

## Análise Multivariada

Lupércio França Bessegato  
Dep. Estatística/UFJF

### Roteiro

1. Introdução
2. Distribuições de Probabilidade Multivariadas
3. Representação de Dados Multivariados
4. Testes de Significância c/ Dados Multivariados
5. Análise de Componentes Principais
6. Análise Fatorial
7. Análise de Agrupamentos
8. Análise de Correlação Canônica
9. Referências

Análise Multivariada - 2016

2

## Análise Fatorial

### Análise Fatorial

- Objetivo:
  - ✓ Descrever as relações de covariância entre muitas variáveis em termos de poucas quantidades aleatórias subjacentes e não observáveis
- Motivação:
  - ✓ Variáveis de um grupo altamente correlacionadas entre si, mas com pequenas correlações de outros grupos
  - ✓ É concebível que cada grupo de variáveis represente um fator (ou construto) que seja o responsável pelas correlações observadas

Análise Multivariada - 2016

4

- Análise factorial:

- ✓ Pode ser considerada uma extensão da Análise de Componentes Principais
  - Ambas são tentativas de aproximar S.
  - A aproximação baseada em Análise Fatorial é mais elaborada

- ✓ Questão principal:

- Dados são consistentes com a estrutura prescrita?

Análise Multivariada - 2016

5

- Análise Fatorial Exploratória:

- ✓ Busca encontrar os fatores subjacentes às variáveis originais amostradas
- ✓ Em geral, efetuada quando não se tem noção clara da quantidade de fatores do modelo e nem do que representam

- Análise Fatorial Confirmatória:

- ✓ Tem-se em mãos um modelo fatorial pré-especificado (modelo hipotético) e deseja-se verificar se é aplicável ou consistente com os dados amostrais de que dispõe

Análise Multivariada - 2016

6

## Modelo Fatorial Ortogonal via Matriz de Correlações

- Seja o vetor aleatório

$$\mathbf{X}' = [X_1, X_2, \dots, X_p].$$

com vetor de médias  $\boldsymbol{\mu}$ , matriz de covariâncias é  $\boldsymbol{\Sigma}$ , e matriz de correlações  $\mathbf{P}$ .

- Sejam as variáveis originais padronizadas:

$$Z_i = \frac{X_i - \mu_i}{\sqrt{\sigma_{ii}}}$$

✓  $\mathbf{P}$  é a matriz de covariâncias do vetor aleatório  $\mathbf{Z}$ , cujos componentes são as variáveis padronizadas

Análise Multivariada - 2016

8

- Modelo Fatorial Ortogonal

- ✓ Construído via a matriz de correlação populacional
- ✓ Relaciona linearmente as variáveis padronizadas e os m fatores comuns (que são desconhecidos)
- ✓ Fatores são variáveis independentes

Análise Multivariada - 2016

9

- Equações do modelo:

$$Z_1 = l_{11}F_1 + l_{12}F_2 + \dots + l_{1m}F_m + \epsilon_1$$

$$Z_2 = l_{21}F_1 + l_{22}F_2 + \dots + l_{2m}F_m + \epsilon_2$$

$$\vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots$$

$$Z_p = l_{p1}F_1 + l_{p2}F_2 + \dots + l_{pm}F_m + \epsilon_p$$

✓ Em notação matricial:

$$\mathbf{V}^{-1/2}(\mathbf{X} - \boldsymbol{\mu}) = \mathbf{LF} + \boldsymbol{\epsilon}.$$

$$\mathbf{V}^{-1/2} = \text{diagonal}\left(\frac{1}{\sqrt{\sigma_{11}}}, \frac{1}{\sqrt{\sigma_{22}}}, \dots, \frac{1}{\sqrt{\sigma_{pp}}}\right).$$

$$\mathbf{L}_{p \times m} = \begin{bmatrix} l_{11} & l_{12} & \dots & l_{1m} \\ l_{21} & l_{22} & \dots & l_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ l_{p1} & l_{p2} & \dots & l_{pm} \end{bmatrix}, \quad \mathbf{F}_{m \times 1} = \begin{bmatrix} F_1 \\ F_2 \\ \vdots \\ F_m \end{bmatrix}, \quad \boldsymbol{\epsilon}_{p \times 1} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_p \end{bmatrix}.$$

Análise Multivariada - 2016

10

- Modelo fatorial:

$$\mathbf{V}^{-1/2}(\mathbf{X} - \boldsymbol{\mu}) = \mathbf{LF} + \boldsymbol{\epsilon}.$$

✓ **F**: vetor aleatório contendo m fatores

- Essas variáveis latentes precisam ser identificadas

✓ **ε**: vetor dos erros aleatórios

- Erros de medida e variação de  $Z_i$  que não é explicada pelos fatores comuns

✓ **L**: matriz de loadings fatorais

-  $l_{ij}$ : representa o grau de relacionamento entre  $Z_i$  e  $F_j$ .

✓ O modelo de análise fatorial assume que as variáveis  $Z_i$  estão relacionadas linearmente com os fatores

- Variáveis originais padronizadas são representadas por  $p+m$  variáveis não observáveis

Análise Multivariada - 2016

11

## Modelo de Fatores Ortogonais

- Suposições:

- Todos os fatores tem média zero  $E[\mathbf{F}] = \mathbf{0}$ .
- Todos os fatores são não correlacionados e tem variância um.  $Cov[\mathbf{F}] = \mathbf{I}_m$ .
- Todos os erros tem média igual a zero  $E[\boldsymbol{\epsilon}] = \mathbf{0}$ .
- Erros são não correlacionados entre si e não necessariamente tem a mesma variância

$$\text{Cov}[\boldsymbol{\epsilon}] = \text{diagonal}(\psi_1, \psi_2, \dots, \psi_p), \quad \text{Var}[\epsilon_j] = \psi_j$$

$$\text{Cov}(\epsilon_i, \epsilon_j) = 0, \quad \forall i \neq j.$$

Análise Multivariada - 2016

12

- v. Os vetores **e** e **F** são independentes

$$\text{Cov}(\boldsymbol{\epsilon}_{p \times 1}, \mathbf{F}_{m \times 1}) = E[\boldsymbol{\epsilon}\mathbf{F}'] = \mathbf{0}.$$

✓ **F** e **ε** são duas fontes de variação distintas, relacionadas às variáveis padronizadas  $Z_i$ , não havendo qualquer relacionamento entre estas fontes de informação.

- Assumido o modelo, **P** pode ser reparametrizada

$$\mathbf{P}_{p \times p} = \mathbf{LL}' + \boldsymbol{\Psi}.$$

✓ O objetivo é encontrar as matrizes  $\mathbf{L}_{p \times m}$  e  $\boldsymbol{\Psi}_{p \times p}$  que possam representar a matriz  $\mathbf{P}_{p \times p}$ .

- Há matrizes de correlação que não podem ser decompostas na forma do modelo

Análise Multivariada - 2016

13

- Consequências da decomposição factorial de  $\mathbf{P}$ :

- Variância de  $Z_i$  é decomposta em duas partes:

$$\text{Var}[Z_i] = h_i^2 + \psi_i$$

onde  $h_i^2 = l_{i1}^2 + l_{i2}^2 + \dots + l_{im}^2$ .

- $h_i^2$ : comunalidade

- variabilidade explicada pelos m fatores que é uma fonte comum de variação de  $Z_i$ .

- $\psi_i$ : variância específica

- Parte da variabilidade de  $Z_i$  associada apenas ao erro aleatório

- ✓ Covariâncias entre variáveis e fatores

$$\text{Cov}(Z_i, Z_k) = l_{i1}l_{k1} + l_{i2}l_{k1} + \dots + l_{im}l_{km}, i, k = 1, 2, \dots, p, i \neq k.$$

$$\text{Cov}(Z_i, F_j) = \text{Corr}(Z_i, F_j) = l_{ij}, i = 1, 2, \dots, p \text{ e } j = 1, 2, \dots, m.$$

- ✓ Proporção da variância total explicada pelo fator  $F_j$ :

$$\text{Proporção explicada}_{F_j} = \frac{\sum_{i=1}^p l_{ij}^2}{p}.$$

## Escolha do Número de Fatores $m$

- Critério 1:

- ✓ Análise da proporção de variância total relacionada com cada autovalor
- ✓ Permanecem aqueles autovalores que representam maiores proporções de variância total
- ✓  $m$  = quantidade de autovalores retidos

- Critério 2:

- ✓ Permanecem os autovalores maiores que 1

- ✓  $m$  = quantidade de autovalores retidos

- ✓ Ideia básica do critério:

- Mantem no sistema nas novas dimensões pelo menos a informação da variância de uma variável original

- Critério 3:

- ✓ Observação do gráfico scree plot
- ✓ Valor de m é igual ao número de autovalores anteriores ao ‘ponto de salto’.

- Importante:

- ✓ Uma escolha adequada do valor de m deve levar em consideração a interpretabilidade dos fatores
- ✓ Deve-se observar também o princípio da parcimônia
  - Descrição da estrutura de variabilidade do vetor aleatório  $Z$  com um número pequeno de fatores

Análise Multivariada - 2016

20

- Importante:

- ✓ Modelo factorial ortogonal só pode ser aplicado quando as variáveis originais são correlacionadas entre si
  - Caso contrário, cada fator ficará relacionado com apenas uma variável original

Análise Multivariada - 2016

21

### Métodos de Estimação de $L$ e $\psi$

- Escolhe-se o valor de m
- Métodos de estimação das matrizes  $L$  e  $\psi$ :
  - ✓ Método de componentes principais
    - Em geral, utilizado como um análise exploratória dos dados, em termos dos fatores subjacentes
  - ✓ Método de fatores principais
    - Refinamento do método das componentes principais
  - ✓ Método da máxima verossimilhança
    - Indicado apenas quando  $Z$  tem distribuição normal

Análise Multivariada - 2016

22

### Método das Componentes Principais

- Matrizes  $L$  e  $\psi$  serão estimadas por:

$$\hat{L} = \left[ \sqrt{\hat{\lambda}_1} \hat{e}_1, \sqrt{\hat{\lambda}_2} \hat{e}_2, \dots, \sqrt{\hat{\lambda}_m} \hat{e}_m \right].$$

$$\hat{\psi} = \text{diagonal} \left( R_{p \times p} - \hat{L}_{p \times m} \hat{L}'_{p \times m} \right).$$

- ✓ Aproximação de  $R$

$$R_{p \times p} \approx \hat{L}_{p \times m} \hat{L}'_{p \times m} + \hat{\psi}.$$

Análise Multivariada - 2016

24

- Matriz residual:

$$M_{\text{Res}} = R_{p \times p} - (\hat{L}_{p \times m} \hat{L}'_{p \times m} + \hat{\psi}).$$

- ✓ Pode servir como critério de avaliação do modelo
  - Seus valores deveriam ser próximos de zero
  - Matriz é nula somente quando o valor de m é igual a p
- ✓ Os elementos da diagonal da matriz R são reproduzidos exatamente pela reprodução do modelo
  - O mesmo não ocorre para os outros elementos da matriz R (covariâncias das variáveis Z<sub>i</sub> e Z<sub>j</sub>)

- Método das componentes principais na estimação de LL' e  $\psi$ .

$$\text{Proporção explicada}_{F_j} = \frac{\sum_{i=1}^p l_{ij}^2}{p}.$$

- ✓ Representa o quanto cada fator consegue captar da variabilidade original das variáveis Z<sub>i</sub>.

