

ME731 - Métodos em Análise Multivariada – Análise Fatorial II –

Prof. Carlos Trucíos
ctrucios@unicamp.br
ctruciosm.github.io

Instituto de Matemática, Estatística e Computação Científica,
Universidade Estadual de Campinas



Aula 14

Agenda I

- 1 Introdução
- 2 Análise Fatorial vía Componentes Principais
- 3 Máxima Versossimilhança
- 4 Rotação

Introdução

Introdução

O objetivo da análise fatorial (AF) é explicar as p variáveis no conjunto de dados utilizando k fatores ($k \ll p$).

Introdução

Definição

Seja $\mathbf{X} \sim (\mu, \Sigma)$ um vetor aleatório p -dimensional. O modelo k -fatorial de \mathbf{X} é dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u},$$

em que o vetor aleatório $\mathbf{F} \in \mathbb{R}^k$ é chamado de *fator comum*, $\Lambda_{p \times k}$ são as *cargas fatoriais* e o vetor aleatório $\mathbf{u} \in \mathbb{R}^p$ é chamado de *fator específico* ou *fator idiossincrático*.

- $\mathbf{F} \sim (0, \mathbf{I})$.
- $\mathbf{u} \sim (0, \Psi)$, $\Psi = \text{Diag}\{\psi_{11}, \dots, \psi_{pp}\}$.
- $\text{Cov}(\mathbf{F}, \mathbf{u}) = 0$.

Introdução

Definição

Seja $\mathbf{X} \sim (\mu, \Sigma)$ um vetor aleatório p -dimensional. O modelo k -fatorial de \mathbf{X} é dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u},$$

em que o vetor aleatório $\mathbf{F} \in \mathbb{R}^k$ é chamado de *fator comum*, $\Lambda_{p \times k}$ são as *cargas fatoriais* e o vetor aleatório $\mathbf{u} \in \mathbb{R}^p$ é chamado de *fator específico* ou *fator idiossincrático*.

- $\mathbf{F} \sim (0, \mathbf{I})$.
- $\mathbf{u} \sim (0, \mathbf{\Psi})$, $\mathbf{\Psi} = \text{Diag}\{\psi_{11}, \dots, \psi_{pp}\}$.
- $\text{Cov}(\mathbf{F}, \mathbf{u}) = 0$.

Alguns preferem chamar o modelo acima de *Modelo Fatorial Ortogonal*, aqui utilizaremos apenas *Modelo Fatorial*. color{black}

Introdução

$$\mathbf{X} = \boldsymbol{\mu} + \boldsymbol{\Lambda}\mathbf{F} + \mathbf{u}$$

implica que,

$$X_j = \mu_j + \sum_{l=1}^k \lambda_{jl} F_l + u_j, \quad j = 1, \dots, p.$$

Introdução

$$\mathbf{X} = \boldsymbol{\mu} + \boldsymbol{\Lambda}\mathbf{F} + \mathbf{u}$$

implica que,

$$X_j = \mu_j + \sum_{l=1}^k \lambda_{jl} F_l + u_j, \quad j = 1, \dots, p.$$

Então,

$$\mathbb{V}(X_j) = \underbrace{\sum_{l=1}^k \lambda_{jl}^2}_{h_j^2} + \psi_{jj} \quad \text{e} \quad \boldsymbol{\Sigma} = \boldsymbol{\Lambda}\boldsymbol{\Lambda}' + \boldsymbol{\Psi}.$$

O modelo fatorial explica a maior parte da variação de \mathbf{X} através de apenas k fatores. Esses fatores explicam completamente a correlação de \mathbf{X} .

Análise Fatorial vía Componentes Principais

Análise Fatorial via Componentes Principais

Seja $\mathbf{X} \sim (\mu, \Sigma)$ e seja o modelo k -fatorial dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u}.$$

Análise Fatorial via Componentes Principais

Seja $\mathbf{X} \sim (\mu, \Sigma)$ e seja o modelo k -fatorial dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u}.$$

sem perda de generalidade, assumiremos que $\mu = 0$.

