

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 - 2015

2

Introdução

Distribuição Normal Multivariada

Normal Multivariada

- Suponha que tenhamos p variáveis X_1, X_2, \dots, X_p
 - ✓ Vetor de componentes $\mathbf{X}' = [X_1, X_2, \dots, X_p]$.
 - ✓ Vetor de médias: $\boldsymbol{\mu}' = [\mu_1, \mu_2, \dots, \mu_p]$.
 - ✓ Matriz de variâncias e covariâncias
- $$\Sigma_X = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{12} & \sigma_{22} & \cdots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1p} & \sigma_{2p} & \cdots & \sigma_{pp} \end{bmatrix}.$$
- ✓ Variância da variável aleatória X_i : $\text{Var}(X_i) = \sigma_{ii} = \sigma_i^2$
 - ✓ Covariância entre Variáveis X_i e X_j : $\text{Covar}(X_i, X_j) = \sigma_{ij}$

Análise Multivariada - 2015

6

Função de Densidade de Probabilidade

- Distribuição Normal Univariada:

$$f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}$$

distância quadrática
padronizada

- Distribuição Normal Multivariada:

$$f_{\mathbf{X}}(\mathbf{x}) = \frac{1}{(2\pi)^{p/2}|\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})'\Sigma^{-1}(\mathbf{x}-\boldsymbol{\mu})\right\}$$

Padronização volume
sob superfície

distância generalizada
quadrática padronizada

Análise Multivariada - 2015

7

- ✓ Distância de Mahalanobis do vetor \mathbf{x} ao vetor de média $\boldsymbol{\mu}$.

$$(\mathbf{x} - \boldsymbol{\mu})'\Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu})$$

- Distância padronizada ou distância estatística

- ✓ Função de densidade da normal p -variada pode ser expressa como:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}) &= k \exp\left\{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})'\left(\sum_{i=1}^p \frac{1}{\lambda_i} \mathbf{e}_i \mathbf{e}_i'\right)(\mathbf{x}-\boldsymbol{\mu})\right\} \\ &= k \exp\left\{-\frac{1}{2} \sum_{i=1}^p \frac{1}{\lambda_i} [\mathbf{e}_i'(\mathbf{x}-\boldsymbol{\mu})]^2\right\} \end{aligned}$$

Análise Multivariada - 2015

8

- ✓ Função de densidade da normal p -variada pode ser expressa como:

$$\begin{aligned} f_{\mathbf{X}}(\mathbf{x}) &= k \exp\left\{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})'\left(\sum_{i=1}^p \frac{1}{\lambda_i} \mathbf{e}_i \mathbf{e}_i'\right)(\mathbf{x}-\boldsymbol{\mu})\right\} \\ &= k \exp\left\{-\frac{1}{2} \sum_{i=1}^p \frac{1}{\lambda_i} [\mathbf{e}_i'(\mathbf{x}-\boldsymbol{\mu})]^2\right\} \end{aligned}$$

- onde $k = \frac{1}{(2\pi)^{p/2}|\Sigma|^{1/2}}$

Análise Multivariada - 2015

9

- ✓ Função de densidade da normal p-variada pode ser expressa como:

$$f_{\mathbf{x}}(\mathbf{x}) = k \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})' \left(\sum_{i=1}^p \frac{1}{\lambda_i} \mathbf{e}_i \mathbf{e}_i' \right) (\mathbf{x} - \boldsymbol{\mu}) \right\}$$

$$= k \exp \left\{ -\frac{1}{2} \sum_{i=1}^p \frac{1}{\lambda_i} \mathbf{e}_i' (\mathbf{x} - \boldsymbol{\mu})^2 \right\}$$

- onde $k = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}}$

Análise Multivariada - 2015

10

- ✓ Para todos os vetores \mathbf{x} e para C constante, tais que

$$C^2 = (\mathbf{x} - \boldsymbol{\mu})' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu}) = \sum_{i=1}^p \frac{1}{\lambda_i} [\mathbf{e}_i' (\mathbf{x} - \boldsymbol{\mu})]^2$$

- ✓ A função de densidade assume o mesmo valor numérico

- ✓ Curva de mesma densidade tem formato de elipsóide

- Eixo principal: direção correspondente à variável de maior variabilidade
- (maior autovalor)
- Segundo eixo: relacionado com a variável de segunda maior variância
- (segundo auto valor e assim por diante)

Análise Multivariada - 2015

11


Normal Bivariada

- Função de densidade de probabilidade ($p=2$)

$$f_{X_1, X_2}(x_1, x_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho_{12}^2}} \exp \left\{ -\frac{1}{2(1-\rho_{12}^2)} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 - 2\rho_{12} \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right] \right\}$$


 $f(\mathbf{x})$

A presença de correlação causa concentração da probabilidade ao longo de uma linha



