mais trabalhoso, pois as integrais que necessitamos calcular são muito trabalhosas, mesmo com um modelo simples como esse. Considerando  $X_1$  e  $Y_2$ , réplicas das variáveis  $Y_1$  e  $Y_2$ , distribuídas independentemente dessas, temos que a função densidade conjunta de  $X_1$  e  $X_2$  é

$$f(x_1, x_2) = \frac{8}{3}x_1^3 + x_2^2.$$

A função densidade conjunta de todas as 4 variáveis é

$$f(y_1, y_2, x_1, x_2) = \left(\frac{8}{3}y_1^3 + y_2^2\right) \left(\frac{8}{3}x_1^3 + x_2^2\right)$$

e  $(\mathbf{y} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})$  é

$$\begin{aligned} (\mathbf{y} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}) &= \left[ \frac{53100}{3301}y_1 - \frac{43470}{3301} + \frac{10800}{3301}y_2 \right] \left( x_1 - \frac{7}{10} \right) + \\ &+ \left[ \frac{10800}{3301}y_1 - \frac{32340}{3301} + \frac{42480}{3301}y_2 \right] \left( x_2 - \frac{7}{12} \right) \end{aligned}$$

Logo, o coeficiente de assimetria é

$$\begin{aligned} \beta_{12} &= \int_0^1 \int_0^1 \int_0^1 \int_0^1 [(\mathbf{y} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})]^3 f(y_1, y_2, x_1, x_2) dx_1 dx_2 dy_1 dy_2 \\ &= 1,120701108. \end{aligned}$$

Da mesma forma, temos que

$$\begin{aligned}
 (\mathbf{y} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu}) &= \left[ \frac{53100}{3301}y_1 - \frac{43470}{3301} + \frac{10800}{3301}y_2 \right] \left( y_1 - \frac{7}{10} \right) + \\
 &+ \left[ \frac{10800}{3301}y_1 - \frac{32340}{3301} + \frac{42480}{3301}y_2 \right] \left( y_2 - \frac{7}{12} \right)
 \end{aligned}$$

e o coeficiente de curtose é

$$\begin{aligned}
 \beta_{22} &= \int_0^1 \int_0^1 [(\mathbf{y} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{y} - \boldsymbol{\mu})]^2 f(y_1, y_2) dy_1 dy_2 \\
 &= 6,610376680.
 \end{aligned}$$

Dessa forma, podemos observar que esta distribuição é assimétrica e platicúrtica ( $\beta_{22} < 8$ ), ou seja achatada, em relação a distribuição normal bivariada.

2.1.2 Mostre que a função  $f(y_1, y_2) = -\frac{3}{13}(y_1^2 + y_2^2 - 5)$  é uma função densidade de probabilidade bivariada no domínio  $0 \leq y_1 \leq 1$  e  $0 \leq y_2 \leq 1$ . Trace o gráfico da função densidade e obtenha a função de distribuição de probabilidade.


Para mostrarmos que  $f(y_1, y_2)$  é uma função densidade legítima, temos que mostrar que seu valor é não negativo no domínio das variáveis e que a integral definida, também no domínio das variáveis resulta em valor igual a 1. Portanto,

$$\begin{aligned}
 -\frac{3}{13}(y_1^2 + y_2^2 - 5) &\geq 0 \\
 y_1^2 + y_2^2 &\leq 5.
 \end{aligned}$$

Como o máximo valor de  $y_1$  ou de  $y_2$  é igual a 1, facilmente verificamos que a desigualdade anterior ocorrerá sempre, indicando que o valor da função densidade de probabilidade conjunta será sempre não negativa. A segunda condição é verificada por

$$\begin{aligned}
 \int_0^1 \int_0^1 \left[ -\frac{3}{13}(y_1^2 + y_2^2 - 5) \right] dy_2 dy_1 &= \int_0^1 -\frac{3}{13} \left[ \left( y_1^2 y_2 + \frac{1}{3} y_2^3 - 5y_2 \right) \right]_0^1 dy_1 \\
 &= \int_0^1 -\frac{3}{13} \left( y_1^2 + \frac{1}{3} - 5 \right) dy_1 = -\frac{3}{13} \left[ \left( \frac{1}{3} y_1^3 + \frac{1}{3} y_1 - 5y_1 \right) \right]_0^1 \\
 &= -\frac{3}{13} \left( \frac{1}{3} + \frac{1}{3} - \frac{15}{3} \right) = -\frac{3}{13} \times \left( -\frac{13}{3} \right) = 1.
 \end{aligned}$$


Assim, a função apresentada atende aos requisitos para ser considerada uma função densidade legítima. O seu gráfico apresentado a seguir nos fornece um mecanismo para verificarmos a primeira das propriedades anteriormente apresentada.



A função de distribuição de probabilidade é obtida por

$$\begin{aligned} F(y_1, y_2) &= \int_0^{y_1} \int_0^{y_2} \left[ -\frac{3}{13} (t_1^2 + t_2^2 - 5) \right] dt_2 dt_1 \\ &= -\frac{1}{13} (y_1^3 y_2 + y_1 y_2^3 - 15y_1 y_2). \end{aligned}$$

O seu gráfico é dado por



2.1.3 Sejam dois vetores aleatórios  $\mathbf{y}_1 = [2, 3]^\top$  e  $\mathbf{y}_2 = [2, 1]^\top$  e considere a matriz

de covariâncias amostral igual a

$$\mathbf{s} = \begin{bmatrix} 10 & 6 \\ 6 & 8 \end{bmatrix},$$

logo, determine:

- (a) A distância euclidiana entre os dois vetores.