Análise Fatorial via Componentes Principais

Seja $\mathbf{X} \sim (\mu, \Sigma)$ e seja o modelo k -fatorial dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u}.$$

sem perda de generalidade, assumiremos que $\mu = 0$. Utilizando ACP temos que as componentes principais são dadas por

$$\mathbf{Z} = \mathbf{P}'\mathbf{X},$$

em que \mathbf{P} é obtido através de $\Sigma = \mathbf{P}\mathbf{D}\mathbf{P}'$.

Análise Fatorial via Componentes Principais

Seja $\mathbf{X} \sim (\mu, \Sigma)$ e seja o modelo k -fatorial dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u}.$$

sem perda de generalidade, assumiremos que $\mu = 0$. Utilizando ACP temos que as componentes principais são dadas por

$$\mathbf{Z} = \mathbf{P}'\mathbf{X},$$

em que \mathbf{P} é obtido através de $\Sigma = \mathbf{P}\mathbf{D}\mathbf{P}'$.

Premultiplicado ambos os lados por \mathbf{P} , $\mathbf{P}\mathbf{Z} = \underbrace{\mathbf{P}\mathbf{P}'}_{\mathbf{I}}\mathbf{X} = \mathbf{X}$

Análise Fatorial via Componentes Principais

Seja $\mathbf{X} \sim (\mu, \Sigma)$ e seja o modelo k -fatorial dado por

$$\mathbf{X} = \mu + \Lambda \mathbf{F} + \mathbf{u}.$$

sem perda de generalidade, assumiremos que $\mu = 0$. Utilizando ACP temos que as componentes principais são dadas por

$$\mathbf{Z} = \mathbf{P}'\mathbf{X},$$

em que \mathbf{P} é obtido através de $\Sigma = \mathbf{P}\mathbf{D}\mathbf{P}'$.

Premultiplicado ambos os lados por \mathbf{P} , $\mathbf{PZ} = \underbrace{\mathbf{PP}'}_{\mathbf{I}}\mathbf{X} = \mathbf{X}$

$$\mathbf{X} = \mathbf{PZ} = \mathbf{P}\mathbf{D}^{1/2}\mathbf{D}^{-1/2}\mathbf{Z} = \underbrace{\mathbf{P}\mathbf{D}^{1/2}}_{\Lambda}\underbrace{\mathbf{D}^{-1/2}\mathbf{P}'\mathbf{X}}_{\mathbf{F}} \quad (1)$$

Análise Fatorial via Componentes Principais

O resultado em (1), embora correto, não é muito útil na prática pois temos tantos fatores quanto variáveis.

Análise Fatorial via Componentes Principais

O resultado em (1), embora correto, não é muito útil na prática pois temos tantos fatores quanto variáveis.

Se fizermos $\Lambda = [\Lambda_1 \quad \Lambda_2]$ e $\mathbf{F} = \begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \end{bmatrix}$, podemos reescrever (1) como:

Análise Fatorial via Componentes Principais

O resultado em (1), embora correto, não é muito útil na prática pois temos tantos fatores quanto variáveis.

Se fizermos $\Lambda = [\Lambda_1 \quad \Lambda_2]$ e $\mathbf{F} = \begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \end{bmatrix}$, podemos reescrever (1) como:

$$\mathbf{X}_{p \times 1} = \Lambda_{p \times p} \mathbf{F}_{p \times 1} = [\Lambda_1 \quad \Lambda_2] \times \begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \end{bmatrix} = \underbrace{\Lambda_1}_{p \times k} \underbrace{\mathbf{F}_1}_{k \times 1} + \underbrace{\Lambda_2 \mathbf{F}_2}_{\mathbf{u}} \quad (2)$$

Análise Fatorial via Componentes Principais

O resultado em (1), embora correto, não é muito útil na prática pois temos tantos fatores quanto variáveis.