12

- Curvas de nível de uma normal bivariada



✓ Maior semi-eixo: $\frac{C}{\sqrt{\lambda_1}}$

✓ Menor semi-eixo: $\frac{C}{\sqrt{\lambda_2}}$

Análise Multivariada - 2015

14

- Variáveis não correlacionadas ($\rho_{12} = 0$)


$$\begin{aligned}
 f_{X_1, X_2}(x_1, x_2) &= \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho_{12}^2}} \exp \left\{ -\frac{1}{2(1-\rho_{12}^2)} \left[\left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 + \right. \right. \\
 &\quad \left. \left. + \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 - 2\rho_{12} \left(\frac{x_1 - \mu_1}{\sigma_1} \right) \left(\frac{x_2 - \mu_2}{\sigma_2} \right) \right] \right\} \\
 &= \frac{1}{\sqrt{2\pi}\sigma_1} \exp \left\{ -\frac{1}{2} \left(\frac{x_1 - \mu_1}{\sigma_1} \right)^2 \right\} \\
 &\quad \times \frac{1}{\sqrt{2\pi}\sigma_2} \exp \left\{ -\frac{1}{2} \left(\frac{x_2 - \mu_2}{\sigma_2} \right)^2 \right\} \\
 &= f_{X_1}(x_1)f_{X_2}(x_2)
 \end{aligned}$$

✓ X_1 e X_2 serão independentes se elas forem não correlacionadas

Análise Multivariada - 2015

15


- X_1 e X_2 independentes



Análise Multivariada - 2015

16

- $\text{Corr}(X_1, X_2) = 0,8$




✓ A presença de correlação causa concentração da probabilidade ao longo de uma linha

Análise Multivariada - 2015

17

Efeito Correlação



Análise Multivariada - 2015

19

- Variância generalizada – Normal bivariada

$$|\Sigma| = \sigma_{11}\sigma_{22}(1 - \rho^2)$$

- ✓ À medida que ρ tende a zero a superfície fica mais dispersa em torno da média
(variância generalizada maior)
- ✓ Quanto maior o valor de $|\rho|$ menor será a variância generalizada

Propriedades da Normal Multivariada

Seja o vetor aleatório $\mathbf{X} \sim \text{Normal p-variada}$

- ✓ Se $\text{cov}(X_1, X_2) = 0$, então X_1 e X_2 são independentes
- ✓ As densidades marginais são normais
 $X_i \sim N(\mu_i, \sigma_{ii})$
- ✓ As combinações lineares construídas com componentes de \mathbf{X} são normais
- ✓ Qualquer conjunto de k variáveis de \mathbf{X} , $k < p$, tem distribuição normal k -variada

- ✓ As distribuições condicionais envolvendo subconjuntos de variáveis aleatórias de \mathbf{X} são normais
- ✓ Combinações lineares de vetores aleatórios que tenham distribuição normal multivariada também são normalmente distribuídas

Verificação da Hipótese de Normalidade

Métodos de Verificação – Normal Multivariada

- Análise das distribuições univariadas e bivariadas auxiliam na verificação da suposição de normalidade p-variada
 - ✓ Demonstrar que distribuições univariadas e bivariadas são normais não implica que o vetor aleatório seja normal multivariado
 - ✓ Na prática, é muito grande a chance de o vetor ser normal, quando as distribuições normais e bivariadas são normais

28

Análise Multivariada - 2015

Distribuições Univariadas – Verificação da Normalidade

- Avaliação gráfica
 - ✓ Verificação de simetria
 - Histograma ($n > 25$)
 - Gráfico de pontos (n pequenos)
 - ✓ Gráficos de probabilidade normal
- Testes de hipóteses
 - ✓ Ryan-Jones
 - ✓ Shapiro-Wilk
 - ✓ Anderson-Darling

29

Análise Multivariada - 2015


Gráficos de Probabilidade Normal

- ✓ Pontos próximos da reta indicam que a hipótese de normalidade permanece defensável
 - Há muita variabilidade na linearidade para amostras pequenas.
 - Em geral, não são informativos a menos que o tamanho amostral seja moderadamente grande ($n \geq 20$)
 - Linearidade do gráfico de probabilidade pode ser medida pelo coeficiente de correlação entre os pontos
- ✓ Padrões de desvio podem fornecer pistas sobre a natureza da não normalidade

30

Análise Multivariada - 2015

- Gráfico de probabilidades normal dos dados:



- ✓ Ser mais influenciado pelos pontos do meio que pelos dos extremos
- ✓ Eixo y com escala de probabilidades (escala z)

31

Análise Multivariada - 2015


Gráfico de Probabilidades Normal

- Pode ser útil na identificação de distribuições que sejam simétricas mas que tenham caudas mais pesadas (ou mais leves) que a normal

Análise Multivariada - 2015

32


- Distribuição de cauda leve



- ✓ Pontos à esquerda tendem a ficar abaixo da linha e à direita tendem a ficar acima
 - As menores e maiores observações não serão tão extremas como se esperaria de uma normal

33

- Distribuição de cauda pesada




- ✓ Pontos à esquerda tendem a ficar acima da linha e à direita tendem a ficar abaixo

