

SME0822 Análise Multivariada e Aprendizado Não-Supervisionado

Aula 8a: **Análise Fatorial**

Prof. Cibeles Russo

cibele@icmc.usp.br

<http://www.icmc.usp.br/~cibele>

Johnson, R. A., & Wichern, D. W. (2007). Applied Multivariate Statistical Analysis. Prentice Hall.

Mingoti, S. A. (2007). Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada. Editora UFMG.

Análise fatorial

Objetivos:

- Descrever a variabilidade original do vetor aleatório $\underline{X}_{p \times 1}$ em termos de um número menor m de variáveis aleatórias chamadas **fatores comuns**, e que estão relacionadas com \underline{X} por meio de um **modelo linear**.
- Agrupar as variáveis originais X_i , $i = 1, \dots, p$, em fatores mutuamente não correlacionados, interpretáveis.
- Reduzir a dimensionalidade do problema.

Análise fatorial

Objetivos:

- Descrever a variabilidade original do vetor aleatório $\underline{X}_{p \times 1}$ em termos de um número menor m de variáveis aleatórias chamadas **fatores comuns**, e que estão relacionadas com \underline{X} por meio de um **modelo linear**.
- Agrupar as variáveis originais X_i , $i = 1, \dots, p$, em fatores mutuamente não correlacionados, interpretáveis.
- Reduzir a dimensionalidade do problema.

Análise fatorial

Objetivos:

- Descrever a variabilidade original do vetor aleatório $\underline{X}_{p \times 1}$ em termos de um número menor m de variáveis aleatórias chamadas **fatores comuns**, e que estão relacionadas com \underline{X} por meio de um **modelo linear**.
- Agrupar as variáveis originais X_i , $i = 1, \dots, p$, em fatores mutuamente não correlacionados, interpretáveis.
- Reduzir a dimensionalidade do problema.

Análise fatorial

Origem: Spearman (1904), em tentativas de **definir e medir inteligência**.

Áreas de aplicação originais: psicologia, psicometria, ciências sociais.

Modelo de análise fatorial via matriz de correlação

Seja $\underline{\tilde{X}}_p$ um vetor aleatório com

$$E(\underline{\tilde{X}}) = \underline{\mu}, \text{ Var}(\underline{\tilde{X}}) = \Sigma \text{ e } \text{Cor}(\underline{\tilde{X}}) = P.$$

Sejam

$$Z_i = \frac{X_i - \mu_i}{\sigma_i}, i = 1, \dots, p$$

as variáveis padronizadas.

Já vimos que $\text{Cov}(\underline{Z}) = P = \text{Cor}(\underline{\tilde{X}})$.

Modelo de análise fatorial via matriz de correlação

Seja $\underline{\tilde{X}}_p$ um vetor aleatório com

$$E(\underline{\tilde{X}}) = \underline{\mu}, \text{Var}(\underline{\tilde{X}}) = \Sigma \text{ e } \text{Cor}(\underline{\tilde{X}}) = P.$$

Sejam

$$Z_i = \frac{X_i - \mu_i}{\sigma_i}, i = 1, \dots, p$$

as variáveis padronizadas.

Já vimos que $\text{Cov}(\underline{Z}) = P = \text{Cor}(\underline{\tilde{X}})$.

Modelo de análise fatorial via matriz de correlação

Seja $\underline{\tilde{X}}_p$ um vetor aleatório com

$$E(\underline{\tilde{X}}) = \underline{\mu}, \text{Var}(\underline{\tilde{X}}) = \Sigma \text{ e } \text{Cor}(\underline{\tilde{X}}) = P.$$

Sejam

$$Z_i = \frac{X_i - \mu_i}{\sigma_i}, i = 1, \dots, p$$

as variáveis padronizadas.

Já vimos que $\text{Cov}(\underline{\tilde{Z}}) = P = \text{Cor}(\underline{\tilde{X}})$.