Se fizermos $\Lambda = [\Lambda_1 \quad \Lambda_2]$ e $\mathbf{F} = \begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \end{bmatrix}$, podemos reescrever (1) como:

$$\mathbf{X}_{p \times 1} = \Lambda_{p \times p} \mathbf{F}_{p \times 1} = [\Lambda_1 \quad \Lambda_2] \times \begin{bmatrix} \mathbf{F}_1 \\ \mathbf{F}_2 \end{bmatrix} = \underbrace{\Lambda_1}_{p \times k} \underbrace{\mathbf{F}_1}_{k \times 1} + \underbrace{\Lambda_2 \mathbf{F}_2}_{\mathbf{u}} \quad (2)$$

Mas quem são Λ_1 e \mathbf{F}_1 em termos de \mathbf{X} , \mathbf{P} e \mathbf{D} ?

Análise Fatorial via Componentes Principais

Se fizermos $\mathbf{P} = [\mathbf{P}_1 \quad \mathbf{P}_2]$ e $\mathbf{D} = \begin{bmatrix} \mathbf{D}_1 & 0 \\ 0 & \mathbf{D}_2 \end{bmatrix}$, temos que:

Análise Fatorial via Componentes Principais

Se fizermos $\mathbf{P} = [\mathbf{P}_1 \quad \mathbf{P}_2]$ e $\mathbf{D} = \begin{bmatrix} \mathbf{D}_1 & 0 \\ 0 & \mathbf{D}_2 \end{bmatrix}$, temos que:

- $\mathbf{Z} = \mathbf{P}'\mathbf{X} = \begin{bmatrix} \mathbf{P}'_1 \\ \mathbf{P}'_2 \end{bmatrix} \mathbf{X} = \begin{bmatrix} \mathbf{P}'_1\mathbf{X} \\ \mathbf{P}'_2\mathbf{X} \end{bmatrix}$
- $\mathbf{F} = \mathbf{D}^{-1/2}\mathbf{Z} = \mathbf{D}^{-1/2} \begin{bmatrix} \mathbf{P}'_1\mathbf{X} \\ \mathbf{P}'_2\mathbf{X} \end{bmatrix} = \begin{bmatrix} \mathbf{D}_1^{-1/2}\mathbf{P}'_1\mathbf{X} \\ \mathbf{D}_2^{-1/2}\mathbf{P}'_2\mathbf{X} \end{bmatrix}$
- $\mathbf{\Lambda} = \mathbf{P}\mathbf{D}^{1/2} = [\mathbf{P}_1 \quad \mathbf{P}_2] \begin{bmatrix} \mathbf{D}_1^{1/2} & 0 \\ 0 & \mathbf{D}_2^{1/2} \end{bmatrix} = [\mathbf{P}_1\mathbf{D}_1^{1/2} \quad \mathbf{P}_2\mathbf{D}_2^{1/2}]$

Então,

$$\mathbf{F}_1 = \mathbf{D}_1^{-1/2}\mathbf{P}'_1\mathbf{X}, \quad \mathbf{\Lambda}_1 = \mathbf{P}_1\mathbf{D}_1^{1/2} \quad \text{e} \quad \mathbf{u} = \mathbf{P}_2\mathbf{D}_2^{1/2}\mathbf{D}_2^{-1/2}\mathbf{P}'_2\mathbf{X} \quad (3)$$

Análise Fatorial via Componentes Principais

Na práticas temos uma matriz de dados

$$\mathbf{x} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix}$$

(n realizações de $\mathbf{X} \sim (\mu, \Sigma)$ com μ e Σ desconhecidos).

Análise Fatorial via Componentes Principais

Na práticas temos uma matriz de dados

$$\mathbf{x} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix}$$

(n realizações de $\mathbf{X} \sim (\mu, \Sigma)$ com μ e Σ desconhecidos).