### Exemplo 9.3 – Preferência de Consumidor

- Amostra aleatória de consumidores pontuando atributos de novo produto:
  - ✓ Respostas em escala semântica de 7 valores
  - ✓  $X_1$ : Gosto
  - ✓  $X_2$ : Preço
  - ✓  $X_3$ : Aroma
  - ✓  $X_4$ : Adequado para lanche
  - ✓  $X_5$ : Fornece muita energia
  - ✓ Dados: BD\_multivariada.xls/preferencia\_consumidor

- Solução por Componentes Principais:

Variável	Loadings Estimados				Comunalidade	$h_j^2$	$\psi_j$
	$e_{1j}$	$t_{1j}$	$e_{2j}$	$t_{2j}$			
Gosto	0,331	0,560	0,607	0,816	$(0,560)^2 + (0,816)^2 =$	$0,979 \cdot 1 - 0,979 =$	0,021
Preço	0,460	0,777	-0,390	-0,524	$(0,777)^2 + (-0,524)^2 =$	$0,879 \cdot 1 - 0,404 =$	0,121
Aroma	0,382	0,645	0,557	0,748	$(0,645)^2 + (0,748)^2 =$	$0,976 \cdot 1 - 0,370 =$	0,024
Adequado lanche	0,556	0,939	-0,078	-0,105	$(0,939)^2 + (-0,105)^2 =$	$0,893 \cdot 1 - 0,493 =$	0,107
Energético	0,473	0,798	-0,404	-0,543	$(0,798)^2 + (-0,543)^2 =$	$0,932 \cdot 1 - 0,493 =$	0,068
Autovalor	2,853		1,806				
	57,1%		93,2%				

- ✓ Em geral, uma rotação pode mostrar uma estrutura simples (interpretação simples)

- Análise Fatorial da Matriz de Correlações:

Factor Analysis: M1		
Principal Component Factor Analysis of the Correlation Matrix		
Unrotated Factor Loadings and Communalities		
Variable	Factor1	Factor2
Var 1	0,560	0,816
Var 2	0,777	-0,524
Var 3	0,645	0,748
Var 4	0,939	-0,305
Var 5	0,798	-0,543
Variance	2,8531	1,8063
% Var	0,571	0,361
		4,6594

$\hat{L}\hat{L}' + \hat{\Psi}$  reproduz aproximadamente R

- Cálculo Comunalidades e Resíduos – Minitab:

```
Let C9 = C6*C6 + C7*C7 # Comunalidades
Let C10 = 1 - C9          # Variancas Específicas
Diagonal C10 M4           # Matriz Psi
Subtract M4 M2 M5 # Matriz de resíduos
Print M5
```

- Matriz de Resíduos:

Data Display					
Matrix M5					
0,0000000	0,0126425	-0,0116968	-0,0201455	0,0064418	
0,0126425	0,0000000	0,0204813	-0,0749273	-0,0551752	
-0,0116968	0,0204813	0,0000000	-0,0275656	0,0011935	
-0,0201455	-0,0749273	-0,0275656	0,0000000	-0,0165955	
0,0064418	-0,0551752	0,0011935	-0,0165955	0,0000000	

#### Exemplo 9.4 – Ações New York

- Taxas de retorno de 5 ações negociadas na Bolsa de New York
  - ✓ Período: jan/75 a Dez/76
    - Observadas 100 semanas
  - ✓ Ações:
    - Allied Chemical
    - du Pont
    - Union Carbide
    - Exxon
    - Texaco
  - ✓ Dados: BD\_multivariada.xls/acoes\_NY

- Vetor de médias amostral ( $\bar{x}$ )

Descriptive Statistics: allied_chemical; du_pont; union_carbide; exxon; texaco	
Variable	Mean
allied_chemical	0,00543
du_pont	0,00483
union_carbide	0,00565
exxon	0,00629
texaco	0,00371

- Matriz de correlações amostral (S)

Correlations: allied_chemical; du_pont; union_carbide; exxon; texaco				
	allied_chemical	du_pont	union_carbide	exxon
du_pont		0,577		
union_carbide		0,509	0,598	
exxon		0,387	0,390	0,436
texaco		0,462	0,322	0,426
				0,524

- Análise Fatorial - Solução por Componentes Principais  
 $\sqrt{m} = 1$


Factor Analysis: allied_chemical; du_pont union_carbide; exxon; texaco		
Principal Component Factor Analysis of the Correlation Matrix		
Unrotated Factor Loadings and Communalities		
Variable	Factor1	Community
allied_chemical	0,783	0,614
du_pont	0,773	0,597
union_carbide	0,794	0,631
exxon	0,713	0,508
texaco	0,712	0,507
Variance	2,8565	2,8565
% Var	0,571	0,571

Principal Component Factor Analysis of the Correlation Matrix			
Unrotated Factor Loadings and Communalities			
Variable	Factor1	Factor2	Community
allied_chemical	0,783	0,217	0,661
du_pont	0,773	0,458	0,806
union_carbide	0,794	0,234	0,686
exxon	0,713	-0,472	0,731
texaco	0,712	-0,524	0,781
Variance	2,8565	0,8091	3,6656
% Var	0,571	0,162	0,733

$\sqrt{m} = 2$

- Scores dos fatores
- Plot dos fatores



Análise Multivariada - 2016

36

- Comparação soluções:

Variável	Fatores Comuns				Solução			
	$e_{11}$	$I_{11}$	$e_{12}$	$I_{22}$	$h_j^2$	$\Psi_j$	$h_j^2$	$\Psi'_j$
Allied Chemical	0,464	0,783	0,241	0,217	0,615	0,385	0,661	0,339
Du Pont	0,457	0,773	0,509	0,458	0,596	0,404	0,806	0,194
Union Carbide	0,470	0,794	0,261	0,234	0,630	0,370	0,685	0,315
Exxon	0,422	0,713	-0,525	-0,472	0,507	0,493	0,731	0,269
Texaco	0,421	0,712	-0,582	-0,524	0,507	0,493	0,780	0,220
Autovalor	2,856		0,809		57,1%		73,3%	

$\sqrt{ }$  Componentes obtidos a partir de R

$\sqrt{ }$  % acumulada da solução a dois fatores é bem maior que a da solução a um fator

Análise Multivariada - 2016

37

- Matriz de Correlações

Correlation					
1,00000	0,57692	0,50866	0,38672	0,46218	
0,57692	1,00000	0,59838	0,38692	0,32195	
0,50866	0,59838	1,00000	0,43610	0,42563	
0,38672	0,38952	0,43610	1,00000	0,52353	
0,46218	0,32195	0,42563	0,52353	1,00000	

- Matriz de Resíduos:  $R - \hat{L}\hat{L}' - \hat{\Psi}$

$\sqrt{ } m = 1$

0	-0,028	-0,114	-0,172	-0,096
-0,028	0	-0,015	-0,161	-0,228
-0,114	-0,015	0	-0,130	-0,140
-0,172	-0,161	-0,130	0	0,016
-0,096	-0,228	-0,140	0,016	0

$\sqrt{ } m = 2$

0	-0,128	-0,164	-0,069	0,018
-0,128	0	-0,123	0,055	0,012
-0,164	-0,123	0	-0,019	0,017
-0,069	0,055	-0,019	0	-0,231
0,018	0,012	-0,017	-0,231	0

$\sqrt{ }$  Para  $m=2$   $LL'$  produz números maiores (principalmente  $r_{45}$ )

Análise Multivariada - 2016

38

- Interpretação:

Principal Component Factor Analysis of the Correlation Matrix			
Variable	Factor1	Factor2	Communality
allied_chemical	0,783	0,217	0,661
du_pont	0,773	0,458	0,806
union_carbide	0,794	0,234	0,686
exxon	0,713	-0,472	0,731
texaco	0,712	-0,524	0,781
Variance	2,8565	0,8091	3,6656
% Var	0,571	0,162	0,733

✓  $F_1$ : fator de mercado

(condições econômicas gerais)

✓  $F_2$ : fator industrial

– contrasta ações de indústrias químicas e de óleo e gás  
(diferencia setores)

- Em essência, mesma conclusão de ACP (ex. 8.5)<sup>39</sup>

Análise Multivariada - 2016

39

## Método do Fatores Principais

- Também chamado Método de Componentes Principais Iterativo

- Idéia básica:

✓ Refinar as estimativas de  $\mathbf{L}_{pxm}$  e  $\boldsymbol{\Psi}_{pxp}$ .

Análise Multivariada - 2016

41

- Procedimento

- ✓ Estimativas iniciais pelo método das componentes principais
- ✓ Troca dos elementos da diagonal de  $\mathbf{R}$  pelas comunalidades estimadas
- ✓ Novas estimações a partir da matriz  $\mathbf{R}^*$
- ✓ Substituição dos elementos da diagonal principal pelas comunalidades estimadas
- ✓ Procedimento é repetido até que as diferenças entre as comunalidades estimadas sejam desprezíveis

Análise Multivariada - 2016

42

## Método da Máxima Verossimilhança

- Só pode ser utilizado quando a forma da distribuição de probabilidades é conhecida

- Suposição:

✓ Vetor aleatório  $\mathbf{X}$  tem distribuição normal p-variada

✓ Consequência:

- Vetor das variáveis padronizadas é normal p-variado
- Fatores tem distribuição normal multivariada com vetor de médias zero e matriz de covariâncias  $\mathbf{I}_m$
- Erros tem distribuição normal p-variada com vetor de médias zero e matriz de covariâncias  $\boldsymbol{\Psi}$ .

