

Análise Multivariada

Lupércio França Bessegato
Dep. Estatística/UFJF

Roteiro

1. Introdução
2. Representação de Dados Multivariados
3. Análise de Componentes Principais
4. Distribuições de Probabilidade Multivariadas
5. Análise Fatorial
6. Análise de Correlação Canônica
7. Análise de Conglomerados
8. Análise Discriminante
9. Referências

Análise Multivariada - 2017

2

Introdução

Análise Multivariada

- Considera várias variáveis relacionadas simultaneamente.
- Variáveis de interesse não independentes uma das outras.
- Associação entre conjuntos de medidas.

Análise Multivariada - 2017

4

Estatística Multivariada

- Métodos estatísticos utilizados em situações nas quais as variáveis são medidas simultaneamente, em cada elemento amostral
 - √ Em geral, independem do conhecimento da forma matemática da distribuição subjacente

5

Análise Multivariada- 2017

Objetos

- Entidades das quais são tomadas medidas
 - √ Itens, pessoas, organizações, etc.
 - √ São portadores de medidas
 - √ São medidos somente com respeito a certas variáveis de interesse

6

Análise Multivariada- 2017

Variáveis

- Características ou propriedades
 - √ São os aspectos dos objetos que são medidos

7

Análise Multivariada- 2017

Observação e Dados

- Dados:
 - √ Observações documentadas ou resultados de medição

```
graph TD; UC[Universo de observações potenciais] --> SC[Subconjunto de comportamentos observados]; SC --> D[Dados]; D --> E[Estrutura]; P[Processo de codificação] --> M[Modelos de medida]; M --> D; Q[Qual fenômeno observar?] --> SC; F[O que focar?] --> SC; MM[Modelos multivariados] --> E;
```

8

Análise Multivariada- 2017

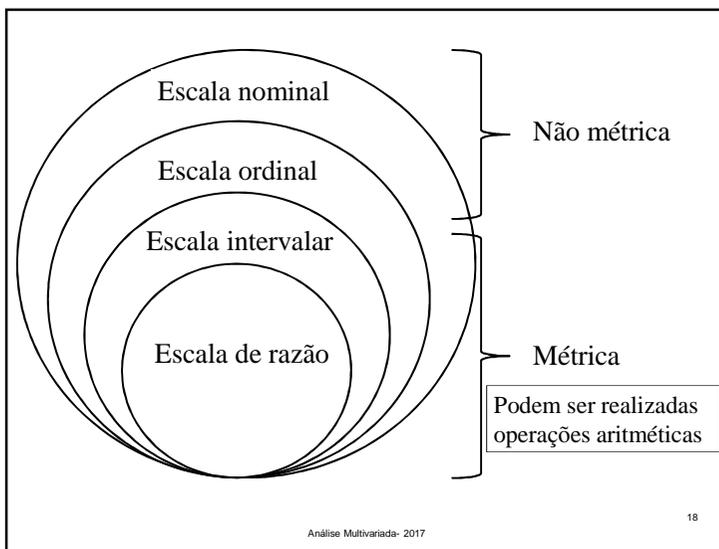
- Teoria subjacente sobre a área de interesse:
 - √ Necessária em cada etapa do processo de ir das observações aos dados
 - √ A interação do pesquisador (orientado pela teoria) com o ambiente de observações potenciais é que leva aos dados
- Última etapa:
 - √ Buscar estrutura associativa nos dados adequando os modelos multivariados

9

Medida

- Processo pelo qual atribuem-se aos números (ou, algumas vezes, outros símbolos) características ou propriedades de objetos, de acordo com um procedimento predeterminado
- Escala de medida:
 - √ Refere-se à quantidade de informação que está contida na medida e o que ela nos informa sobre a relação entre dois objetos

10



Organização de Dados Multivariados

$$\mathbf{X}_{n \times p} = \begin{matrix} & \begin{matrix} 1 & 2 & \dots & p \end{matrix} \\ \begin{matrix} 1 \\ 2 \\ \vdots \\ n \end{matrix} & \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \end{matrix}$$

p: número de variáveis
n: número de objetos

- √ Matriz:
 - Organização em arranjo estrutural de dados multivariados (métricos ou não métricos)
- √ Colunas: variáveis (características medidas de objetos)
- √ Linhas: objetos (lista de características medidas de um objeto)