Da decomposição espectral temos \mathbf{P} e \mathbf{D} ($\mathbf{S} = \mathbf{PDP}$) e de (3) temos que

$$\mathbf{F}_1 = \mathbf{D}_1^{-1/2} \mathbf{P}'_1 \mathbf{X}, \quad \Lambda_1 = \mathbf{P}_1 \mathbf{D}_1^{1/2} \quad \text{e} \quad \mathbf{u} = \mathbf{P}_2 \mathbf{D}_2^{1/2} \mathbf{D}_2^{-1/2} \mathbf{P}'_2 \mathbf{X}$$

Análise Fatorial via Componentes Principais

$$\mathbf{F}_1 = \mathbf{D}_1^{-1/2} \mathbf{P}'_1 \mathbf{X}, \quad \Lambda_1 = \mathbf{P}_1 \mathbf{D}_1^{1/2} \quad e \quad \mathbf{u} = \mathbf{P}_2 \mathbf{D}_2^{1/2} \mathbf{D}_2^{-1/2} \mathbf{P}'_2 \mathbf{X}$$

No caso da matriz de dados,

- $\hat{F}'_i = \mathbf{D}_1^{-1/2} \mathbf{P}'_1 \mathbf{x}'_i \rightarrow \underbrace{\hat{F}_i}_{1 \times p} = \underbrace{\mathbf{x}_i}_{1 \times p} \mathbf{P}_1 \mathbf{D}_1^{-1/2} \rightarrow \underbrace{\hat{\mathbf{F}}}_{n \times p} = \underbrace{\mathbf{X}}_{n \times p} \mathbf{P}_1 \mathbf{D}_1^{-1/2}$
- $\Lambda = \mathbf{P}_1 \mathbf{D}_1^{1/2}$
- $\mathbf{u}'_i = \mathbf{P}_2 \mathbf{P}'_2 \mathbf{x}'_i \rightarrow \underbrace{\mathbf{u}_i}_{1 \times p} = \underbrace{\mathbf{x}_i}_{1 \times p} \underbrace{\mathbf{P}_2}_{p \times (p-k)} \underbrace{\mathbf{P}'_2}_{(p-k) \times p} \rightarrow \mathbf{u} = \mathbf{X} \mathbf{P}_2 \mathbf{P}'_2.$

Análise Fatorial via Componentes Principais

Os passos para estimar o modelo k -fatorial através de ACP podem ser resumido como:

Algoritmo:

- 1 Estimar Σ por \mathbf{S} .
- 2 Aplicar a decomposição espectral $\mathbf{S} = \mathbf{P}\mathbf{D}\mathbf{P}'$
- 3 Fazer $\hat{\mathbf{F}} = \mathbf{x}\mathbf{P}_1\mathbf{D}_1^{-1/2}$, $\hat{\Lambda} = \mathbf{P}_1\mathbf{D}_1^{1/2}$ e $\hat{\mathbf{u}} = \mathbf{x}\mathbf{P}_2\mathbf{P}_2'$

$\hat{\mathbf{u}}$ no passo 3 pode também ser obtido como $\mathbf{x} - \hat{\mathbf{F}}\hat{\Lambda}'$

Análise Fatorial via Componentes Principais

Os retornos semanais de 5 ações negociadas no NYSE estão disponíveis [aqui](#).

```
library(dplyr)
library(expm)
retornos <- read.table("https://raw.githubusercontent.com/ctrucio")
glimpse(retornos)
```

```
## Rows: 103
## Columns: 5
## $ V1 <dbl> 1.30338, 0.84862, -1.79153, 2.15589, 1.08225, 1.017
## $ V2 <dbl> -0.78431, 1.66886, -0.86393, -0.34858, 0.37167, -1
## $ V3 <dbl> -0.31889, -0.62100, 1.00360, 1.74353, -1.01345, -0
## $ V4 <dbl> -4.47693, 1.19560, 0.00000, -2.85917, 2.91900, 1.37
## $ V5 <dbl> 0.52151, 1.34890, -0.61428, -0.69534, 4.09751, 0.29
```

Análise Fatorial via Componentes Principais

```
retornos <- scale(retornos, center = TRUE, scale = FALSE)
# Decomposição Espectral
eigen_aux <- eigen(cov(retornos))
P <- eigen_aux$vectors      # autovetores
D <- diag(eigen_aux$values) # autovalores
```

Análise Fatorial via Componentes Principais

```
retornos <- scale(retornos, center = TRUE, scale = FALSE)
# Decomposição Espectral
eigen_aux <- eigen(cov(retornos))
P <- eigen_aux$vectors      # autovetores
D <- diag(eigen_aux$values) # autovalores
```