Modelo de análise fatorial via matriz de correlação

Queremos explicar as variáveis padronizadas Z_1, \dots, Z_p com m fatores F_1, \dots, F_m de tal forma que

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

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

\vdots

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

Modelo de análise fatorial via matriz de correlação

Em notação matricial, podemos escrever

$$\underline{Z} = L\underline{F} + \underline{\epsilon},$$

em que os elementos são dados por

$$\begin{pmatrix} Z_1 \\ \vdots \\ Z_p \end{pmatrix} = \begin{pmatrix} l_{11} & \dots & l_{1m} \\ \vdots & \ddots & \vdots \\ l_{p1} & \dots & l_{pm} \end{pmatrix} \begin{pmatrix} F_1 \\ \vdots \\ F_m \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \vdots \\ \epsilon_p \end{pmatrix}.$$

Modelo de análise fatorial via matriz de correlação

Nesse modelo,

- $\underline{F}_{m \times 1}$ é um vetor aleatório que contém m fatores, também chamados de **variáveis latentes**, que descrevem os elementos da população e são não observáveis.
- $\underline{\epsilon}$ é o vetor de erros aleatórios não observáveis.
- l_{ij} , também chamado de *loading* (peso) ou carga fatorial, é o coeficiente da i -ésima variável padronizada Z_i , $i = 1, \dots, p$ no j -ésimo fator, F_j , $j = 1, \dots, m$.
- L é a matriz de cargas fatoriais

Modelo de análise fatorial via matriz de correlação

Nesse modelo,

- $\underline{F}_{m \times 1}$ é um vetor aleatório que contém m fatores, também chamados de **variáveis latentes**, que descrevem os elementos da população e são não observáveis.
- $\underline{\epsilon}$ é o vetor de erros aleatórios não observáveis.
- l_{ij} , também chamado de *loading* (peso) ou carga fatorial, é o coeficiente da i -ésima variável padronizada Z_i , $i = 1, \dots, p$ no j -ésimo fator, F_j , $j = 1, \dots, m$.
- L é a matriz de cargas fatoriais

Modelo de análise fatorial via matriz de correlação

Nesse modelo,

- $\underline{F}_{m \times 1}$ é um vetor aleatório que contém m fatores, também chamados de **variáveis latentes**, que descrevem os elementos da população e são não observáveis.
- $\underline{\epsilon}$ é o vetor de erros aleatórios não observáveis.
- l_{ij} , também chamado de *loading* (peso) ou carga fatorial, é o coeficiente da i -ésima variável padronizada Z_i , $i = 1, \dots, p$ no j -ésimo fator, F_j , $j = 1, \dots, m$.
- L é a matriz de cargas fatoriais

Modelo de análise fatorial via matriz de correlação

Nesse modelo,

- $\underline{F}_{m \times 1}$ é um vetor aleatório que contém m fatores, também chamados de **variáveis latentes**, que descrevem os elementos da população e são não observáveis.
- $\underline{\epsilon}$ é o vetor de erros aleatórios não observáveis.
- l_{ij} , também chamado de *loading* (peso) ou carga fatorial, é o coeficiente da i -ésima variável padronizada Z_i , $i = 1, \dots, p$ no j -ésimo fator, F_j , $j = 1, \dots, m$.
- L é a matriz de cargas fatoriais

Modelo fatorial ortogonal

O modelo

$$\underline{Z} = L\underline{F} + \underline{\epsilon},$$

com as suposições

- i. $E(\underline{F}) = \underline{0}$
- ii. $\text{Var}(\underline{F}) = I$
- iii. $E(\underline{\epsilon}) = \underline{0}$
- iv. $\text{Var}(\underline{\epsilon}) = \Psi = \text{diag}(\psi_1, \dots, \psi_p)$

é chamado de **modelo fatorial ortogonal**, já que os m fatores são ortogonais entre si. Além disso, supomos que \underline{F} e $\underline{\epsilon}$ são não correlacionados.

Modelo fatorial ortogonal

Resultado

Em um modelo fatorial ortogonal (suposições i a iv satisfeitas), pode-se escrever a matriz P como

$$P = LL^T + \Psi.$$

Prova: Temos que

$$\begin{aligned} P &= \text{Var}(\underline{Z}) \\ &= \text{Var}(L\underline{F} + \underline{\epsilon}) \\ &= L\text{Var}\underline{F}L^T + \text{Var}(\underline{\epsilon}) = \\ &= LIL^T + \Psi = LL^T + \Psi. \end{aligned}$$

Modelo fatorial ortogonal

Resultado

Em um modelo fatorial ortogonal (suposições i a iv satisfeitas), pode-se escrever a matriz P como

$$P = LL^T + \Psi.$$

Prova: Temos que

$$\begin{aligned} P &= \text{Var}(\underline{Z}) \\ &= \text{Var}(L\underline{F} + \underline{\epsilon}) \\ &= L\text{Var}\underline{F}L^T + \text{Var}(\underline{\epsilon}) = \\ &= LIL^T + \Psi = LL^T + \Psi. \end{aligned}$$

Modelo fatorial ortogonal

Objetivo:

Queremos encontrar $L_{p \times m}$ e $\Psi_{p \times p}$ que possam decompor a matriz P na forma

$$P = LL^T + \Psi,$$

o que nem sempre é possível.