- ✓ Gráfico em forma de S

Análise Multivariada - 2015

34

- Distribuição assimétrica



- ✓ Pontos de ambas as extremidades tendem a estar abaixo da linha

- ✓ Gráfico tem forma curvada

Análise Multivariada - 2015

35

Distribuições Bivariadas – Verificação da Normalidade

- Diagrama de dispersão de pares de variáveis:
 - ✓ Observações provenientes de normal multivariada:
 - cada distribuição bivariada será normal
 - plot dos pontos bivariados observados devem exibir padrão global aproximadamente elíptico

Análise Multivariada - 2015

37

Distâncias Quadráticas Generalizadas

- Método mais formal para julgar a normalidade
 - ✓ Distância estatística de cada ponto amostral ao centróide de todas as observações
- $$d_j^2 = (\mathbf{x}_j - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x}_j - \bar{\mathbf{x}}), \quad j = 1, 2, \dots, n.$$
- ✓ Pode ser usada para $p \geq 2$
 - ✓ $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$: observações amostrais

Análise Multivariada - 2015

38

- Se população for normal multivariada e n e $(n - p)$ forem suficientemente grandes
 - ✓ Cada uma das distâncias quadráticas deveria se comportar como uma variável aleatória χ^2
 - ✓ Embora essas distâncias não sejam independentes ou exatamente distribuídas como uma χ^2 é útil plotá-las como se fossem

Análise Multivariada - 2015

39

Q-Q Plot

- Procedimento:
 - ✓ Ordenar as distâncias quadráticas:
 - $d_{(1)}^2 \leq d_{(2)}^2 \leq \dots \leq d_{(n)}^2 \leq$
 - ✓ Plotar os pares $(q_{c,p}((j - 1/2)/n), d(j)^2)$
 - ✓ $q_{c,p}((j - 1/2)/n)$ é o $100(j - 1/2)/n$ percentil superior de uma χ^2_p
- Em um gráfico de χ^2 os pontos deveriam estar próximos da linha reta

Análise Multivariada - 2015

40

- Gráfico de χ^2

✓ Distâncias quadráticas generalizadas

$$d_j^2 = (\mathbf{x} - \bar{\mathbf{x}})' \mathbf{S}^{-1} (\mathbf{x} - \bar{\mathbf{x}})$$

✓ Os pontos d_j^2 de uma normal p-variada tem distribuição χ^2_p

– Para amostras grandes

✓ Em um gráfico de χ^2 os pontos deveriam estar próximos da linha reta

Análise Multivariada - 2015

41

Exemplo

- Estudo poluição do ar

✓ Amostra: 41 cidades americanas

✓ Variáveis:

- SO2: concentração no ar (mg/m3)

- Temp: temperatura

- Popul: população, em milhares (censo 1970)

- Vento: velocidade média anual (milhas/hora)

- Precip: precipitação média anual (pol)


- Dias: número médio anual de dias de chuva

✓ Conjunto de dados: USairpollution {HSAUR2 }

Análise Multivariada - 2015

50

- Histogramas das variáveis (univariada)



✓ SO2 e Precipitação:

- Forte assimetria


✓ Indústrias e População:

- Indícios de outliers

Análise Multivariada - 2015

52

- Gráficos de probabilidade univariados



Análise Multivariada - 2015

53

- Teste de normalidade

- ✓ H_0 : dados se ajustam à distribuição normal
- ✓ H_1 : dados não se ajustam à distribuição normal


```
> teste<- sapply(colnames(dados), function(x) shapiro.test(dados[[x]])$p.value)
> as.matrix(teste)
[,1]
SO2 9.723376e-06
Temp 2.214972e-02
Indust 2.781101e-09
Pop 3.622798e-08
Vento 6.972580e-01
Precip 3.725311e-02
Dias 2.419457e-01
```

- ✓ Não se rejeita a hipótese de normalidade para as variáveis Vento e Dias

Análise Multivariada - 2015

54

- Diagramas de dispersão (bivariada)



Análise Multivariada - 2015

55


- ✓ SO2 e Precipitação:

- Formato não elíptico

- ✓ Indústrias e População:

- Indício de formação elíptica

- Gráfico das distâncias generalizadas (χ^2):



- ✓ Gráfico detectou possíveis outliers nos dados multivariados
 - Desvio da variabilidade natural dos dados

Análise Multivariada - 2015

57

Comentários

- É difícil construir um bom teste global de normalidade conjunta em mais de duas dimensões
- Hipótese de normalidade aparenta estar violada
 - ✓ As marginais aparentam ser normais? E a algumas combinações lineares de componentes X_i ?
 - ✓ Diagramas de dispersão de diferentes características têm aparência elíptica?
 - ✓ Há outliers que devessem ser verificados?

Análise Multivariada - 2015

58

- Hipótese de normalidade individual é menos crucial em situações em que o tamanho amostral é grande e as técnicas dependem da média amostral (ou de distâncias envolvendo essa média)

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.