Análise Multivariada - 2016

43

- A função de verossimilhança é expressa como:

$$L(\mathbf{0}, \mathbf{P}) = \frac{1}{(2\pi)^{np/2} |\mathbf{LL}' + \boldsymbol{\psi}|^{n/2}} \exp \left\{ -\frac{1}{2} \sum_{j=1}^n \mathbf{z}_j' (\mathbf{LL}' + \boldsymbol{\psi})^{-1} \mathbf{z}_j \right\}.$$

- ✓ A função de verossimilhança depende da matrizes  $\mathbf{L}$  e  $\boldsymbol{\psi}$ , através da matriz de correlação  $\mathbf{P}$ .
- ✓ As estimativas de máxima verossimilhança de  $\hat{\mathbf{L}}$  e  $\hat{\boldsymbol{\psi}}$  são as matrizes  $\mathbf{L}$  e  $\boldsymbol{\psi}$  que maximizam a função de verossimilhança.
- ✓ Maximização é feita por métodos numéricos
- ✓ Método mais sofisticado que os métodos de componentes e fatores principais
  - Produz estimativas mais precisas

Análise Multivariada - 2016

45

- Cuidados:

- ✓ Está fundamentado na suposição de normalidade multivariada dos vetores  $\mathbf{Z}$ ,  $\mathbf{F}$  e  $\boldsymbol{\epsilon}$ .
  - Apenas a normalidade do vetor  $\mathbf{Z}$  pode ser investigada a priori a partir dos dados amostrais
  - Fatores e erros são variáveis aleatórias não observáveis

Análise Multivariada - 2016

46

- Valor de m:

- ✓ Método de máxima verossimilhança
  - Mudança de valor de m altera as estimativas dos loadings
- ✓ Método de componentes principais
  - Aumento no valor de m não altera os loadings para os fatores obtidos anteriormente
- ✓ Quando os dados provêm de distribuição normal multivariada
  - Usar método de componentes principais como análise exploratória dos fatores e estimação do valor provável de m
  - Posteriormente, qualidade da solução inicial poderá ser melhorada pelo uso do método de máxima verossimilhança

Análise Multivariada - 2016

47

- Dados omissos:

- ✓ São considerados apenas os elementos amostrais com observações completas
  - (Análise de componentes principais e análise factorial)
- ✓ Caso haja muitas observações com dados omissos em algumas variáveis, deve-se avaliar até que ponto as análises são válidas.

Análise Multivariada - 2016

48

### Exemplo 9.4 – Ações New York

#### Solução Máxima Verossimilhança

- Taxas de retorno de 5 ações negociadas na Bolsa de New York

✓ Período: jan/75 a Dez/76

– Observadas 100 semanas

✓ Ações:

- Allied Chemical
- du Pont
- Union Carbide
- Exxon
- Texaco

✓ Dados: BD\_multivariada.xls/acoes\_NY

Análise Multivariada - 2016

49

Variável	Máxima Verossimilhança				Componentes Principais			
	$l_1$	$l_2$	$h_i^2$	$\varphi_i$	$l_1$	$l_2$	$h_i^2$	$\varphi_i$
Allied Chemical	0,687	-0,176	0,503	0,497	0,783	0,217	0,661	0,339
Du Pont	0,704	-0,506	0,751	0,249	0,773	0,458	0,806	0,194
Union Carbide	0,685	-0,234	0,525	0,475	0,794	0,234	0,685	0,315
Exxon	0,620	0,086	0,392	0,608	0,713	-0,472	0,731	0,269
Texaco	0,782	0,452	0,816	0,184	0,712	-0,524	0,780	0,220
Variância	2,434	0,554	2,988		2,856	0,809	3,663	
% Variância Total	48,7%	11,1%	59,8%		57,1%	16,2%	73,3%	

✓ Proporção da variância total amostral padronizada explicada é maior para a fatoração por componentes principais que por máxima verossimilhança

– Componentes principais têm a propriedade de otimizar a variância

✓  $F_1$ : loadings positivos e grandes

– não tanto quanto por componentes principais

✓  $F_2$ : sinais consistentes com contraste, mas magnitudes em alguns casos são menores

– comparação entre Du Pont e Texaco

Análise Multivariada - 2016

51

✓ Solução por Máxima Verossimilhança

Factor Analysis: allied_chemical; du_pont; union_carbide; exxon; texaco			
Maximum Likelihood Factor Analysis of the Correlation Matrix			
Unrotated Factor Loadings and Communalities			
Variable	Factor1	Factor2	Communality
allied_chemical	0,687	-0,176	0,503
du_pont	0,704	-0,506	0,751
union_carbide	0,685	-0,234	0,525
exxon	0,620	0,086	0,392
texaco	0,782	0,452	0,816
Variance	2,4338	0,5538	2,9876
% Var	0,487	0,111	0,598

✓ Solução por Componentes Principais

Principal Component Factor Analysis of the Correlation Matrix			
Unrotated Factor Loadings and Communalities			
Variable	Factor1	Factor2	Communality
allied_chemical	0,783	0,217	0,661
du_pont	0,773	0,458	0,806
union_carbide	0,794	0,234	0,686
exxon	0,713	-0,472	0,731
texaco	0,712	-0,524	0,781
Variance	2,8565	0,8091	3,6656
% Var	0,571	0,162	0,733

50

• Matriz de Resíduos:  $R - \hat{L}\hat{L}' - \hat{\Psi}$

✓ Máxima Verossimilhança

m=2	0	-0,004	0,004	0,024	-0,004
0	-0,004	0	0,003	0,004	0,000
0,004	0,003	0	-0,031	0,005	
0,024	0,004	-0,031	0	0,000	
-0,004	0,000	0,005	0,000	0	

✓ Componentes Principais

0	-0,128	-0,164	-0,069	0,018
-0,128	0	-0,123	0,055	0,012
-0,164	-0,123	0	-0,019	-0,017
-0,069	0,055	-0,019	0	-0,231
0,018	0,012	-0,017	-0,231	0

✓ Elementos da matriz de resíduos são bem menores que aqueles obtidos pela análise fatorial por componentes principais

✓ Escolha:

– Solução por máxima verossimilhança

Análise Multivariada - 2016

52

- Importante:
  - ✓ Os padrões dos *loadings* fatoriais iniciais estão restritos pela condição de unicidade da estimativa de  $\hat{L}' \hat{\Psi} \hat{L} = \Delta$
  - ✓ Padrões fatoriais úteis frequentemente não são revelados até que os fatores sejam rotacionados

Análise Multivariada - 2016

54

### Exemplo 9.6 – Decatlo Olímpico

- Estudo de escores olímpicos de decatlo (Linden, 1977)
  - ✓ 160 observações multivariadas (139 atletas)
  - ✓ Período: 1948 a 1976
  - ✓ Escores padronizados para cada um dos 10 eventos
  - ✓ Análise Fatorial de R por componentes principais e por máxima verossimilhança
  - ✓ Dados: *BD\_multivariada.xls/decatlo*

Análise Multivariada - 2016

55

- ✓ A distribuição dos scores padronizados são normais ou aproximadamente normais para cada um dos 10 eventos (Linden, 1977)
- ✓ Variáveis:
  - $X_1$ : 100 m rasos
  - $X_2$ : Salto em distância
  - $X_3$ : Arremesso de peso
  - $X_4$ : Salto em altura
  - $X_5$ : 400 m rasos
  - $X_6$ : 100 m com barreiras
  - $X_7$ : Lançamento de disco
  - $X_8$ : Salto com vara
  - $X_9$ : Lançamento de dardo
  - $X_{10}$ : 1.500 m

Análise Multivariada - 2016

56

- Matriz de Correlações

Matrix M1										
1,00	0,59	0,35	0,34	0,63	0,40	0,28	0,20	0,11	-0,07	
0,59	1,00	0,42	0,51	0,49	0,52	0,31	0,36	0,21	0,09	
0,35	0,42	1,00	0,38	0,19	0,36	0,73	0,24	0,44	-0,08	
0,34	0,51	0,38	1,00	0,29	0,46	0,27	0,39	0,17	0,18	
0,49	0,19	0,29	0,08	1,00	0,34	0,17	0,23	0,18	0,35	
0,40	0,27	0,50	0,34	0,20	1,00	0,22	0,33	0,23	0,00	
0,28	0,31	0,73	0,27	0,17	0,32	1,00	0,24	0,34	-0,02	
0,20	0,36	0,24	0,39	0,23	0,33	0,24	1,00	0,24	0,17	
0,11	0,21	0,44	0,17	0,13	0,18	0,34	0,24	1,00	0,00	
-0,07	0,09	-0,08	0,18	0,39	0,00	-0,02	0,17	0,00	1,00	

- ✓ Há correlação potencial entre scores sucessivos de atletas que concluíram a prova em mais de uma Olimpíada
  - Efetuado análise usando 139 escores representativo de cada atleta
  - Escolheu-se aleatoriamente um dos escores dos atletas que participaram de mais de uma Olimpíada

Análise Multivariada - 2016

57

## ✓ Solução por Componentes Principais

Factor Analysis: M1

Principal Component Factor Analysis of the Correlation Matrix

Unrotated Factor Loadings and Communalities

Variable	Factor1	Factor2	Factor3	Factor4	Community
Var 1	0,661	-0,117	0,520	-0,206	0,837
Var 2	0,464	0,189	0,192	0,921	0,701
Var 3	0,702	0,595	-0,047	-0,175	0,811
Var 4	0,674	-0,194	0,199	0,296	0,648
Var 5	0,657	-0,191	0,194	0,296	0,570
Var 6	0,687	-0,042	0,161	0,245	0,618
Var 7	0,621	0,521	-0,103	-0,234	0,724
Var 8	0,593	-0,057	-0,411	0,440	0,660
Var 9	0,484	0,469	-0,272	-0,223	0,574
Var 10	0,147	-0,596	-0,450	-0,279	0,588

Variance 3,7662 1,6173 1,1146 0,9124 7,9217

% Var 37,9% 16,2% 11,1% 9,1% 60,4%

100 m rasos 0,691 -0,217 0,520 -0,206 0,837 0,163 0,498 -0,225 0,700 0,179 0,816 0,184

Salto em distância 0,789 -0,184 0,193 0,092 0,701 0,299 0,464 -0,381 0,455 -0,240 0,825 0,375

Arremesso de peso 0,702 0,535 -0,047 -0,175 0,811 0,189 0,876 -0,334 -0,235 0,040 0,956 0,064

Salto em altura 0,674 -0,134 -0,139 0,396 0,648 0,552 0,348 -0,407 0,204 -0,437 0,519 0,481

400 m rasos 0,620 -0,551 0,084 -0,419 0,870 0,130 0,144 -0,563 0,551 0,166 0,699 0,331

100 m barreiras 0,687 -0,042 0,161 0,345 0,618 0,382 0,418 -0,247 0,307 -0,345 0,449 0,551

Lançamento disco 0,621 0,521 -0,109 -0,234 0,724 0,276 0,666 -0,301 -0,182 0,041 0,569 0,431

Salto com vara 0,538 -0,087 -0,411 0,440 0,660 0,340 0,211 -0,323 0,127 -0,360 0,294 0,706

Lançamento dardo 0,434 0,439 -0,373 -0,235 0,574 0,426 0,392 -0,194 -0,138 -0,058 0,214 0,786

1500 m 0,147 -0,596 -0,658 -0,279 0,888 0,112 -0,440 -0,864 -0,070 0,016 0,946 0,054

Variancia 3,787 1,517 1,114 0,913 7,932 2,379 1,850 1,265 0,564 6,037

% Variância Total 37,9% 15,2% 11,1% 9,1% 73,3% 23,8% 18,3% 12,6% 5,6% 60,4%

Análise Multivariada - 2016

58

## ✓ Solução por Máxima Verossimilhança

Maximum Likelihood Factor Analysis of the Correlation Matrix

Unrotated Factor Loadings and Communalities

Variable	Factor1	Factor2	Factor3	Factor4	Community
Var 1	0,493	-0,125	0,700	0,179	0,816
Var 2	0,464	-0,381	0,455	-0,240	0,625
Var 3	0,876	-0,334	-0,235	0,040	0,936
Var 4	0,348	-0,407	0,204	-0,437	0,519
Var 5	0,144	-0,563	0,551	0,166	0,669
Var 6	0,418	-0,247	0,307	-0,345	0,449
Var 7	0,677	-0,402	0,212	0,161	0,659
Var 8	0,211	-0,322	0,127	-0,360	0,294
Var 9	0,392	-0,194	-0,138	-0,058	0,214
Var 10	-0,440	-0,864	-0,070	0,016	0,946