Trabalharemos com $k = 2$ fatores.

```
F_hat <- retornos %*% P[,1:2] %*% solve(sqrtm(D[1:2, 1:2]))
Lambda_hat <- P[, 1:2] %*% sqrtm(D[1:2, 1:2])
u_hat <- retornos - F_hat %*% t(Lambda_hat)
```

Análise Fatorial via Componentes Principais

```
round(cov(F_hat), 4)
```

```
##          [,1] [,2]  
## [1,]      1   0  
## [2,]      0   1
```

```
round(cov(F_hat, u_hat), 4)
```

```
##          V1 V2 V3 V4 V5  
## [1,]      0  0  0  0  0  
## [2,]      0  0  0  0  0
```

Análise Fatorial via Componentes Principais

```
round(cov(u_hat), 4)
```

```
##           V1          V2          V3          V4          V5
## V1  0.9128 -0.6803 -0.3918 -0.2191  0.3170
## V2 -0.6803  0.8145 -0.2287  0.1207 -0.2158
## V3 -0.3918 -0.2287  1.0798 -0.0198  0.0047
## V4 -0.2191  0.1207 -0.0198  1.2099 -1.1650
## V5  0.3170 -0.2158  0.0047 -1.1650  1.1359
```

$\mathbb{V}(\hat{\mathbf{u}})$ não é uma matriz diagonal! “Tá” certo isso?

Análise Fatorial via Componentes Principais

```
round(cov(u_hat), 4)
```

```
##           V1          V2          V3          V4          V5
## V1  0.9128 -0.6803 -0.3918 -0.2191  0.3170
## V2 -0.6803  0.8145 -0.2287  0.1207 -0.2158
## V3 -0.3918 -0.2287  1.0798 -0.0198  0.0047
## V4 -0.2191  0.1207 -0.0198  1.2099 -1.1650
## V5  0.3170 -0.2158  0.0047 -1.1650  1.1359
```

$\mathbb{V}(\hat{\mathbf{u}})$ não é uma matriz diagonal! “Tá” certo isso? **Sim!** nada garante que $\mathbb{V}(\hat{\mathbf{u}})$ será diagonal.

Análise Fatorial via Componentes Principais

```
round(cov(u_hat), 4)
```

```
##           V1          V2          V3          V4          V5
## V1  0.9128 -0.6803 -0.3918 -0.2191  0.3170
## V2 -0.6803  0.8145 -0.2287  0.1207 -0.2158
## V3 -0.3918 -0.2287  1.0798 -0.0198  0.0047
## V4 -0.2191  0.1207 -0.0198  1.2099 -1.1650
## V5  0.3170 -0.2158  0.0047 -1.1650  1.1359
```

$\mathbb{V}(\hat{\mathbf{u}})$ não é uma matriz diagonal! “Tá” certo isso? **Sim!** nada garante que $\mathbb{V}(\hat{\mathbf{u}})$ será diagonal.

Lembre-se, no AF aproximamos $\mathbf{S} \approx \hat{\Lambda}\hat{\Lambda}' + \Psi$ (ou seja, estamos desconsiderando os elementos de $\mathbb{V}(\hat{\mathbf{u}})$ que estão fora da diagonal).

Análise Fatorial vía Componentes Principais

Como determinar o número de fatores?

- Geralmente, ele é predefinido pelo pesquisador da área.
- Se ele não for previamente definido, podem ser utilizados os mesmos critérios utilizados em ACP.

Análise Fatorial via Componentes Principais

Como determinar o número de fatores?

- Geralmente, ele é predefinido pelo pesquisador da área.
- Se ele não for previamente definido, podem ser utilizados os mesmos critérios utilizados em ACP.

Para avaliar se nossa escolha de k foi boa, olhamos para:

- h_i^2 (esperamos que a cumunalidade seja alta).
- $\mathbf{S} - \hat{\Lambda}_1 \hat{\Lambda}'_1$ (esperamos que os elementos fora da diagonal sejam pequenos)

Máxima Versossimilhança

Máxima Versossimilhança

Seja $\mathbf{X} \sim N_p(\mu, \Sigma)$, então $\hat{\Lambda}$ e $\hat{\Psi}$ podem ser obtidos pelo método de máxima verossimilhança.