20

Conjunto de Dados #1

- Bumpus (1898)
- Pardais sobreviventes de tempestade
 - √ Dados de 1/Fev/1898
 - √ Medidas morfológicas e peso de 49 pássaros fêmeas
 - √ 28 morreram, 21 não morreram
- Dados: *birds.csv* (*birds.txt*)

Análise Multivariada - 2017

21

√ Variáveis:

- sv: 1= vivo, 2= morto.
- ag: 1= adulto, 2 = jovem.
- tl: comprimento total (bico à ponta da cauda), em mm.
- ae: extensão alar, (ponta a ponta de asas), em mm.
- wt: peso, em gramas.
- bh: comprimento bico e cabeça, em mm.
- hl: comprimento do úmero (osso braço), em polegadas.
- fl: comprimento do fêmur (osso coxa), em polegadas.
- tt: comprimento da tibia-tarso (osso perna), em polegadas.
- sk: amplitude do crânio, em polegadas.
- kl: comprimento da quilha do esterno, em polegadas.

Análise Multivariada - 2017

22

• Questões interessantes:

1. Como as variáveis estão relacionadas?
(Um valor grande de uma variável tende a ocorrer com valores grandes para as outras variáveis?)
2. Os sobreviventes e os não sobreviventes têm diferenças estatisticamente significativas para seus valores médios das variáveis?
3. Os sobreviventes e os não sobreviventes mostram quantidades similares de variação para a variável?
4. Se os sobreviventes e não sobreviventes diferem em termos das distribuições das variáveis, então é possível construir alguma função dessas variáveis que separe os dois grupos?
(Índice de ajuste Darwiano dos pardais: valores grandes da função tendem a ocorrer com os sobreviventes)

Análise Multivariada - 2017

23

• Conclusão de Bumpus (1898):

- √ Os sobreviventes são mais curtos e pesam menos, tem ossos das asas mais longos, pernas mais longas, esternos mais longos e maior capacidade cerebral
- O processo de eliminação seletiva é mais severo com indivíduos extremamente variáveis (independente da direção)
 - √ É tão perigoso estar acima de um certo padrão de excelência orgânica como estar visivelmente abaixo desse padrão

Análise Multivariada - 2017

24

Conjunto de Dados #2

- Thomson e Randall-Maciver (1905)
- Medidas em crânios masculinos da área de Tebas
 - √ 5 amostras de 30 crânios cada uma:
 - Período pré-dinástico primitivo (~ 4.000 aC)
 - Período pré-dinástico antigo (~3.300 aC)
 - 12ª e 13ª dinastias (~ 1.850 aC)
 - Período Ptolemaico (~ 200 aC)
 - Período romano (~150 dC)
 - √ Dados: *skulls{ade4}* ou *skulls2.csv* (*skulls.txt*)

Análise Multivariada- 2017

25

• Variáveis:

- √ MB (X_1): Largura máxima do crânio
- √ BH (X_2): Altura do basibregmático do crânio
- √ BL (X_3): Comprimento do basalveolar do crânio
- √ NH (X_4): Altura nasal do crânio
- √ Ano: Ano aproximado de formação do crânio

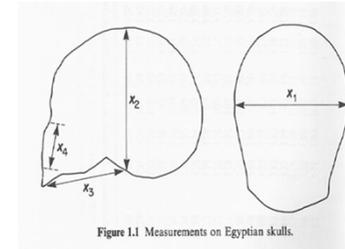


Figure 1.1 Measurements on Egyptian skulls.

Análise Multivariada- 2017

26

• Questões interessantes:

1. Como estão relacionadas as quatro medidas?
2. Existem diferenças estatisticamente significantes nas médias amostrais das variáveis?
 - Elas refletem mudanças graduais ao longo do tempo na forma e no tamanho dos crânios?
3. Existem diferenças significantes nos desvios-padrão para as variáveis?
 - Elas refletem mudanças ao longo do tempo na quantidade de variação?
4. É possível construir uma função das quatro variáveis que, em algum sentido, descreva as mudanças ao longo do tempo?

Análise Multivariada- 2017

27

• Conclusão de Thomson e Randall-Maciver (1905):

- √ Há diferenças entre as cinco amostras que podem ser explicadas parcialmente como tendências no tempo.
- √ As razões para as aparentes mudanças são desconhecidas
- √ A migração de outras raças dentro da região pode ter sido o fator mais importante.

