



**RAD1509 – Estatística Aplicada à Administração II**  
**Prof. Dr. Evandro Marcos Saidel Ribeiro**  
**RESUMO**

**1 Matriz de correlação**

A matriz de correlação é escrita na forma:

$$\mathbf{R} = \begin{bmatrix} 1 & r_{12} & \dots & r_{1k} \\ r_{21} & 1 & \dots & r_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ r_{k1} & r_{k2} & \dots & 1 \end{bmatrix} \quad (1)$$

O cálculo de cada elemento desta matriz pode ser obtido da matriz **S** por:

$$r_{ij} = \frac{S_{ij}}{\sqrt{S_{ii}} \sqrt{S_{jj}}} \quad (2)$$

Sendo *i* e *j* duas variáveis,  $x_1$  e  $x_2$ . Por exemplo, para,  $x_1$  e  $x_2$  dados por

$$\mathbf{X} = \begin{bmatrix} 2 & 1 \\ 9 & 8 \\ 7 & 5 \\ 3 & 4 \\ 4 & 2 \end{bmatrix}, \quad (3)$$

A correlação será  $r_{12} = 0,908025$ .

A correlação pode ser obtida na HP12C pelo seguinte procedimento:

- Digite os dados:  $x_2$  [enter]  $x_1$   $\Sigma+$  (4)
- Obtenha o valor de  $r$ : [g] 2 [xy] (5)

**2 Matriz de covariância**

O cálculo de cada elemento da matriz de covariância pode ser feito a partir da matriz de correlação. Assim, a partir da correlação  $r_{12}$ , entre duas variáveis  $x_1$  e  $x_2$ , a covariância é dada por:

$$S_{ij} = r_{ij} s_i s_j \quad (6)$$

Na expressão (11)  $s_i$  e  $s_j$  são os desvios-padrão das variáveis *i* e *j*, respectivamente.

**3 Componentes Principais e Análise Fatorial**

Na Análise Fatorial (AF) cada variável é associada a Fatores:

$$x_i = a_{i1}F_1 + a_{i2}F_2 + \dots + a_{in}F_n \quad (7)$$

sendo  $a_{ij}$  cargas fatoriais.

As cargas fatoriais são dadas numa “Tabela de Cargas Fatoriais”. Por exemplo: Considerando 4 variáveis e dois fatores:

**Tabela 1. Cargas Fatoriais**

Variável	Fator 1	Fator 2
X1	0,15	0,70
X2	0,02	0,84
X3	-0,85	0,01
X4	0,90	0,05

A soma das cargas fatoriais ao quadrado para uma determinada variável (soma em todos os NF fatores) é igual a comunalidade da variável:

$$h_i = \sum_{j=1}^{NF} a_{ij}^2 \quad (8)$$

Se a soma for feita para um determinado índice relacionado a um fator (soma para todas as *k* variáveis) então obtemos o autovalor correspondente ao fator em questão:

$$\lambda_j = \sum_{i=1}^k a_{ij}^2 \quad (9)$$

Para o exemplo na Tabela 1 temos os resultados de autovalores e comunalidades apresentados na Tabela 2.

**Tabela 2. Cargas Fatoriais, Comunalidades e Autovalores**

Variável	Fator 1	Fator 2	Comunalidade (hi)
X1	0,15	0,70	0,51
X2	0,02	0,84	0,71
X3	-0,85	0,01	0,72
X4	0,90	0,05	0,81
Autovalor ( $\lambda_i$ )	1,5554	1,1982	
% Variância	38,89	29,96	

### Autovalores:

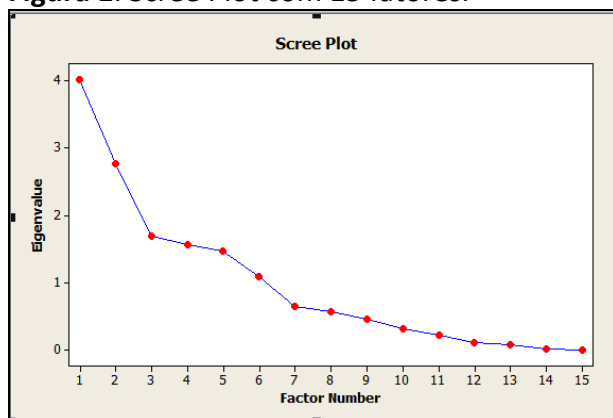
O percentual da variação explicada: Na análise de componentes principais a variação explicada por cada componente é dada pelo autovalor dividido pela soma dos autovalores:

$$CP_i = \frac{\lambda_i}{\sum \lambda} \times 100 \quad (10)$$

Considerando a matriz de correlação, a soma dos autovalores é igual ao número de variáveis.