Variance 2,3788 1,8296 1,2648 0,5643 6,0374

% Var 23,8% 18,3% 12,6% 5,6% 60,4%

Análise Multivariada - 2016

59

- As soluções dos dois métodos são bem diferentes

Análise Multivariada - 2016

59

## ✓ Solução por Componentes Principais

Factor Analysis: M1

Principal Component Factor Analysis of the Correlation Matrix

Unrotated Factor Loadings and Communalities

Variable	Factor1	Factor2	Factor3	Factor4	Community
Var 1	0,691	-0,217	0,520	-0,206	0,837
Var 2	0,789	-0,184	0,193	0,092	0,701
Var 3	0,702	0,595	-0,047	-0,175	0,811
Var 4	0,674	-0,194	0,199	0,296	0,648
Var 5	0,657	-0,191	0,194	0,296	0,570
Var 6	0,687	-0,042	0,161	0,245	0,618
Var 7	0,621	0,521	-0,103	-0,234	0,724
Var 8	0,593	-0,057	-0,411	0,440	0,660
Var 9	0,484	0,469	-0,272	-0,223	0,574
Var 10	0,147	-0,596	-0,450	-0,279	0,588

- F<sub>1</sub>: Todos os loadings positivos e grandes (exceto X<sub>10</sub>)

Habilidade atlética geral

- F<sub>2</sub>: Contraste entre habilidade de corrida e de arremesso- F<sub>3</sub>: Contraste resistência (1500 m) com velocidade (100 m)

▪ Embora haja loading relativamente alto para salto com vara

- F<sub>4</sub>: É um mistério neste ponto

Análise Multivariada - 2016

60

## ✓ Solução por Máxima Verossimilhança

Maximum Likelihood Factor Analysis of the Correlation Matrix

Unrotated Factor Loadings and Communalities

Variable	Factor1	Factor2	Factor3	Factor4	Community
Var 1	0,493	-0,125	0,700	0,179	0,816
Var 2	0,464	-0,381	0,455	-0,240	0,625
Var 3	0,876	-0,334	-0,235	0,040	0,936
Var 4	0,348	-0,407	0,204	-0,437	0,519
Var 5	0,144	-0,563	0,551	0,166	0,669
Var 6	0,418	-0,247	0,307	-0,345	0,449
Var 7	0,666	-0,301	-0,182	0,041	0,569
Var 8	0,211	-0,322	0,127	-0,360	0,294
Var 9	0,392	-0,194	-0,138	-0,058	0,214
Var 10	-0,440	-0,864	-0,070	0,016	0,946

- F<sub>1</sub>: Loadings de arremesso de disco e de peso são altos

Fator de força

- F<sub>2</sub>: Corrida 1500 m única variável com loading alto

Fator resistência

- F<sub>3</sub>: Loadings de corrida 100 e 400 m são altos

Fator velocidade

- F<sub>4</sub>: Não é facilmente identificável

(pode ter algo com habilidade de salto e força nas pernas)

Análise Multivariada - 2016

62

- Matriz de Resíduos:  $R - \hat{L}\hat{L}' - \hat{\Psi}$

✓ Componentes Principais

Componentes Principais										
0	-0,075	-0,090	-0,001	-0,047	-0,095	-0,027	0,114	0,051	-0,016	
-0,075	0	-0,010	-0,056	-0,077	-0,092	-0,041	-0,042	0,042	0,017	
-0,030	-0,010	0	0,042	-0,020	-0,032	-0,031	-0,034	-0,158	0,056	
-0,001	-0,056	0,042	0	-0,024	-0,122	-0,001	-0,215	-0,022	0,020	
-0,047	-0,077	-0,020	-0,024	0	0,022	-0,017	0,067	0,036	-0,091	
-0,096	-0,092	-0,052	-0,122	0,022	0	0,014	-0,129	0,041	0,076	
-0,027	-0,041	-0,031	-0,001	-0,017	0,014	0	0,009	-0,254	0,062	
0,114	-0,042	-0,034	-0,215	0,067	-0,129	0,009	0	-0,008	-0,109	
0,051	0,042	-0,158	-0,022	0,036	0,041	-0,254	-0,005	0	-0,112	
-0,016	0,017	0,056	0,020	-0,091	0,076	0,062	-0,109	-0,112	0	

✓ Máxima Verossimilhança

Máxima Verossimilhança										
0	0,001	0,000	0,013	0,017	-0,014	0,004	-0,001	-0,020	-0,001	
0,001	0	0,002	-0,004	-0,002	0,009	-0,021	-0,005	0,003	0,000	
0,000	0,002	0	0,005	-0,002	-0,004	0,001	-0,008	0,001	0,000	
0,013	-0,004	0,005	0	-0,029	0,001	-0,029	0,002	-0,042	0,002	
0,017	-0,002	-0,002	-0,029	0	0,029	-0,003	0,008	0,050	0,003	
-0,014	0,009	-0,004	0,001	0,029	0	0,037	-0,001	-0,010	-0,002	
0,004	-0,021	0,001	-0,009	-0,002	0,037	0	0,041	-0,003	0,001	
-0,001	-0,005	-0,008	0,002	0,008	-0,001	0,041	0	0,092	-0,001	
-0,020	0,003	0,001	-0,042	0,050	-0,010	-0,003	0,092	0	-0,004	
-0,001	0,000	0,000	0,002	0,003	-0,002	0,001	-0,001	-0,004	0	

Análise Multivariada - 2016

63

## Rotação dos Fatores

- A matriz de covariância  $\Sigma$  é reproduzida pelos loadings fatoriais obtidos por transformação ortogonal, da mesma maneira que os loadings iniciais.

✓ Matriz de covariâncias estimada

$$\hat{L}\hat{L}' + \hat{\Psi} = \hat{L}\hat{T}\hat{T}'\hat{L}' + \hat{\Psi} = \hat{L}^*\hat{L}' + \hat{\Psi}$$

✓  $\hat{T}\hat{T}' = T'T = I$

✓  $\hat{L}^*$ : matriz de loadings rotacionados

✓ A matriz de resíduos permanece a mesma ( $\hat{h}_i^2$  e  $\hat{\Psi}_i$ )

$$S_n - \hat{L}\hat{L}' - \hat{\Psi} = S_n - \hat{L}^*\hat{L}' - \hat{\Psi}$$

✓ Do ponto de vista estatístico é irrelevante obter  $\hat{L}$  ou  $\hat{L}^*$

Análise Multivariada - 2016

64

- Comentários:

- ✓ Com a rotação, busca-se uma estrutura mais simples
  - loadings originais podem não ter fácil interpretação
- ✓ Ideal: encontrar um padrão de loadings tais que cada variável carregue-se fortemente em um único fator (com loadings moderados nos outros fatores)
- ✓ Nem sempre é possível obter esta estrutura mais simples

Análise Multivariada - 2016

65

## Exemplo 9.8 – Examination Scores

✓ Lawley & Maxwell (1971)

✓ Avaliações de 220 estudantes do sexo masculino

✓  $p = 6$

✓ Dados: BD\_multivariada.xls/examination

✓ Matriz de correlações:

Gaélico	1	0,439	0,410	0,288	0,329	0,248
Inglês	0,439	1	0,351	0,354	0,320	0,329
História	0,410	0,351	1	0,164	0,190	0,181
Aritmética	0,288	0,354	0,164	1	0,595	0,470
Álgebra	0,329	0,320	0,190	0,595	1	0,464
Geometria	0,248	0,329	0,181	0,470	0,464	1

Análise Multivariada - 2016

66

- Solução por Máxima Verossimilhança:


Factor Analysis: M1			
Maximum Likelihood Factor Analysis of the Correlation Matrix			
Unrotated Factor Loadings and Communalities			
Variable	Factor1	Factor2	Communality
Var 1	0,553	0,428	0,490
Var 2	0,568	0,288	0,406
Var 3	0,392	0,450	0,356
Var 4	0,740	-0,272	0,622
Var 5	0,724	-0,212	0,569
Var 6	0,595	-0,132	0,372
Variance	2,095	0,6056	2,8151
% Var	0,368	0,101	0,469

- ✓  $F_1$ : reflete a resposta global dos estudantes à instrução fator de inteligência geral
- ✓  $F_2$ : não é facilmente identificável
  - Fator “Math – nonmath”
  - metade positiva, metade negativa (fator bipolar)

Análise Multivariada - 2016

67

- Plot dos loadings fatoriais:



- ✓ Todos os pontos caem no primeiro quadrante
- ✓ Revelam-se mais claramente 2 clusters das variáveis

Análise Multivariada - 2016

68

- Rotação horária de  $20^\circ$ :  $T = \begin{bmatrix} \cos \phi & \sin \phi \\ -\sin \phi & \cos \phi \end{bmatrix} = \begin{bmatrix} 0,9397 & 0,3420 \\ -0,3420 & 0,9397 \end{bmatrix}$
- Rotação dos loadings:

Unrotated Factor Loadings and Communalities			
Variable	Factor1	Factor2	Communality
Var 1	0,373	0,594	0,490
Var 2	0,435	0,467	0,406
Var 3	0,214	0,558	0,356
Var 4	0,789	0,001	0,622
Var 5	0,752	0,054	0,569
Var 6	0,604	0,083	0,372
Variance	1,9295	0,8856	2,8151
% Var	0,322	0,148	0,469

- ✓  $F_1^*$ : variáveis matemáticas do teste com loading alto
  - (desprezíveis em  $F_2^*$ )
  - Fator de habilidade matemática
- ✓  $F_2^*$ : variáveis de habilidade verbal com loadings altos
  - Fator de habilidade verbal

Análise Multivariada - 2016

69

- Comentários:

- ✓ O fator de inteligência geral está submerso dos fatores  $F_1^*$  e  $F_2^*$ .
- ✓ As comunalidades não se modificam  
(fatores com e sem rotação)

Análise Multivariada - 2016

70

## Critérios de Rotação

- Ideal:
  - ✓ Transformação que fizesse os loadings de cada  $Z_i$  ter valor grande em apenas um dos fatores e valores pequenos (ou moderados) nos outros
    - Para facilitar a interpretação dos fatores
- Alguns critérios para encontrar matriz ortogonal:
  - ✓ Varimax
  - ✓ Quartimax
  - ✓ Orthomax

Análise Multivariada - 2016

71

## Qualidade de ajuste

- ✓ A rotação não acrescenta nenhuma melhoria em relação ao ajuste original
  - Matriz residual original não é alterada pela transformação ortogonal
  - Valores estimados de communalidade e variâncias específicas permanecem inalterados

## Interpretação:

- ✓ Novos fatores podem ser de mais fácil interpretação
- Quando a solução sem rotação já é de boa qualidade, não se recomenda rotação
  - ✓ Solução rotacionada pode ser pior