Análise Multivariada- 2017

28

Conjunto de Dados #3

- McKechnie et al. (1975)
- Distribuição de uma borboleta:
 - √ 16 colônias de borboletas *Euphydryas editha* na Califórnia e Oregon
- Dados: `butterfly{ade4}`

Análise Multivariada- 2017

29

- Variáveis ambientais (`butterfly$envir`):
 - √ Altitude, em pés
 - √ Precipitation: precipitação anual, em polegadas
 - √ Temp_max: temperatura máxima, em °F
 - √ Temp_min: temperatura mínima, em °F
- Variáveis genéticas: (`butterfly$genet`):
 - √ Frequências de mobilidade gênica *Fósforo Glucose-Isomerase (Pgi)* para colônias de borboletas
 - Níveis: 0,4; 0,6; 0,8; 1; 1,16; 1,3
 (representa diferentes tipos genéticos de Pgi de modo que as frequências para uma colônia (somando a 100%) mostram as frequências do diferentes tipos para a *E. editha* naquele local)

Análise Multivariada- 2017

30

- Dados agregados:
 - √ Variáveis ambientais e genéticas

```
> borboleta <- cbind(butterfly$envir, butterfly$genet)
> borboleta
```

	Altitude	Precipitation	Temp_Max	Temp_Min	0.4	0.6	0.8	1	1.16	1.3
SS	500	43	98	17	0	3	22	57	17	1
SB	800	20	92	32	0	16	20	38	13	13
WSB	570	28	98	26	0	6	28	46	17	3
JRC	550	28	98	26	0	4	19	47	27	3
JRH	550	28	98	26	0	1	8	50	35	6
SJ	380	15	99	28	0	2	19	44	32	3
CR	930	21	99	28	0	0	15	50	27	8
UO	650	10	101	27	10	21	40	25	4	0
LO	600	10	101	27	14	26	32	28	0	0
DP	1500	19	99	23	0	1	6	80	12	1
PZ	1750	22	101	27	1	4	34	33	22	6
MC	2000	58	100	18	0	7	14	66	13	0
IF	2500	34	102	16	0	9	15	47	21	8
AF	2000	21	105	20	3	7	17	32	27	14
GH	7850	42	84	5	0	5	7	84	4	0
GL	10500	50	81	-12	0	3	1	92	4	0

Análise Multivariada- 2017

31

- Rótulos das linhas: Local das colônias
 - √ SS (Oregon), SB, WSB, JRC, JRH, SJ, CR, UO, LO, DP, PZ, MC, IF, AF, GH, GL.



Figure 1.2 Colonies of *Euphydryas editha* in California and Oregon.

Fonte: Manly, 2005

Análise Multivariada- 2017

32

- Questões interessantes:

- √ As frequências Pgi são similares para as colônias espacialmente próximas?
- √ O quanto, se algum, as frequências Pgi estão relacionadas às variáveis ambientais?

Análise Multivariada- 2017

33

- Análise das respostas:

- √ Se a composição genética das colônias foi fortemente determinada pelas migrações passadas e presentes
 - Frequências gênicas tenderão a ser similares para colônias que estão localizadas nas proximidades
- √ Se o meio ambiente é mais importante
 - Deve aparecer relacionamento entre as frequências gênicas e as variáveis ambientais
 - Colônias próximas têm frequências gênicas similares somente se têm ambientes similares)
 - Pode ser difícil chegar a essa conclusão

Análise Multivariada- 2017

34

Conjunto de Dados #4

- Coleção de ossos caninos do período em torno de 3.500 aC até o presente
 - √ Local: Tailândia
- A origem dos cães pré-históricos é incerta
 - √ Podem descender dos chacais dourados (*canis aureus*) ou do lobo (não é nativo da Tailândia)
- Fontes de origem mais próximas:
 - √ Parte ocidental da China: *canis lupus chanco*
 - √ Subcontinente indiano: *canis lupus pallides*
- Dados: *canine.txt*

Análise Multivariada- 2017

35

- Higham et al. (1980)

- Objetivo do estudo:

- √ Comparar medidas da mandíbula dos espécimes pré-históricos disponíveis com as mesmas medidas no chagal dourado, lobo chinês, lobo indiano, dingo (originário da Índia), cuon: *cuon alpinus* (originário do Sudeste da Ásia) e cães modernos da Tailândia.