Máxima Versossimilhança

Seja $\mathbf{X} \sim N_p(\mu, \Sigma)$, então $\hat{\Lambda}$ e $\hat{\Psi}$ podem ser obtidos pelo método de máxima verossimilhança.

Como $\hat{\mu} = \bar{\mathbf{X}}$, a log-verossimilhança é reduzida a,

$$l = -\frac{1}{2}n \log |2\pi\Sigma| - \frac{1}{2}n \text{Tr}(\Sigma^{-1}\mathbf{S}).$$

Máxima Versossimilhança

Seja $\mathbf{X} \sim N_p(\mu, \Sigma)$, então $\hat{\Lambda}$ e $\hat{\Psi}$ podem ser obtidos pelo método de máxima verossimilhança.

Como $\hat{\mu} = \bar{\mathbf{X}}$, a log-verossimilhança é reduzida a,

$$l = -\frac{1}{2}n \log |2\pi\Sigma| - \frac{1}{2}n \text{Tr}(\Sigma^{-1}\mathbf{S}).$$

Mas $\Sigma = \Lambda\Lambda' + \Psi$, então podemos re-escrever a verossimilhança como

$$l = -\frac{p}{2} \log(2\pi) - \frac{1}{2}n \log |\Lambda\Lambda' + \Psi| - \frac{1}{2}n \text{Tr}([\Lambda\Lambda' + \Psi]^{-1}\mathbf{S}) \quad (4)$$

$$\propto -\frac{1}{2}n \log |\Lambda\Lambda' + \Psi| - \frac{1}{2}n \text{Tr}([\Lambda\Lambda' + \Psi]^{-1}\mathbf{S}) \quad (5)$$

$$\propto -\log |\Lambda\Lambda' + \Psi| - \text{Tr}([\Lambda\Lambda' + \Psi]^{-1}\mathbf{S}) \quad (6)$$

Máxima Versossimilhança

Devido à multiplicidade de Λ' a função a ser otimizada ainda não está bem definida. Para contornar esse problema, impomos a restrição de que $\Lambda\Psi\Lambda'$ seja diagonal.

Máxima Versossimilhança

Devido à multiplicidade de Λ' a função a ser otimizada ainda não está bem definida. Para contornar esse problema, impomos a restrição de que $\Lambda\Psi\Lambda'$ seja diagonal.

Assim, basta maximizar (3) [ou minimizar $-(3)$] *w.r.t.* Λ e Ψ e com a restrição imposta para obter os EMV.

Máxima Versossimilhança

Devido à multiplicidade de Λ' a função a ser otimizada ainda não está bem definida. Para contornar esse problema, impomos a restrição de que $\Lambda\Psi\Lambda'$ seja diagonal.

Assim, basta maximizar (3) [ou minimizar $-(3)$] *w.r.t.* Λ e Ψ e com a restrição imposta para obter os EMV.

A solução é numérica

O problema? mesmo para $k = 1$ a maximização/minimização é bastante complexa e algoritmos iterativos são utilizados.

Fatores Estimados

Embora o foco principal esteja em estimar Λ e Ψ , às vezes é de interesse obter $\hat{\mathbf{F}}$.

Fatores Estimados

Embora o foco principal esteja em estimar Λ e Ψ , às vezes é de interesse obter $\hat{\mathbf{F}}$.

Quando utilizamos AF via ACP, $\hat{\mathbf{F}} = \hat{\mathbf{D}}_1^{-1/2} \hat{\mathbf{P}}_1 \mathbf{X}$. Em geral, existem outros métodos que podemos utilizar:

Fatores Estimados

Embora o foco principal esteja em estimar Λ e Ψ , às vezes é de interesse obter $\hat{\mathbf{F}}$.