Análise Multivariada - 2016

72

- Critério Varimax:
  - ✓ É um dos mais utilizados
  - ✓ Em geral, produz soluções mais simples
- Critério Quartimax
  - ✓ Tem tendência de gerar fatores, onde todas as variáveis têm loadings elevados
- Critério Orthomax
  - ✓ É uma média ponderada dos dois outros métodos

Análise Multivariada - 2016

76

## Exemplo 9.9 – Preferência Consumidor


- (continuação exemplo 9.3)
  - ✓  $X_1$ : Gosto
  - ✓  $X_2$ : Preço
  - ✓  $X_3$ : Aroma
  - ✓  $X_4$ : Adequado para lanche
  - ✓  $X_5$ : fornece muita energia
  - ✓ Dados: *BD\_multivariada.xls/preferencia\_consumidor*

Análise Multivariada - 2016

77

- Solução por Componentes Principais:

Principal Component Analysis of tb			
Unrotated Factor Loadings and Communality			
Variable	Factor1	Factor2	Communality
Var 1	0,560	0,816	0,979
Var 2	0,777	-0,524	0,879
Var 3	0,645	0,748	0,976
Var 4	0,939	-0,105	0,893
Var 5	0,798	-0,543	0,932
Variance	2,8531	1,8063	4,6594
% Var	57,1%	36,1%	93,2%



Análise Multivariada - 2016

78

- Rotação Varimax:

Rotated Factor Loadings and Communalities Varimax Rotation			
Variable	Factor1	Factor2	Communality
Var 1	0,020	0,989	0,979
Var 2	0,937	-0,011	0,879
Var 3	0,129	0,979	0,976
Var 4	0,842	0,428	0,893
Var 5	0,965	-0,016	0,932
Variance	2,5374	2,1220	4,6594
% Var	50,7	42,4%	93,2%

✓  $F_1^*$ : Fator nutricional

Variável 4 está mais alinhada com  $F_1^*$

✓  $F_2^*$ : Fator sabor

Análise Multivariada - 2016

79

- Comparação

Variável	Loadings Estimados				
	Originais		Rotação		
	$L_{11}$	$L_{21}$	$L_{12}$	$L_{22}$	$h_i^2$
Gosto	0,560	0,816	0,020	0,989481	0,979
Preço	0,777	-0,524	0,937	-0,01123	0,879
Aroma	0,645	0,748	0,129	0,979467	0,976
Adequado lanche	0,939	-0,105	0,842	0,428052	0,893
Energético	0,798	-0,543	0,965	-0,01563	0,932
Variância	2,853	1,806	2,537	2,122	4,6594
% variabilidade	57,1%	36,1%	50,7%	42,4%	93,2%

Análise Multivariada - 2016

80

## Exemplo 9.10 – Ações New York Rotação

Continuação Exemplo 9.4

- Taxas de retorno de 5 ações negociadas na Bolsa de New York

✓ Período: jan/75 a Dez/76

– Observadas 100 semanas

✓ Ações:

- Allied Chemical
- du Pont
- Union Carbide
- Exxon
- Texaco


Análise Multivariada - 2016

81

✓ Solução por Máxima Verossimilhança

Factor Analysis: allied_chemical; du_pont; union_carbide; exxon; texaco				
Maximum Likelihood Factor Analysis of the Correlation Matrix				
Unrotated Factor Loadings and Communalities				
Variable	Factor1	Factor2	Communality	
allied_chemical	0,687	-0,176	0,503	
du_pont	0,704	-0,506	0,751	
union_carbide	0,685	-0,234	0,525	
exxon	0,620	0,086	0,392	
texaco	0,782	0,452	0,816	
Variance	2,4338	0,5538	2,9876	
% Var	0,487	0,111	0,598	

✓ Plot dos loadings:



Análise Multivariada - 2016

• Rotação Varimax:

Rotated Factor Loadings and Communalities			
Varimax Rotation			
Variable	Factor1	Factor2	Community
allied_chemical	0,600	0,379	0,503
du_pont	0,851	0,164	0,751
union_carbide	0,641	0,338	0,525
exxon	0,363	0,510	0,392
texaco	0,208	0,879	0,816

• Matriz de Resíduos:

m=2				
0	-0,004	0,004	0,024	-0,004
-0,004	0	0,003	0,004	0,000
0,004	0,003	0	-0,031	0,005
0,024	0,004	-0,031	0	0,000
-0,004	0,000	0,005	0,000	0

Análise Multivariada - 2016

83

Variável	Loadings Estimados				
	Originais		Rotação		
	$L_1$	$L_2$	$L_1$	$L_2$	$h^2$
Allied Chemical	0,687	-0,176	0,600	0,379	0,503
Du Pont	0,704	-0,506	0,851	0,164	0,751
Union Carbide	0,685	-0,234	0,641	0,338	0,525
Exxon	0,620	0,086	0,363	0,510	0,392
Texaco	0,782	0,452	0,208	0,879	0,816
Variância	2,434	0,554	1,670	1,318	2,988
% variabilidade	48,7%	11,1%	33,4%	26,4%	59,8%

✓  $F_1^*$ : Indústrias químicas carregam fortemente

- Representam condições econômicas que afetam essas ações

✓  $F_2^*$ : Ações de óleo & gás carregam fortemente

- Representam condições econômicas que afetam essas ações

✓ Rotação tende a destruir um fator geral

Análise Multivariada - 2016

85

### Exemplo 9.11 – Decatlo Olímpico

• Continuação exemplo 9.6

✓ 160 observações multivariadas (139 atletas)

✓ Período: 1948 a 1976

✓ Escores padronizados para cada um dos 10 eventos

✓ Análise Fatorial de R por componentes principais e por máxima verossimilhança

✓ Dados: BD\_multivariada.xls/decatlo

Análise Multivariada - 2016

86

✓ A distribuição dos scores padronizados são normais ou aproximadamente normais para cada um dos 10 eventos (Linden, 1977)

✓ Variáveis:

X<sub>1</sub>: 100 m rasos

X<sub>2</sub>: Salto em distância

X<sub>3</sub>: Arremesso de peso

X<sub>4</sub>: Salto em altura

X<sub>5</sub>: 400 m rasos

X<sub>6</sub>: 100 m com barreiras

X<sub>7</sub>: Lançamento de disco

X<sub>8</sub>: Salto com vara

X<sub>9</sub>: Lançamento de dardo

X<sub>10</sub>: 1.500 m

Análise Multivariada - 2016

87

✓ Solução por Componentes Principais

Factor Analysis: M1					
Principal Component Factor Analysis of the Correlation Matrix					
Unrotated Factor Loadings and Communalities					
Variable	Factor1	Factor2	Factor3	Factor4	Communality
Var 1	0,691	-0,217	0,920	-0,206	0,897
Var 2	0,785	-0,184	0,182	0,082	0,701
Var 3	0,652	0,184	-0,179	-0,275	0,612
Var 4	0,674	-0,194	-0,189	0,396	0,646
Var 5	0,620	-0,081	0,084	0,419	0,870
Var 6	0,651	-0,142	0,142	0,346	0,728
Var 7	0,521	0,821	-0,189	-0,234	0,794
Var 8	0,551	-0,087	-0,411	0,440	0,860
Var 9	0,494	0,449	-0,272	-0,228	0,874
Var 10	0,147	-0,396	-0,688	-0,279	0,888
Variance	0,7866	1,8179	1,1144	0,9194	7,3317
% Var	0,979	0,182	0,111	0,091	0,782

✓ Solução por Máxima Verossimilhança

Maximum Likelihood Factor Analysis of the Correlation Matrix					
Unrotated Factor Loadings and Communalities					
Variables Factor1 Factor2 Factor3 Factor4 Communality					
Var 1	0,493	-0,225	0,700	0,179	0,816
Var 2	0,464	-0,381	0,455	-0,240	0,625
Var 3	0,575	-0,407	0,101	0,110	0,686
Var 4	0,345	-0,407	0,204	-0,437	0,519
Var 5	0,144	-0,563	0,551	0,166	0,669
Var 6	0,418	-0,247	0,307	-0,345	0,449
Var 7	0,666	-0,301	-0,182	0,041	0,569
Var 8	0,211	-0,322	0,171	-0,360	0,294
Var 9	0,592	-0,712	-0,138	-0,088	0,214
Var 10	-0,440	-0,864	-0,070	0,016	0,946
Variance	2,3788	1,8296	1,2648	0,5643	6,0388
% Var	0,238	0,183	0,126	0,056	0,604

Análise Multivariada - 2016

✓ Rotação Componentes Principais

Rotated Factor Loadings and Communalities					
Varimax Rotation					
Variable	Factor1	Factor2	Factor3	Factor4	Communality
Var 1	0,691	0,118	0,158	-0,113	0,887
Var 2	0,631	0,194	0,515	0,006	0,701
Var 3	0,248	0,825	0,223	0,148	0,811
Var 4	0,239	0,151	0,750	-0,077	0,648
Var 5	0,797	0,075	0,102	-0,468	0,870
Var 6	0,404	0,153	0,635	0,170	0,618
Var 7	0,146	0,591	0,174	0,779	0,724
Var 8	-0,336	0,076	0,762	-0,237	0,660
Var 9	-0,048	0,735	0,110	-0,141	0,574
Var 10	0,045	-0,041	0,112	-0,934	0,888
Variance	2,1345	2,0230	1,9407	1,2335	7,3317
% Var	0,213	0,202	0,194	0,123	0,793

✓ Rotação Máxima Verossimilhança

Maximum Likelihood Factor Analysis of the Correlation Matrix					
Unrotated Factor Loadings and Communalities					
Variable	Factor1	Factor2	Factor3	Factor4	Communality
Var 1	0,493	-0,225	0,700	0,179	0,816
Var 2	0,464	-0,381	0,455	-0,240	0,625
Var 3	0,575	-0,407	0,101	0,110	0,686
Var 4	0,345	-0,407	0,204	-0,437	0,519
Var 5	0,144	-0,563	0,551	0,166	0,669
Var 6	0,418	-0,247	0,307	-0,345	0,449
Var 7	0,666	-0,301	-0,182	0,041	0,569
Var 8	0,211	-0,322	0,127	-0,360	0,294
Var 9	0,392	-0,194	-0,138	-0,058	0,214
Var 10	-0,440	-0,864	-0,070	0,016	0,946
Variance	2,3788	1,8296	1,2648	0,5643	6,0388
% Var	0,238	0,183	0,126	0,056	0,604