Um gráfico de autovalores é o Scree Plot. Para fazer este gráfico deve-se ordenar os autovalores do maior para o menor. No eixo-x são consideradas as componentes (ou índices dos fatores), no eixo-y são considerados os autovalores. Exemplo na Figura 1 abaixo.

Figura 1. Scree Plot com 15 fatores.



Um dos objetivos principais da AF: cada Fator pode ser escrito em termos das variáveis sendo possível assim obter uma função para o Escore Fatorial  $j$ :

$$F_j = b_{j1}x_1 + b_{j2}x_2 + \dots + b_{jk}x_k \quad (11)$$

O número de fatores a serem considerados pode ser obtido pelo

$$\text{Critério Kaiser: autovalores} > 1 \quad (12)$$

Os coeficientes para o Escore Fatorial são dados na Tabela de Coeficientes de Escore Fatorial. Por exemplo: Considerando 4 variáveis e dois fatores, um exemplo pode ser visto na Tabela 3.

Tabela 3. Coeficientes dos Escores Fatoriais

Variável	Fator 1	Fator 2
X1	0,35	0,80
X2	0,02	0,95
X3	-0,94	0,10
X4	0,99	0,10

A partir da Tabela 3 e dos valores de cada variável são obtidos os Escores Fatoriais de acordo com a equação (11) para cada caso em análise.

Por Exemplo:

Considerando um caso no qual

$$(x_1; x_2; x_3; x_4) = (1,5; -1,0; 1,0; 2)$$

O Escore Fatorial 1, dado pela expressão (11) é calculado com os valores de  $b_j$  da Tabela 3:

$$F_1 = 0,35 \times 1,5 + 0,02 \times (-1,0) - 0,94 \times 1,0 + 0,99 \times 2,0 = 1,545$$

### 4 Análise de Agrupamentos: Hierárquico

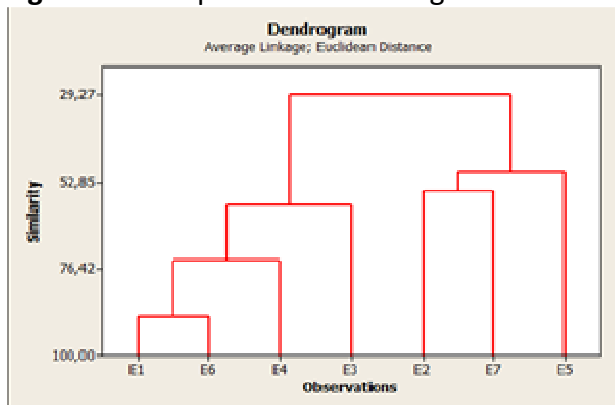
Objetivo dessa técnica é agrupar objetos (itens) semelhantes segundo suas características (variáveis)

Procedimento:

- Padronizar as variáveis:  $z_i = (x_i - \bar{x}_i) / s_i$
- Obter uma matriz de distâncias
- Aplicar um método de aglomeração, por exemplo os métodos hierárquicos
  - Ligação Simples (vizinho mais próximo), ou ainda Single Linkage
  - Ligação Completa (vizinho mais distante), ou ainda Complete Linkage
  - Ligação Média (distância média), ou ainda Average linkage
- Considerar a menor distância para formar um grupo.
- Recalcular a matriz de distâncias
- No final, esboçar um Dendrograma

A Figura 2 apresenta um exemplo de Dendrograma resultante da Análise de Agrupamento de sete empresas visto em aula (ver slides).

**Figura 2.** Exemplo de um dendrograma.



## 5 Análise Discriminante

Utilizada para determinar quais variáveis discriminam entre dois ou mais grupos já conhecidos.