Quando utilizamos AF via ACP, $\hat{\mathbf{F}} = \hat{\mathbf{D}}_1^{-1/2} \hat{\mathbf{P}}_1 \mathbf{X}$. Em geral, existem outros métodos que podemos utilizar:

- Método de mínimo quadrados ponderados: $\hat{\mathbf{F}} = (\hat{\Lambda}' \hat{\Psi}^{-1} \hat{\Lambda})^{-1} \hat{\Lambda}' \hat{\Psi}^{-1} \mathbf{X}$
- Regressão: $\hat{\mathbf{F}} = \hat{\Lambda}' \mathbf{S}^{-1} \mathbf{X}$
- etc.

Rotação

Rotação

- As restrições impostas na estimação ($\Lambda'\Psi^{-1}\Lambda$ ou $\Lambda'\mathbf{D}^{-1}\Lambda$ ser diagonal), são apenas formas matemáticas de lidar com o problema de multiplicidade.

Rotação

- As restrições impostas na estimação ($\Lambda'\Psi^{-1}\Lambda$ ou $\Lambda'\mathbf{D}^{-1}\Lambda$ ser diagonal), são apenas formas matemáticas de lidar com o problema de multiplicidade.
- Contudo, essas restrições não garantem que a interpretação dos fatores seja fácil.

Rotação

- As restrições impostas na estimação ($\Lambda'\Psi^{-1}\Lambda$ ou $\Lambda'\mathbf{D}^{-1}\Lambda$ ser diagonal), são apenas formas matemáticas de lidar com o problema de multiplicidade.
- Contudo, essas restrições não garantem que a interpretação dos fatores seja fácil.
- Utilizando a não unicidade da solução podemos encontrar matrizes ortogonais que nos levarão a uma melhor interpretação.

Rotação

- As restrições impostas na estimação ($\Lambda'\Psi^{-1}\Lambda$ ou $\Lambda'\mathbf{D}^{-1}\Lambda$ ser diagonal), são apenas formas matemáticas de lidar com o problema de multiplicidade.
- Contudo, essas restrições não garantem que a interpretação dos fatores seja fácil.
- Utilizando a não unicidade da solução podemos encontrar matrizes ortogonais que nos levarão a uma melhor interpretação.
- Utilizar matrizes ortogonais significa *rotar os fatores* de forma que sejam mais facilmente interpretáveis

Rotação

- As restrições impostas na estimação ($\Lambda'\Psi^{-1}\Lambda$ ou $\Lambda'\mathbf{D}^{-1}\Lambda$ ser diagonal), são apenas formas matemáticas de lidar com o problema de multiplicidade.
- Contudo, essas restrições não garantem que a interpretação dos fatores seja fácil.
- Utilizando a não unicidade da solução podemos encontrar matrizes ortogonais que nos levarão a uma melhor interpretação.
- Utilizar matrizes ortogonais significa *rotar os fatores* de forma que sejam mais facilmente interpretáveis
- Existem vários métodos para fazer a rotação.

Rotação

- Seja \hat{F} a solução inicial (obtida vía ACP, MV ou algúm outro método).


Rotação

- Seja \hat{F} a solução inicial (obtida via ACP, MV ou algum outro método).
- Sabemos que $\text{Cor}(\hat{F}, \mathbf{X}) = \text{Diag}(\mathbf{S})^{-1/2} \hat{\Lambda}$ (ou apenas $\hat{\Lambda}$ se \mathbf{X} for padronizada)

Rotação


- Seja \hat{F} a solução inicial (obtida via ACP, MV ou algum outro método).
- Sabemos que $\text{Cor}(\hat{F}, \mathbf{X}) = \text{Diag}(\mathbf{S})^{-1/2} \hat{\Lambda}$ (ou apenas $\hat{\Lambda}$ se \mathbf{X} for padronizada)
- A ideia da rotação é que as variáveis originais tenham uma correlação o mais próximo de 1 com um fator e o mais próximo de 0 com os outros fatores (assim, cada fator terá um grupo de variáveis fortemente correlacionadas com ele).

Rotação



Fonte: https://clemson.instructure.com/files/2156796/download?download_frd=1

Rotação



Fonte: https://clemson.instructure.com/files/2156796/download?download_frd=1

A seguir, veremos o método **varimax** (um dos métodos de rotação mais conhecidos).