✓ Ambos os métodos

– Loadings apontam para mesmo atributos subjacentes

– Fatores 1 e 2 não estão na mesma ordem

Variável	Loadings Estimados				Máxima Verossimilhança
	L <sub>1</sub>	L <sub>2</sub>	L <sub>3</sub>	L <sub>4</sub>	
100m rasos	0,884	0,136	0,156	0,113	0,837
Salto em distância	0,631	0,194	0,515	0,006	0,701
Arremesso de peso	0,245	0,825	0,223	0,148	0,811
Salto em altura	0,239	0,151	0,750	-0,077	0,648
400m rasos	0,797	0,075	0,102	-0,468	0,870
100m com barreiras	0,404	0,153	0,635	0,170	0,618
Lançamento de disco	0,186	0,814	0,147	0,079	0,724
Salto com vara	-0,036	0,176	0,762	-0,217	0,660
Lançamento de dardo	-0,048	0,735	0,110	-0,141	0,574
1.500 m	0,045	-0,041	0,112	-0,934	0,888
Variancia	2,134	2,023	1,941	1,233	7,332
% variabilidade	21,3%	20,2%	19,4%	12,3%	17,7%
					15,9% 15,8% 11,0% 60,4%

Análise Multivariada - 2016


90

- Solução de máxima verossimilhança -Interpretação:
  - ✓ F1\*: Arremesso de peso, lançamento de disco e lançamento de dardo.  
– Linden (1977): *explosive arm strength*
  - ✓ F2\*: 100 m rasos e 400 m rasos (salto em distância)  
– Linden (1977): *running speed*
  - ✓ F3\*: Salto em altura, 110 m com barreiras, salto com vara e salto em distância  
– Linden (1977): *explosive leg strength*
  - ✓ F4\*: 1.500 m e 400 m rasos  
– Linden (1977): *running endurance*

Análise Multivariada - 2016

91

- Plot dos *loadings* de máxima verossimilhança com rotação:



✓ Em geral, os pontos estão agrupados ao longo dos eixos

Análise Multivariada - 2016

92

## Estimação dos Escores dos Fatores

- Modelo factorial:
 
$$\begin{aligned} Z_1 &= l_{11}F_1 + l_{12}F_2 + \dots + l_{1m}F_m + \epsilon_1 \\ Z_2 &= l_{21}F_1 + l_{22}F_2 + \dots + l_{2m}F_m + \epsilon_2 \\ &\vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \\ Z_p &= l_{p1}F_1 + l_{p2}F_2 + \dots + l_{pm}F_m + \epsilon_p \end{aligned}$$
- ✓ Para cada elemento amostral  $k$ , seu escore no fator  $F_j$  é calculado como:
 
$$\hat{F}_{jk} = w_{j1}Z_{1k} + w_{j2}Z_{2k} + \dots + w_{jp}Z_{pk}$$
  - $w_{jk}$ : peso de ponderação de cada variável no Fator  $F_j$

Análise Multivariada - 2016

95

- Os escores podem ser utilizados para construir:
  - ✓ Gráficos
  - ✓ Mapas de percepção
  - ✓ Variável resposta ou explicativa em outros métodos
- Métodos de estimação dos scores:
  - ✓ Método de mínimos quadrados ponderados
  - ✓ Método de regressão
  - ✓ Método ad hoc

Análise Multivariada - 2016

96

### Exemplo 9.12 – Cálculo dos Scores Fatoriais

- Ações New York

✓ Solução por Máxima Verossimilhança de R

Rotated Factor Loadings	
0,599557	0,379038
0,851127	0,164465
0,640928	0,337589
0,363370	0,509725
0,207976	0,879263

Matrix \Psi	
0,496861	0,000000
0,000000	0,248534
0,000000	0,475245
0,000000	0,000000
0,000000	0,000000
0,000000	0,000000

✓ Regressão:  $\hat{f} = \hat{L}^{*'} R^{-1} z$

✓ Mínimos quadrados ponderados:  $\hat{f} = (\hat{L}^{*'} \hat{\Psi}^{-1} \hat{L}^*)^{-1} \hat{L}^{*'} \hat{\Psi}^{-1} z$

Análise Multivariada - 2016

101

- Para o vetor de observações padronizadas:

$$\sqrt{z} = [0,5; -1,40; -0,20; -0,70; 1,40]$$

✓ scores por regressão

$$\hat{f} = \hat{L}^{*'} R z = \begin{bmatrix} 0,1838 & 0,6626 & 0,2188 & 0,0479 & -0,2085 \\ 0,0402 & -0,1877 & 0,0164 & 0,1123 & 0,8553 \end{bmatrix} \begin{bmatrix} 0,50 \\ -1,40 \\ -0,20 \\ -0,70 \\ 1,40 \end{bmatrix} = \begin{bmatrix} -1,205 \\ 1,398 \end{bmatrix}$$


✓ Para cálculo da matriz de dados

$$\hat{f}' = z' R^{-1} \hat{L}^*$$

Análise Multivariada - 2016

102

- Plot scores fatoriais:



Análise Multivariada - 2016

105

### Critérios para Determinação do Valor de $m$

- Teste de hipótese para auxiliar na decisão do número de fatores ( $m$ ) que são suficientes para o modelo de análise factorial

- Suposições do teste:

✓ Os vetores aleatórios  $Z$  e  $F$  têm distribuição normal multivariada

✓ Amostras de tamanho grande

Análise Multivariada - 2016

107

- Teste

✓  $H_0$ :  $m$  fatores são suficientes vs.

$H_1$ : necessários mais que  $m$  fatores

✓ Estatística de teste (Bartlett, 1954)

$$T = \left[ n - 1 - \frac{2p + 4m + 5}{6} \right] \ln \left( \frac{|\hat{\mathbf{L}}_z \hat{\mathbf{L}}_z'| + \hat{\Psi}_z|}{|R|} \right)$$

✓ Sob  $H_0$ :  $T \sim \chi^2_{gl}$ , com  $gl = \frac{1}{2} [(p - m)^2 - p - m]$

✓ Para o teste ser válido  $gl > 0$

- Se  $p = 5$ ,  $m \leq 2$

- Se  $p = 10$ ,  $m \leq 5$

- Se  $p = 20$ ,  $m \leq 14$

✓ Para  $n$  grande e  $m$  pequeno em relação a  $p$ , o teste tende a rejeitar  $H_0$  (indica aumento de  $m$ )

Análise Multivariada - 2016

108

- Comentários:

✓ Teste somente é válido para dados provenientes de distribuição normal p-variada

✓ Para  $n$  grande e  $m$  pequeno em relação a  $p$ , o teste tende a rejeitar  $H_0$  (indicando o aumento de  $m$ )

- Baseando-se apenas na indicação do teste, a tendência será reter no sistema um número muito grande de fatores sem necessidade

Análise Multivariada - 2016

109

### Exemplo 9.7 – Teste para valor de $m$

- Ações Bolsa New York ( $m = 2$ )

$$\hat{\mathbf{L}}_z \hat{\mathbf{L}}_z' + \hat{\Psi} = \begin{bmatrix} 1,00000 & 0,57264 & 0,51223 & 0,41107 & 0,45797 \\ 0,57264 & 1,00000 & 0,60103 & 0,39311 & 0,32162 \\ 0,51223 & 0,60103 & 1,00000 & 0,40497 & 0,43013 \\ 0,41107 & 0,39311 & 0,40497 & 1,00000 & 0,52375 \\ 0,45797 & 0,32162 & 0,43013 & 0,52375 & 1,00000 \end{bmatrix}$$

$$\mathbf{R} = \begin{bmatrix} 1,00000 & 0,57692 & 0,50866 & 0,38672 & 0,46218 \\ 0,57692 & 1,00000 & 0,59838 & 0,38952 & 0,32195 \\ 0,50866 & 0,59838 & 1,00000 & 0,43610 & 0,42563 \\ 0,38672 & 0,38952 & 0,43610 & 1,00000 & 0,52353 \\ 0,46218 & 0,32195 & 0,42563 & 0,52353 & 1,00000 \end{bmatrix}$$

$$|\hat{\mathbf{L}}_z \hat{\mathbf{L}}_z' + \hat{\Psi}| = 0,194403 \text{ e } |R| = 0,193234$$

$$T = \left[ 100 - 1 - \frac{2(5) + 4(2) + 5}{6} \right] \ln \left( \frac{0,194403}{0,193234} \right) = 0,574$$

✓ Valor crítico:  $gl = \frac{1}{2}[(5 - 2)^2 - 5 - m] = 1$

$$\chi^2_1(0,05) = 3,84 \rightarrow \text{Não se rejeita } H_0$$

$$\text{p-valor: } P\{\chi^2_1 > 0,574\} = 0,448674$$

-  $H_0$  não deveria ser rejeitada em qualquer nível razoável

110

### Critério de Akaike

Akaike (1974, 1987)

- Suposições:

✓ Dados provenientes de normal multivariada

✓ Envolve método de máxima verossimilhança

- Critério: escolhe-se o valor de  $m$  que minimize a função AIC

$$\text{AIC} = [-\ln(\max\{L(\mu, \Sigma)\})]$$

✓ Se dois métodos tem a mesma verossimilhança, o procedimento vai privilegiar o modelo com menor número de fatores

Análise Multivariada - 2016

111

### Critério Bayesiano de Schwarz

- Suposições:
  - ✓ Dados provenientes de normal multivariada
  - ✓ Envolve método de máxima verossimilhança
- Critério: escolhe-se o valor de  $m$  que minimize a função SBC

$$SBC = [-\ln(\max\{L(\mu, \Sigma)\})] + \frac{m}{2} \ln(n)$$

- ✓ Os critérios AIC e SBC devem ser usados com cautela
  - Em geral, indicam quantidade de fatores maior que a necessária
- ✓ Em geral, o critério SBC resulta em melhores soluções que o método Akaike

Análise Multivariada - 2016

112

### Matriz de Resíduos

- A observação da matriz de resíduos:
  - ✓ Muitas vezes, pode indicar quando o número de fatores está superdimensionado
  - ✓ Ex.:
    - Se  $m$  não for muito pequeno e a matriz de resíduos estiver próxima de zero, recomenda-se testar outras soluções para  $m$  menores que o valor já especificado

Análise Multivariada - 2016

114

- Importante:

- ✓ Análise factorial deve ser utilizada apenas se utilizada em situações em que as variáveis originais são correlacionadas
- ✓ Consequência:
  - Evitar soluções com  $m$  elevado tal que determinados fatores fiquem relacionados com uma única variável original
- ✓ Em situações em que aparecem fatores relacionados a uma única variável  $Z_i$  é recomendável retirar a variável  $Z_i$  e reestimar o modelo de análise factorial

Análise Multivariada - 2016

115

### Validação do Modelo

- Análise Fatorial está fundamentada em suposições que não podem ser verificadas a priori:
  - ✓ Linearidade e independência dos fatores
  - ✓ Interpretação centrada na informação contida na matriz  $\hat{L}$  (estimada a partir da escolha prévia de  $m$ )
- É importante avaliar até que ponto a matriz  $\hat{L}$  está representando corretamente a relação existente entre as variáveis originais e os fatores do modelo

Análise Multivariada - 2016

116

## Estratégia para Análise Fatorial

Johnson & Wichern (2002)

- Decisões em qualquer Análise Fatorial

- ✓ Escolha de  $m$ , o número de fatores comuns

- Há muitos testes de adequação assintóticos que são apropriados apenas os dados que são aproximadamente normais
- Os teste provavelmente rejeitarão o modelo para  $m$  pequeno se o número de variáveis e de observações for alto
- Em geral a escolha é baseada em alguma combinação de:
  - proporção de variância amostral explicada
  - conhecimento do assunto
  - razoabilidade dos resultados

Análise Multivariada - 2016

117

- ✓ Escolha do método de solução e do tipo de rotação

- São decisões menos cruciais
- A maioria de análises fatoriais satisfatórias são aquelas em que:
  - são tentados mais de um método de rotação
  - os resultados confirmam substancialmente a mesma estrutura

Análise Multivariada - 2016

118

## Roteiro

1. Execute uma Análise Fatorial por componentes principais

- ✓ Este método é particularmente apropriado para uma primeira passagem pelos dados
- ✓ Procure observações suspeitas plotando os escores fatoriais
  - Calcule os escores padronizados e as distâncias quadráticas para cada observação
- ✓ Tente rotação Varimax

Análise Multivariada - 2016

119

2. Execute Análise Fatorial de Máxima Verossimilhança,

- ✓ (incluir uma rotação Varimax)

3. Compare as soluções obtidas pelas duas análises fatoriais

- ✓ Os loadings se agrupam da mesma maneira?
- ✓ Plote os escores fatoriais obtidos por componentes principais vs. os obtido pela solução de máxima verossimilhança

4. Repita passos anteriores para outros valores de  $m$

- ✓ Os fatores extras contribuem necessariamente para a compreensão e interpretação dos dados?