Análise Multivariada- 2017

36

- Variáveis:

- √ X_1 : comprimento da mandíbula, em mm.
- √ X_2 : largura da mandíbula, em mm.
- √ X_3 : largura do côndilo da mandíbula, em mm.
- √ X_4 : altura da mandíbula abaixo do 1º molar, em mm.
- √ X_5 : comprimento do 1º molar, em mm.
- √ X_6 : largura do 1º molar, em mm.
- √ X_7 : comprimento do 1º ao 3º molar, em mm.
- √ X_8 : comprimento do 1º ao 4º molar, em mm.
- √ X_9 : largura do maxilar inferior, em mm.

Análise Multivariada- 2017

37

- Questões interessantes:

1. O que as medidas sugerem sobre o relacionamento entre os grupos?
2. Como os cães pré-históricos parecem se relacionar com os outros grupos?

Análise Multivariada- 2017

38

Conjunto de Dados #5

- Porcentagem da força de trabalho em nove diferentes tipos de indústrias para 30 países europeus
 - √ De 1980 a 1995
- Dados:

Análise Multivariada- 2017

39

- Objetivo do estudo:

- √ Isolar grupos de países com padrões similares
- √ Auxiliar o entendimento dos relacionamentos entre países
- Cada linha do conjunto de dados soma 100%

Análise Multivariada- 2017

40

- Variáveis:

- √ Group: Eastern= Leste europeu; EFTA: área europeia de livre comércio; EU: União Europeia; Other: outros países
- √ AGR: agricultura, floresta e pesca
- √ MIN: mineração e exploração de pedreiras
- √ MAN: fabricação
- √ PS: fornecimento de energia elétrica
- √ CON: construção
- √ SER: serviços
- √ FIN: finanças
- √ SPS: serviços sociais e pessoais
- √ TC: transportes e comunicações

Análise Multivariada- 2017

41

- Questões:

1. É possível isolar grupos de países com padrões similares de emprego?
2. Qual o relacionamento entre os países com relação aos níveis de emprego?
 - Podem ser de interesse diferenças entre países que estejam relacionadas a grupos políticos (União Europeia; área europeia de livre comércio; países do leste europeu e outros países)

Análise Multivariada- 2017

42

Conjunto de Dados #6

- Estudo de poluição do ar em 41 cidades dos EUA
 - √ Ano: 1970
- Dados: *Usairpollution*{MVA}

Análise Multivariada- 2017

43

- Variáveis:

- √ SO2: conteúdo de dióxido de enxofre no ar, em $\mu\text{g}/\text{m}^3$.
- √ temp: temperatura média anual (°F)
- √ manu: quantidade de empresas manufatureiras empregando pelo menos 20 empregados.
- √ popul: população (censo 1970), em milhares.
- √ wind: velocidade média anual de vento, em milhas/h
- √ precip: precipitação média anual, em polegadas
- √ predays: número médio anual de dias com precipitação

Análise Multivariada- 2017

44

- Questões:

- √ Como o nível de poluição, medido pela concentração de dióxido de enxofre está relacionado com as outras seis variáveis?
- √ Como reduzir a quantidade de variáveis que descrevem as cidades, simplificando os dados?
- √ É possível encontrar variáveis latentes que descrevam as cidades?

Análise Multivariada- 2017

45

Técnicas em Estatística Multivariada

- Técnicas Exploratórias:

- √ Sintetização da estrutura de variabilidade dos dados
 - Análise de componentes principais, análise fatorial, análise de correlações canônicas, análise de agrupamentos, análise discriminante

- √ Técnicas de Inferência Estatística:

- Métodos de estimação de parâmetros, testes de hipóteses, análise de variância, análise de covariância, análise de regressão multivariada

Análise Multivariada- 2017

46

Visão dos Métodos Multivariados

- Análise de componentes principais:

- √ Redução do número de variáveis a um número menor de índices (componentes principais)
 - Componentes principais: combinações lineares das variáveis originais
- √ Pode acontecer de que duas ou mais componentes principais forneçam um bom resumo de todas as variáveis originais

Análise Multivariada- 2017

47

- Exemplo – Pardais sobreviventes

- √ Muito da variação nas medidas do corpo dos pardais (X_1 a X_5) está relacionada com:

- Tamanho geral dos pássaros (I_1)

$$I_1 = k_1X_1 + k_2X_2 + k_3X_3 + k_4X_4 + k_5X_5$$

- Contraste entre as três primeiras medidas e as duas últimas

$$I_2 = k^*_1X_1 + k^*_2X_2 + k^*_3X_3 - k^*_4X_4 - k^*_5X_5$$

- √ Análise de componentes principais:

- Maneira de simplificar os dados, reduzindo o número de variáveis

Análise Multivariada- 2017

48

• **Análise fatorial:**

- √ Estudar a variação em uma quantidade de variáveis originais, usando um número menor de fatores (variáveis índices)
- √ Assume-se que cada variável original pode ser expressa como uma combinação linear dos fatores mais um termo residual (reflete quanto a variável é independente das outras variáveis)

Análise Multivariada- 2017

49

• **Modelo:**

$$\begin{aligned}
 X_1 &= a_{11}F_1 + a_{12}F_2 + \epsilon_1, \\
 X_2 &= a_{21}F_1 + a_{22}F_2 + \epsilon_2, \\
 X_3 &= a_{31}F_1 + a_{32}F_3 + \epsilon_3, \\
 X_4 &= a_{41}F_1 + a_{42}F_4 + \epsilon_4, \\
 X_5 &= a_{51}F_1 + a_{52}F_5 + \epsilon_5.
 \end{aligned}$$

a_{ij} : constantes

$F_1; F_2$: fatores

ϵ_i : variação em X_i que é independente da variação nas outras variáveis

√ F_1 : fator tamanho

- Alguns pássaros tendem a ser grandes, alguns pássaros tendem a ser pequenos, em todas as medidas do corpo

√ F_2 : mede algum aspecto da forma dos pássaros

- Alguns coeficientes positivos e alguns negativos

Análise Multivariada- 2017

50

• **Análise discriminante:**

- √ Separação em diferentes grupos com base nas medidas disponíveis
- √ Encontrar combinações lineares convenientes das variáveis originais para atingir o objetivo desejado
- √ Exemplo:
 - Quão bem os pardais sobreviventes e não sobreviventes podem ser separados usando suas medidas do corpo?

Análise Multivariada- 2017

51

• **Análise de agrupamento:**

√ Identificação de grupos de objetos similares

√ Exemplos:

1. Encontrar similaridades entre cães pré-históricos tailandeses e outros animais
2. Agrupar os países europeus em termos de suas similaridade no padrão de empregos.

Análise Multivariada- 2017

52

- Escalonamento multidimensional:

- √ Mapeamento, com distância, entre objetos, mostrando como eles estão relacionados

- √ Visualização possível em até três dimensões

- √ Alternativa para a análise de agrupamentos

- √ Exemplos:

1. Encontrar similaridades entre cães pré-históricos tailandeses e outros animais
2. Agrupar os países europeus em termos de suas similaridade no padrão de empregos.

Análise Multivariada- 2017

53

- Métodos de ordenação:

- √ Produção de eixos nos quais um conjunto de objetos de interesse pode ser representado

- √ Algumas técnicas de ordenação:

- Análise de componentes principais
- Escalonamento multidimensional

Análise Multivariada- 2017

54

- Análise de correlação canônica:

- √ As variáveis (não os objetos) são divididos em dois grupos e o interesse está centrado no relacionamento entre elas

- √ Exemplo – Colônias de borboleta:

- Encontrar relacionamento entre as variáveis ambientais e as variáveis genéticas.

Análise Multivariada- 2017

55

- Análise de correspondência:

- √ Dados sobre a abundância de cada uma das várias características para cada elemento de um conjunto de objetos

- √ Exemplo – Ecologia:

- Objetos de interesse: diferentes locais
- Características: diferentes espécies
- Dados: abundância de espécies em locais
- Objetivo: tornar claro os relacionamentos entre locais (expressos por distribuições das espécies) e os relacionamentos entre as espécies (expressos por distribuições dos locais).

Análise Multivariada- 2017

56

Usos das Técnicas Multivariadas

- Construção de índices:

- √ Sintetizar em uma única variável a informação de todas as variáveis que foram medidas sobre o fenômeno
 - Análise de componentes principais
 - Análise fatorial
 - Análise de correlação canônica

Análise Multivariada- 2017

57

- Classificação e discriminação:

- √ Busca-se a divisão de conjunto de dados em grupos, de modo que os grupos tenham coesão interna e sejam heterogêneos entre si
 - Análise de agrupamentos (segmentação de mercado)
 - Análise discriminante (classificação de crédito)

Análise Multivariada- 2017

58

- Inferência estatística:

- √ Comparação de grupos em relação às médias de variáveis medidas conjuntamente
- √ Regressão multivariada:
 - Análise do efeito de fatores externos não controlados nas variáveis que são monitoradas regularmente

Análise Multivariada- 2017

59

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.