**A variável dependente é categórica** e indica os grupos já conhecidos. As variáveis independentes podem ser métricas ou categóricas, estas deverão ter poder de discriminar os indivíduos entre dois ou mais grupos.

O primeiro passo é compor para cada grupo ( $g_i$ ), as funções discriminantes ( $d_i$ ):

$$\text{Para } g_1: d_1 = \beta_{10} + \beta_{11}x_1 + \beta_{12}x_2 + \dots + \beta_{1n}x_n$$

$$\text{Para } g_2: d_2 = \beta_{20} + \beta_{21}x_1 + \beta_{22}x_2 + \dots + \beta_{2n}x_n$$

⋮

$$\text{Para } g_k: d_k = \beta_{k0} + \beta_{k1}x_1 + \beta_{k2}x_2 + \dots + \beta_{kn}x_n$$

Para classificar um indivíduo num determinado grupo devemos substituir as variáveis  $x_1, x_2, \dots, x_n$  em todas as funções discriminantes  $d_i$ . A função que obtiver o maior valor indica a classificação do indivíduo para o grupo correspondente.

Os coeficientes  $\beta$ 's são fornecidos numa tabela de coeficientes para Funções Discriminantes. Por exemplo, a Tabela 4 apresenta os coeficientes para as funções discriminantes, considerando 5 variáveis explicativas e uma variável dependente com 3 categorias.

**Tabela 4.** Coeficientes para Funções Discriminantes para três grupos.

↓	C7	C8	C9
	disc1	disc2	disc3
1	-2,6888E+01	-4,3228E+01	-3,5491E+01
2	3,1581E-06	1,2579E-06	9,7455E-07
3	4,0853E-01	6,5124E-01	6,8182E-01
4	2,3688E+01	4,3778E+01	2,2095E+01
5	3,3481E-01	4,6246E-01	5,8346E-01
6			

O percentual de acerto pode ser obtido a partir de uma tabela de classificação. Nesta Tabela de Classificação (exemplificada na Figura 3) pode-se observar as categorias verdadeiras (coluna: True Group), bem como, as Classificações feitas de acordo com as funções discriminantes (Put into Group). Com isto podemos verificar a proporção de acertos ( $0,952 = 20/21$  no exemplo abaixo).

**Figura 3.** Tabela de Classificação

Summary of classification			
	True Group		
Put into Group	1	2	3
1	6	0	0
2	0	10	0
3	0	1	4
Total N	6	11	4
N correct	6	10	4
Proportion	1,000	0,909	1,000
N = 21	N Correct = 20		

## 6 Regressão Logística

A variável dependente é categórica. Na Regressão Logística Binária são consideradas duas categorias: 0 e 1. O modelo desenvolvido fornece a probabilidade de um caso (empresa, indivíduo, ...) ser classificado na categoria 1.

$$P(Y = 1) = \frac{1}{1 + \exp(-g(x))}, \quad (13)$$

onde, a função  $g(x)$  é obtida na forma:

$$g(x) = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n. \quad (14)$$

Os valores de  $\beta$ 's são dados numa Tabela de coeficientes para regressão logística.

Por exemplo: A tabela 5 fornece os valores de betas para um modelo de regressão logística com 3 variáveis: R, ND e VE, para previsão de inadimplência.

**Tabela 5.** Coeficientes betas para função  $g(x)$

Variáveis	Beta
Constante	1,5
R	-1,9
ND	0,9
VE	2,8

Considere um caso no qual  
 $R = 3$ ,  $ND = 2$  e  $VE = 0$ .

A partir da Tabela 5 e dos valores de cada variável calcula-se o valor de  $g(x)$  dado pela equação (14)

$$g(x) = 1,5 - 1,9 \times 3 + 0,9 \times 2 + 2,8 \times 0 = -2,4$$

Este valor é substituído na expressão (13):

$$P(Y = 1) = \frac{1}{1 + \exp(2,4)} = 0,083$$

O valor obtido é a probabilidade de que o caso seja classificado como 1, ou seja, neste caso a probabilidade de ser inadimplente.

Para obter a previsão de classificação o resultado deve ser arredondado para 0 ou 1.

Neste caso:  $Prev = 0$ .

O percentual de acerto também pode ser obtido a partir de uma tabela de classificação, de forma análoga à análise discriminante na seção 5, anterior.