Análise Multivariada - 2016

120

5. Para grandes conjuntos de dados, divida-os pela metade e execute uma Análise Fatorial em cada parte
- ✓ Compare os dois resultados, com aquele obtido do conjunto de dados completo
  - ✓ Verifique a estabilidade da solução
  - ✓ A divisão pode ser aleatória ou determinística

Análise Multivariada - 2016

121

### Exemplo 9.14

- Medidas de ossos e crânios de frangos White Leghorn
  - ✓ Dados originais: Dunn (1928)
  - ✓ Análise fatorial elaborada por Wright (1954)
  - ✓ Variáveis:  
 Crânio              Pernas              Asas  
 $\sqrt{X_1}$ : comprimento     $\sqrt{X_3}$ : fêmur (comp.)     $\sqrt{X_5}$ : úmero (comp.)  
 $\sqrt{X_2}$ : amplitude       $\sqrt{X_4}$ : tíbia (comp.)       $\sqrt{X_6}$ : cíbito (comp.)
  - ✓ Dados: *BD\_multivariada.xls/frangos*

Análise Multivariada - 2016

122

- Matriz de Correlações amostral:

R (conjunto completo)									
R <sub>1</sub> (n <sub>1</sub> = 137)	R <sub>2</sub> (n <sub>2</sub> = 139)								
1,000 0,696 0,588 0,639 0,694 0,660	1,000 0,366 0,572 0,587 0,587 0,598								
0,696 1,000 0,540 0,575 0,606 0,584	0,366 1,000 0,352 0,406 0,420 0,386								
0,588 0,540 1,000 0,901 0,844 0,866	0,572 0,352 1,000 0,950 0,909 0,894								
0,639 0,575 0,901 1,000 0,835 0,863	0,587 0,406 0,950 1,000 0,911 0,927								
0,694 0,606 0,844 0,835 1,000 0,931	0,587 0,420 0,909 0,911 1,000 0,940								
0,660 0,584 0,866 0,863 0,931 1,000	0,598 0,386 0,894 0,927 0,940 1,000								

Análise Multivariada - 2016

123

- Solução por Componentes Principais

Principal Component Factor Analysis of the Correlation Matrix					
Unrotated Factor Loadings and Communalities					
Variable	Factor1	Factor2	Factor3	Communality	
Var 1	0,741	0,350	0,573	0,999	
Var 2	0,604	0,721	-0,340	1,000	
Var 3	0,929	-0,233	-0,075	0,923	
Var 4	0,943	-0,174	-0,067	0,925	
Var 5	0,948	-0,143	-0,045	0,920	
Var 6	0,945	-0,189	-0,047	0,930	
Variance	4,4564	0,7824	0,4584	5,6973	
% Var	0,743	0,130	0,076	0,950	
Rotated Factor Loadings and Communalities					
Varimax Rotation					
Variable	Factor1	Factor2	Factor3	Communality	
Var 1	0,355	0,502	0,243	0,999	
Var 2	0,535	0,238	0,169	1,000	
Var 3	0,921	0,218	0,165	0,923	
Var 4	0,904	0,251	0,212	0,925	
Var 5	0,888	0,284	0,228	0,920	
Var 6	0,908	0,264	0,191	0,930	
Variance	3,4578	1,1198	1,1197	5,6973	
% Var	0,576	0,187	0,187	0,950	

Análise Multivariada - 2016

124

- Solução por Componentes Principais

Variável	Componentes Principais						$h^2$	$\Psi_i$
	$L_1$	$L_2$	$L_3$	$L_1$	$L_2$	$L_3$		
Comprimento	0,741	0,350	0,573	0,355	0,902	0,243	0,999	0,001
Amplitude	0,604	0,721	-0,340	0,235	0,211	0,949	1,000	0,000
Fêmur	0,929	-0,233	-0,075	0,921	0,218	0,165	0,923	0,077
Tíbia	0,943	-0,174	-0,067	0,904	0,251	0,212	0,925	0,075
Úmero	0,948	-0,143	-0,045	0,888	0,284	0,228	0,920	0,080
Côbito	0,945	-0,189	-0,047	0,908	0,264	0,191	0,930	0,070
Variância	4,456	0,782	0,458	3,458	1,120	1,120	5,697	
% variabilidade	74,3%	13,0%	7,6%	57,6%	18,7%	18,7%	95,0%	

- Matriz de Resíduos

Matrix M8								
-0,0000000	0,0002522	0,0055712	0,0028457	-0,0051820	-0,0036794			
0,0002522	-0,0000000	0,0031813	-0,000630	-0,0027691	-0,0006024			
0,0055712	0,0031813	-0,0000000	0,0041433	-0,0397322	-0,0468808			
0,0028457	-0,000630	0,0041433	-0,0000000	-0,0478565	-0,0332595			
-0,0051820	-0,0027691	-0,0397322	-0,0478565	-0,0000000	0,0127770			
-0,0036794	-0,0006024	-0,0468809	-0,0332595	0,0127770	-0,0000000			

Análise Multivariada - 2016

125

- Solução por Máxima Verossimilhança

Factor Analysis: M1					
Maximum Likelihood Factor Analysis of the Correlation Matrix					
* NOTE * Heywood case					
Rotated Factor Loadings and Communalities					
Varimax Rotation					
Variable Factor1 Factor2 Factor3 Communality					
Var 1	0,468	-0,491	0,154	0,484	
Var 2	0,209	-0,808	0,066	0,701	
Var 3	0,887	-0,281	0,126	0,881	
Var 4	0,941	-0,336	-0,026	1,000	
Var 5	0,816	-0,349	0,444	0,985	
Var 6	0,846	-0,314	0,310	0,910	
Variance	3,3169	1,3061	0,3375	4,9605	
%					

✓ Heywood Case: variância específica da tíbia = 0

- Replicar o resultado, usando a opção Heywood (SAS ou similar)

Análise Multivariada - 2016

126

- Solução por Máxima Verossimilhança

Variável	Máxima Verossimilhança						$h_i^2$	$\Psi_i$	
	Loadings Estimados			Loadings Estimados (Rotação)					
	$L_1$	$L_2$	$L_3$	$L_1$	$L_2$	$L_3$			
Comprimento	0,602	0,279	0,209	0,468	0,491	0,154	0,484	0,516	
Amplitude	0,467	0,674	0,172	0,209	0,808	0,066	0,701	0,299	
Fêmur	0,926	-0,054	0,143	0,887	0,281	0,126	0,881	0,119	
Tíbia	1,000	0,000	0,000	0,941	0,336	-0,026	1,000	0,000	
Úmero	0,874	-0,010	0,470	0,816	0,349	0,444	0,985	0,015	
Côbito	0,894	-0,034	0,331	0,846	0,314	0,310	0,910	0,090	
Variância	4,001	0,536	0,424	3,317	1,306	0,338	4,961		
% variabilidade	66,7%	8,9%	7,1%	55,3%	21,8%	5,6%	82,7%		

- Matriz de Resíduos

Matrix M9								
0,0000000	0,000290	-0,0033400	-0,0000000	-0,0005029	0,0052478			
0,000290	0,0000000	0,0013411	-0,0000000	0,0000741	-0,0010782			
-0,0033400	0,0013411	0,0000000	-0,0000000	-0,0001735	0,0008743			
-0,0000000	-0,0000000	0,0000000	0,0000000	-0,0000000	-0,0000000			
-0,0005029	0,0000741	-0,0001735	-0,0000000	0,0000000	-0,0001086			
0,0052478	-0,0010782	0,0008743	-0,0000000	-0,0001086	0,0000000			

Análise Multivariada - 2016

127

- Comentários:

✓ Após a rotação, os dois métodos de solução parecem fornecer resultados diferentes

✓ Componentes principais:

- $F_1$ : Todos os fatores, exceto  $X_1$  e  $X_2$ .
- $F_2$  e  $F_3$ : cada um com uma única variável
- Solução por três fatores comuns parece estar garantida ( $F_3$  explica uma quantidade significativa da variância)

✓ Máxima Verossimilhança:

- $F_1$ : Todos os fatores exceto  $X_1$  e  $X_2$
- $F_2$ : Dimensão cabeça ( $X_1$  e  $X_2$ )
- $F_3$ : não é claro (provavelmente não é necessário)
- Matriz de resíduos com elementos bastante pequenos (retenção de 3 ou menos fatores)

Análise Multivariada - 2016

128

- Plot dos escores de  $F_1$  e  $F_2$

✓ Escores por Mínimos Quadrados Ponderados de estimativas de máxima verossimilhança com rotação




Figure 9.5 Factor scores for the first two factors of chicken-bone data.

- Gráficos deste tipo permitem identificar observações que não são consistentes com o restante das observações

Análise Multivariada - 2016

129

- Plot dos escores fatoriais obtidos por componentes principais e por máxima verossimilhança

✓ Se os loadings de um particular fator concordam entre si, os pares de escores deveriam se agrupar próximos à identidade

✓ Conjuntos de loadings que não concordam produzirão escores fatoriais que se desviam deste padrão

- Usualmente, associado com o último fator, podendo sugerir que o número de fatores é muito grande  
(últimos fatores não significativos)

Análise Multivariada - 2016

130

✓  $F_1$  – Componentes Principais vs. Máxima Verossimilhança





Figure 9.6 Pairs of factor scores for the chicken-bone data. (Loadings are estimated by principal component and maximum likelihood methods.)