A distância euclidiana quadrática é obtida por

$$\begin{aligned} d^2(\mathbf{y}_1, \mathbf{y}_2) &= (\mathbf{y}_1 - \mathbf{y}_2)^\top (\mathbf{y}_1 - \mathbf{y}_2) = \sum_{k=1}^p (y_{1k} - y_{2k})^2 \\ &= (2 - 2)^2 + (3 - 1)^2 = 4. \end{aligned}$$

- (b) A distância quadrática de Karl Pearson.

Vamos calculá-la por

$$\begin{aligned} d^2(\mathbf{y}_1, \mathbf{y}_2) &= (\mathbf{y}_1 - \mathbf{y}_2)^\top \mathbf{D}^{-1} (\mathbf{y}_1 - \mathbf{y}_2) = \sum_{k=1}^p \frac{(y_{1k} - y_{2k})^2}{S_{kk}} \\ &= \frac{(2 - 2)^2}{10} + \frac{(3 - 1)^2}{8} = 0,5. \end{aligned}$$

- (c) A distância generalizada de Mahalanobis.

$$\begin{aligned} d^2(\mathbf{y}_1, \mathbf{y}_2) &= (\mathbf{y}_1 - \mathbf{y}_2)^\top \mathbf{S}^{-1} (\mathbf{y}_1 - \mathbf{y}_2) \\ &= [0, 2] \begin{bmatrix} 0,1818182 & -0,1363636 \\ -0,1363636 & 0,2272727 \end{bmatrix} \begin{bmatrix} 0 \\ 2 \end{bmatrix} \\ &= 0,909091. \end{aligned}$$

- (d) Qual das três distâncias você considera mais apropriada para essa situação e por quê?

Houve uma grande diferença nos valores das três distâncias, sendo que a mais apropriada para essa situação é a distância de Mahalanobis. Há diferença nas escalas das variáveis, o que não é contemplado pela distância euclidiana, mas é pela distância de Karl Pearson. Entretanto, a correlação entre as duas variáveis do modelo é de 0,6708. A distância de Karl Pearson não considera a correlação (covariância) entre as variáveis, o que é feito pela distância generalizada de Mahalanobis. Assim, a distância

generalizada de Mahalanobis, por contemplar tanto as diferenças de variabilidade entre as variáveis quanto as correlações existentes entre elas, é a mais apropriada. Professor Bussab em uma palestra do curso de verão no IME/USP, em que eu era aluno, disse que a distância de Mahalanobis podia ser comparada com a distância entre dois pontos de um rio, que queremos atravessar. Ele nos perguntou qual seria a menor distância determinada por dois pontos do outro lado da margem em relação a um ponto da margem onde nos encontrávamos. Um em linha reta, perpendicular ao sentido da correnteza, e outro mais abaixo, oblíquo ao sentido do fluxo da correnteza do rio. Obviamente a menor distância no espaço euclidiano é do ponto em linha reta, perpendicular ao fluxo do rio. Essa seria a distância euclidiana. Mas em termos de esforço que faríamos para nadarmos ou remarmos até a outra margem, o ponto mais abaixo, longitudinal, mas que acompanhava a corredeira do rio, estaria mais perto. Essa parábola apresentada pelo Professor Bussab nos dá noção exata do conceito de distância estatística. Ao nos explicar isso, professor Bussab mencionou que a correnteza do rio seria comparável às correlações e às diferentes variabilidades. Dai, quando utilizamos uma medida de distância em que há diferenças de escala e há correlações não-nulas entre as variáveis, a distância de Mahalanobis é a mais apropriada.

2.1.4 Obtenha as variâncias generalizadas da matriz de covariâncias amostral apresentada a seguir. Determine a matriz de correlações e a variância generalizada correspondente. Obtenha a matriz de correlação amostral  $\mathbf{r}$  correspondente e verifique que é a mesma que seria obtida no exercício 2.1.3. Obtenha as variâncias generalizadas da matriz  $\mathbf{s}$  do exercício 2.1.3 e também da matriz  $\mathbf{r}$ . Compare os três resultados obtidos.

$$\mathbf{s} = \begin{bmatrix} 32 & 12 \\ 12 & 10 \end{bmatrix}$$

A variância generalizada estimada é

$$|\mathbf{s}| = 32 \times 10 - 12^2 = 320 - 144 = 176.$$

A variância generalizada estimada da matriz  $\mathbf{s}$  do exercício 2.1.3 é

$$|\mathbf{s}| = 10 \times 8 - 6^2 = 80 - 36 = 64.$$

A matriz de correlação amostral é

$$\mathbf{r} = \begin{bmatrix} 1,0000 & 0,6708 \\ 0,6708 & 1,0000 \end{bmatrix}$$

A variância generalizada correspondente é

$$|\mathbf{r}| = 1 \times 1 - 0,6708^2 = 0,550027.$$

Podemos observar que ambas as matrizes de covariâncias possuem a mesma estrutura de correlação, mas apresentam diferentes variâncias generalizadas. A razão disso é que quanto maior for a variância de uma variável, maior será a variância generalizada. No primeiro caso, a variância generalizada é dada por  $320 \times 0,550027$  e no segundo  $80 \times 0,550027$ . Isso indica que os fatores 320 e 80, produtos das variâncias amostrais, reescalam a variância generalizada da matriz de correlação. Isso mostra o efeito das escalas no volume do hiperparalelepípedo determinado pelas variâncias e covariâncias das variáveis. Dependendo do problema podemos utilizar esse fato de forma favorável e em outros casos, a diferença de escalas pode ser desfavorável. Nesses casos, devemos usar variâncias generalizadas das matrizes de correlações.