Modelo fatorial ortogonal

Note que

$$P = LL^T + \Psi = \begin{pmatrix} \sum_{j=1}^m l_{1j}^2 & \cdots & \sum_{j=1}^m l_{1j}l_{jp} \\ \vdots & \ddots & \vdots \\ \sum_{j=1}^m l_{pj}l_{j1} & \cdots & \sum_{j=1}^m l_{pj}^2 \end{pmatrix} + \begin{pmatrix} \psi_1 & 0 & \cdots & 0 \\ 0 & \psi_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \psi_p \end{pmatrix}$$

Modelo fatorial ortogonal

Assim, vem que

- $\text{Var}(Z_i) = \sum_{j=1}^m l_{ij}^2 + \psi_i = h_i^2 + \psi_i = 1$, em que h_i^2 é chamado **comunalidade** (devido aos fatores) e ψ_i é chamado de **variância específica**.
- $\text{Cov}(Z_i, Z_k) = l_{i1}l_{1k} + \dots + l_{im}l_{mk}$ para $i, k = 1, \dots, p$ e $i \neq k$.
- $\text{Cov}(\underline{Z}, \underline{F}) = L$ e $\text{Cov}(Z_i, F_k) = \text{Cor}(Z_i, F_k) = l_{ik}$ pois $\text{Cov}(\underline{Z}, \underline{F}) = \text{Cov}(L\underline{F} + \underline{\epsilon}, \underline{F}) = \text{Cov}(L\underline{F}, \underline{F}) + \text{Cov}(\underline{\epsilon}, \underline{F}) = L$.

Modelo fatorial ortogonal

Assim, vem que

- $\text{Var}(Z_i) = \sum_{j=1}^m l_{ij}^2 + \psi_i = h_i^2 + \psi_i = 1$, em que h_i^2 é chamado **comunalidade** (devido aos fatores) e ψ_i é chamado de **variância específica**.
- $\text{Cov}(Z_i, Z_k) = l_{i1}l_{1k} + \dots + l_{im}l_{mk}$ para $i, k = 1, \dots, p$ e $i \neq k$.
- $\text{Cov}(\underline{Z}, \underline{F}) = L$ e $\text{Cov}(Z_i, F_k) = \text{Cor}(Z_i, F_k) = l_{ik}$ pois
 $\text{Cov}(\underline{Z}, \underline{F}) = \text{Cov}(L\underline{F} + \underline{\epsilon}, \underline{F}) = \text{Cov}(L\underline{F}, \underline{F}) + \text{Cov}(\underline{\epsilon}, \underline{F}) = L$.

Modelo fatorial ortogonal

Assim, vem que

- $\text{Var}(Z_i) = \sum_{j=1}^m l_{ij}^2 + \psi_i = h_i^2 + \psi_i = 1$, em que h_i^2 é chamado **comunalidade** (devido aos fatores) e ψ_i é chamado de **variância específica**.
- $\text{Cov}(Z_i, Z_k) = l_{i1}l_{1k} + \dots + l_{im}l_{mk}$ para $i, k = 1, \dots, p$ e $i \neq k$.
- $\text{Cov}(\underline{Z}, \underline{F}) = L$ e $\text{Cov}(Z_i, F_k) = \text{Cor}(Z_i, F_k) = l_{ik}$ pois
 $\text{Cov}(\underline{Z}, \underline{F}) = \text{Cov}(L\underline{F} + \underline{\epsilon}, \underline{F}) = \text{Cov}(L\underline{F}, \underline{F}) + \text{Cov}(\underline{\epsilon}, \underline{F}) = L$.

Modelo fatorial ortogonal

Assim, vem que

- $\text{Var}(Z_i) = \sum_{j=1}^m l_{ij}^2 + \psi_i = h_i^2 + \psi_i = 1$, em que h_i^2 é chamado **comunalidade** (devido aos fatores) e ψ_i é chamado de **variância específica**.
- $\text{Cov}(Z_i, Z_k) = l_{i1}l_{1k} + \dots + l_{im}l_{mk}$ para $i, k = 1, \dots, p$ e $i \neq k$.
- $\text{Cov}(\underline{Z}, \underline{F}) = L$ e $\text{Cov}(Z_i, F_k) = \text{Cor}(Z_i, F_k) = l_{ik}$ pois $\text{Cov}(\underline{Z}, \underline{F}) = \text{Cov}(L\underline{F} + \underline{\epsilon}, \underline{F}) = \text{Cov}(L\underline{F}, \underline{F}) + \text{Cov}(\underline{\epsilon}, \underline{F}) = L$.