Rotação: Varimax

Pense em $k = 2$, a matriz de rotação (no sentido horário) é dada por

$$G(\theta) = \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix}.$$

Rotação: Varimax

Pense em $k = 2$, a matriz de rotação (no sentido horário) é dada por

$$G(\theta) = \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix}.$$

A matriz de cargas (já rotada) é dada por $\hat{\Lambda}^* = \hat{\Lambda}G(\theta)$.

Rotação: Varimax

Pense em $k = 2$, a matriz de rotação (no sentido horário) é dada por

$$G(\theta) = \begin{pmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{pmatrix}.$$

A matriz de cargas (já rotada) é dada por $\hat{\Lambda}^* = \hat{\Lambda}G(\theta)$.

A ideia de **varimax** é encontrar θ de forma que maximize a soma das variâncias dos quadrados das cargas fatoriais (padronizadas pela cumunalidade) dentro de cada coluna de $\hat{\Lambda}^*$.

Rotação: Varimax

A variância dos quadrados das cargas fatoriais (padronizadas pela cumunalidade) do j -ésimo fator (rotado) é dada por,

$$\frac{\sum_{i=1}^p (\lambda_{ij}^{2*} / h_j^{2*})^2}{p} - \left[\frac{\sum_{i=1}^p \lambda_{ij}^{2*} / h_j^{2*}}{p} \right]^2$$

Rotação: Varimax

A variância dos quadrados das cargas fatoriais (padronizadas pela cumunalidade) do j -ésimo fator (rotado) é dada por,

$$\frac{\sum_{i=1}^p (\lambda_{ij}^{2*} / h_j^{2*})^2}{p} - \left[\frac{\sum_{i=1}^p \lambda_{ij}^{2*} / h_j^{2*}}{p} \right]^2$$

Varimax: escolhemos θ de forma que

$$\frac{1}{p} \sum_{j=1}^k \left[\sum_{i=1}^p \left(\frac{\lambda_{ij}^{2*}}{h_i^{2*}} \right)^2 - \frac{1}{p} \left(\sum_{i=1}^p \frac{\lambda_{ij}^{2*}}{h_i^{2*}} \right)^2 \right] \text{ seja máximo.}$$

Rotação: Varimax

A variância dos quadrados das cargas fatoriais (padronizadas pela cumunalidade) do j -ésimo fator (rotado) é dada por,

$$\frac{\sum_{i=1}^p (\lambda_{ij}^{2*} / h_j^{2*})^2}{p} - \left[\frac{\sum_{i=1}^p \lambda_{ij}^{2*} / h_j^{2*}}{p} \right]^2$$

Varimax: escolhemos θ de forma que

$$\frac{1}{p} \sum_{j=1}^k \left[\sum_{i=1}^p \left(\frac{\lambda_{ij}^{2*}}{h_i^{2*}} \right)^2 - \frac{1}{p} \left(\sum_{i=1}^p \frac{\lambda_{ij}^{2*}}{h_i^{2*}} \right)^2 \right] \text{ seja máximo.}$$

Observação: alguns chamam de **varimax padronizado**.

Rotação

Existem vários métodos de rotação:

- **Varimax:** (simplifica a interpretação dos fatores).
- **Quartimax:** minimiza o número de fatores necessários para explicar cada variável (simplifica a interpretação das variáveis observadas).
- **Equamax:** combinação entre varimax e quartimax.
- **Oblimin:** rotação oblíqua (não ortogonal)
- **Promax:** rotação oblíqua (mais rápida que oblimin)

Referências

Referências

- Härdle, W. K., & Simar, L. (2019). Applied Multivariate Statistical Analysis. Fifth Edition. Springer Nature. Capítulo 12.
- Mardia, K. V., Kent, J. T., & Bibby, J. M. (1979). Multivariate Analysis. Academic Press. Capítulo 9.
- Peña, D. (2002). Análisis de Datos Multivariantes. Mc Graw Hill. Capítulo 12.