Análise Multivariada - 2016

131

✓  $F_2$  – Componentes Principais vs. Máxima Verossimilhança




✓ Uma das observações não é consistente com as demais  
- Score incomumente alto

Análise Multivariada - 2016

132

✓  $F_3$  – Componentes Principais vs. Máxima Verossimilhança



✓ Aparentemente, o 3º fator não é necessário

133

- Divisão do conjunto de dados em duas partes iguais (o conjunto de dados é grande)
  - ✓ Matrizes de correlação

Análise Multivariada - 2016

134

✓ Estimativas dos loadings por Componentes Principais com rotação ( $m=3$ )

Variável	Componentes Principais - Loadings c/ Rotação					
	$L_1$	$L_2$	$L_3$	$h^2$	$\Psi_L$	$L_h$
Comprimento	0,360	0,361	0,853	0,988	0,012	0,352
Amplitude	0,303	0,899	0,312	0,997	0,003	0,203
Fêmur	0,914	0,238	0,175	0,923	0,077	0,930
Tíbia	0,877	0,270	0,242	0,901	0,099	0,925
Úmero	0,830	0,247	0,395	0,906	0,094	0,912
Côbito	0,871	0,231	0,332	0,922	0,078	0,914
Variância	3,273	1,182	1,180	5,636		3,553
% variabilidade	54,6%	19,7%	19,7%	93,9%		59,2%
						18,8%
						18,1%
						96,1%

– Os resultados das duas metades são bastante similares

Análise Multivariada - 2016

135

- Conclusões

- ✓ Fatores  $F_2^*$  e  $F_3^*$  trocam de posição, mas coletivamente representam as dimensões da cabeça
- ✓ Fator  $F_1^*$  aparenta ser dimensões do corpo (pernas e asas)
- ✓ A solução é estável
  - É a mesma interpretação dada pelo conjunto completo
- ✓ Parece que modelo com um ou dois fatores é suficiente para ajustar os dados

Análise Multivariada - 2016

136

## Outras Medidas de Ajuste do Modelo

- ✓ Critério de Kaiser-Meyer-Olkin (KMO)
- ✓ Teste de Esfericidade de Bartlett para R

Análise Multivariada - 2016

137

## Critério de Kaiser–Meyer–Olkin

- ✓ Rencher (2002) sugere que para um modelo de Análise Fatorial possa ser ajustado adequadamente aos dados é necessário que  $R^{-1}$  seja próxima da matriz diagonal
  - O coeficiente KMO baseia-se nesse princípio

$$KMO = \frac{\sum_{i \neq j} R_{ij}^2}{\sum_{i \neq j} R_{ij}^2 + \sum_{i \neq j} Q_{ij}^2}$$

- ✓  $R_{ij} = \text{Corr}(X_i, X_j)$
- ✓  $Q_{ij} = \text{Correlação parcial entre 2 variáveis quando todas as outras variáveis são consideradas constantes}$
- ✓  $Q_{ij} \approx \text{zero} \rightarrow KMO \approx 1 \rightarrow R^{-1} \approx \text{diagonal}$

Análise Multivariada - 2016

138

- Adequabilidade do ajuste de um modelo de Análise Fatorial (Rice, 1977)
  - ✓ modelo adequado:  $KMO \geq 0,8$
  - ✓ modelo excelente:  $KMO \geq 0,9$
  - ✓ modelo péssimo:  $KMO \leq 0,5$

Análise Multivariada - 2016

139

## Teste de Bartlett

- Teste de Esfericidade da matriz de correlação
  - ✓ Suposições:
    - variáveis provenientes de distribuição normal multivariada
    - modelo de Análise Fatorial pressupõe que as variáveis respostas são correlacionadas entre si
  - ✓ Teste de hipótese para verificar se a matriz de correlação populacional é próxima ou não da identidade

Análise Multivariada - 2016

140

- Hipóteses:

✓  $H_0: \boldsymbol{\rho} = \mathbf{I}$  vs.  $H_1: \boldsymbol{\rho} \neq \mathbf{I}$

- Estatística de teste:

$$T = - \left[ n - \frac{1}{6}(2p + 1) \right] \sum_{i=1}^p \ln \hat{\lambda}_i$$

✓  $\hat{\lambda}_i$ : autovalores da matriz de correlação amostral R

- Sob  $H_0$ :  $T \sim \chi^2_{gl}$ , com  $gl = \frac{1}{2} p(p - 1)$

✓ Para se ajustar o modelo de Análise Fatorial, o teste de Bartlett deve rejeitar  $H_0$ .

Análise Multivariada - 2016

141

### Comentários

- Análise factorial permanece muito subjetiva

✓ Exemplos em que o modelo oferece explicações razoáveis em termos de poucos fatores interpretáveis

✓ Infelizmente o critério para julgar a qualidade de qualquer análise factorial não têm sido bem quantificado

- A qualidade do ajuste parece depender do critério Huau (wow)

✓ Huau, eu comprehendi estes fatores

Análise Multivariada - 2016

142

### Exemplos

### Exemplo

- Expectativa de vida

✓ Referente à expectativa de vida (em anos) nos anos 60

– Médias por país, idade e sexo

✓ Fonte: Keyfitz e Flieger (1971)

✓ Apresentado em Everitt e Hothorn (2011)

✓ Dados: lifeex.txt

Análise Multivariada - 2016

146

- Variáveis:

- ✓ País: país (fator com 31 níveis)
- ✓ m0: expectativa média de vida dos homens ao nascer (anos)
- ✓ m25: expectativa média de vida dos homens na juventude (anos)
- ✓ m50: expectativa média de vida dos homens na maturidade (anos)
- ✓ m75: expectativa média de vida dos homens na velhice (anos)
- ✓ w0: expectativa média de vida das mulheres ao nascer (anos)
- ✓ w25: expectativa média de vida das mulheres na juventude (anos)
- ✓ w50: expectativa média de vida das mulheres na maturidade (anos)
- ✓ w75: expectativa média de vida das mulheres na velhice (anos)

Análise Multivariada - 2016

147

- Carregamento dos dados – Comandos em R:

```
> # Carregamento de Dados
>
> expectativa <- read.table("lifeex.txt", header = T) # Carrega data frame
> colunas <- c("pais", "h0", "h25", "h50", "h75", "m0", "m25", "m50", "m75")
> colnames(expectativa) <- colunas
> head(expectativa)
  pais h0 h25 h50 h75 m0 m25 m50 m75
1 Algeria 63 51 30 13 67 54 34 15
2 Cameroon 34 29 13 5 38 32 17 6
3 Madagascar 38 30 17 7 38 34 20 7
4 Mauritius 59 42 20 6 64 46 25 8
5 Reunion 56 38 18 7 62 46 25 10
6 Seychelles 62 44 24 7 69 50 28 14
> vida <- expectativa[, -1]
```

Análise Multivariada - 2016

148

- ✓ Teste formal para o número de fatores – Máxima Verossimilhança

```
> # Teste para o número de fatores - MV
>
> rownames(vida) <- expectativa[, 1]
> sapply(1:3, function(f)
+ factanal(vida, factors = f, method = "mle")$FVAL)
  objective   objective   objective
1.879555e-24 1.911514e-05 4.578204e-01
```

- ✓ Teste:  $H_0$ : quantidade de fatores é suficiente
- ✓ A solução com 3 fatores pode ser suficiente
- ✓ Cuidado:
  - Há apenas 31 países e o uso de teste assintótico pode ser suspeito

Análise Multivariada - 2016

149

- ✓ Modelo factorial com 3 fatores

```
> # Análise factorial
>
> vida.af <- factanal(vida, factors = 3, method = "mle")
> vida.af

Call:
factanal(x = vida, factors = 3, method = "mle")

Uniquenesses:
   h0    h25   h50   h75    m0    m25   m50   m75
h0 0.005 0.362 0.066 0.288 0.005 0.011 0.020 0.146

Loadings:
 Factor1 Factor2 Factor3
h0  0.964  0.122  0.226
h25 0.646  0.169  0.438
h50 0.430  0.354  0.790
h75 0.430  0.525  0.656
m0  0.970  0.217
m25 0.764  0.556  0.310
m50 0.536  0.729  0.401
m75 0.156  0.867  0.280

Factor1 Factor2 Factor3
h0 loadings  3.375  2.082  1.640
Proportion Var 0.422  0.260  0.205
Cumulative Var 0.422  0.682  0.887

Test of the hypothesis that 3 factors are sufficient.
The chi square statistic is 6.73 on 7 degrees of freedom.
The p-value is 0.455
```

- Default do comando `factanal` é rotação Varimax

Análise Multivariada - 2016

150

✓ Comunalidades

```
# Comunalidades:
# 1 - vida.af$uniquenesses
h0      h25     h50     h75      m0      m25      m50      m75
0.9950000 0.6383261 0.9337228 0.7122064 0.9950000 0.9889330 0.9798799 0.8540204
```

- ✓ As variáveis h0, h50, m0, m25 e m50 compartilham muito de suas variâncias através dos fatores
- ✓ As variáveis h25 e h75 são mais únicas

Análise Multivariada - 2016

151

✓ Interpretação dos fatores

```
# Loadings
vida.af$loadings


Loadings:
Factor1 Factor2 Factor3
h0      0.964  0.122  0.226
h25     0.646  0.169  0.438
h50     0.430  0.354  0.790
h75     0.525  0.525  0.656
m0      0.970  0.217
m25     0.764  0.556  0.310
m50     0.536  0.729  0.401
m75     0.156  0.867  0.280

Factor1 Factor2 Factor3
ss loadings 3.375  2.082  1.640
Proportion Var 0.422  0.260  0.205
Cumulative Var 0.422  0.682  0.887
```

- ✓ F1: Expectativa de vida ao nascer (H/M) dominante  
– (Força de vida ao nascer)
- ✓ F2: Expectativa de vida em mulheres mais velhas  
– (Força de vida mulheres mais velhas)
- ✓ F3: Cargas maiores para h50 e h75  
– (força de vida homens mais velhos)

Análise Multivariada - 2016


152



Análise Multivariada - 2016

153

• Gráfico 3-D dos fatores vs. dados




```
# 3-D Plot dos 3 fatores vs. dados
library(lattice)
cloud(Fator3 ~ Fator1 * Fator2, xlim=range(Fator1), ylim=range(Fator2),
      zlim=range(Fator3),
      pch=row.names(vida.df),
      scales = list(distance = rep(1, 3), arrows = FALSE))
```

Análise Multivariada - 2016

154

- Diagramas de dispersão dos escores fatoriais



- Força de vida ao nascer variando de países como Camarões e Madagascar para países como USA
- Argélia se sobressai no 3º. Eixo
  - ✓ Alta expectativa de vida entre homens
- Camarões baixa expectativa de vida aos 50

Análise Multivariada - 2016

155

## Referências

### Bibliografia Recomendada

- MANLY, B. J. F. *Métodos Estatísticos Multivariados: uma Introdução*. Bookman, 2008.
- JOHNSON, R. A.; WINCHERN, D. W. *Applied Multivariate Statistical Analysis*. Prentice Hall, 2007
- MINGOTI, D.C. *Análise de Dados através de Métodos de Estatística Multivariada*. Ed. UFMG, 2005.
- EVERITT, B.; HOTHORN, T. *An Introduction to Applied Multivariate Analysis with R*. Springer, 2011.

Análise Multivariada - 2016

159