Modelo fatorial ortogonal

Critérios para a escolha do número de fatores

- Análise da proporção da variância,
- Número de autovalores de R maiores do que 1,
- Gráfico scree-plot.

Modelo fatorial ortogonal

Pode-se estimar L e Ψ utilizando alguns métodos

- 1 Método dos fatores principais
- 2 Método dos fatores principais iterativo
- 3 Método da máxima verossimilhança (com a suposição de normalidade).

Métodos para a estimação das matrizes L e Ψ

1. Método das componentes principais ou fatores principais:

Considere a decomposição espectral de P :

$$\begin{aligned} P &= \sum_{i=1}^p \lambda_i \mathbf{e}_i \mathbf{e}_i^\top = \\ &= \left(\sqrt{\lambda_1} \mathbf{e}_1 \quad \dots \quad \sqrt{\lambda_p} \mathbf{e}_p \right) \begin{pmatrix} \sqrt{\lambda_1} \mathbf{e}_1^\top \\ \dots \\ \sqrt{\lambda_p} \mathbf{e}_p^\top \end{pmatrix} = LL^\top \end{aligned}$$

Se o número de fatores $m = p$, então $P = LL^\top$. Entretanto, nosso interesse está quase sempre em reduzir a dimensionalidade do problema para $m < p$ fatores. Nesse caso, consideramos o algoritmo:

Métodos para a estimação das matrizes L e Ψ

1. Método das componentes principais ou fatores principais:

Considere a decomposição espectral de P :

$$\begin{aligned} P &= \sum_{i=1}^p \lambda_i \mathbf{e}_i \mathbf{e}_i^\top = \\ &= \left(\sqrt{\lambda_1} \mathbf{e}_1 \quad \dots \quad \sqrt{\lambda_p} \mathbf{e}_p \right) \begin{pmatrix} \sqrt{\lambda_1} \mathbf{e}_1^\top \\ \dots \\ \sqrt{\lambda_p} \mathbf{e}_p^\top \end{pmatrix} = LL^\top \end{aligned}$$

Se o número de fatores $m = p$, então $P = LL^\top$. Entretanto, nosso interesse está quase sempre em reduzir a dimensionalidade do problema para $m < p$ fatores. Nesse caso, consideramos o algoritmo:

Método dos fatores principais

- 1 Extrair os autovalores e autovetores normalizados correspondentes de R , $(\hat{\lambda}_i, \hat{e}_i)$, para $i = 1, \dots, p$,
- 2 Selecionar os m autovalores e autovetores correspondentes $(\hat{\lambda}_i, \hat{e}_i)$, para $i = 1, \dots, m$,
- 3 Estimar L e Ψ fazendo:

$$\begin{aligned}\hat{L} &= \left(\sqrt{\hat{\lambda}_1} \hat{e}_1, \dots, \sqrt{\hat{\lambda}_m} \hat{e}_m \right) \\ \hat{\Psi} &= \text{diag}(R - \hat{L}\hat{L}^\top)\end{aligned}$$

A matriz residual nesse caso é dada por

$$MRes = R - \hat{L}\hat{L}^\top - \hat{\Psi}$$

Método dos fatores principais

- 1 Extrair os autovalores e autovetores normalizados correspondentes de R , $(\hat{\lambda}_i, \hat{e}_i)$, para $i = 1, \dots, p$,
- 2 Selecionar os m autovalores e autovetores correspondentes $(\hat{\lambda}_i, \hat{e}_i)$, para $i = 1, \dots, m$,
- 3 Estimar L e Ψ fazendo:

$$\begin{aligned}\hat{L} &= \left(\sqrt{\hat{\lambda}_1} \hat{e}_1, \dots, \sqrt{\hat{\lambda}_m} \hat{e}_m \right) \\ \hat{\Psi} &= \text{diag}(R - \hat{L}\hat{L}^\top)\end{aligned}$$

A matriz residual nesse caso é dada por

$$MRes = R - \hat{L}\hat{L}^\top - \hat{\Psi}$$

Métodos para a estimação das matrizes L e Ψ

2. Método das componentes principais iterativo ou fatores principais iterativo:

- Refinamento das estimativas de L e Ψ obtidas pelo Método dos fatores principais.
- m é definido por um critério anterior

Método dos fatores principais iterativo

Considere que a matriz de correlações de X , P , seja modelada como

$$P = LL^{\top} + \Psi$$

Então

$$LL^{\top} = P - \Psi = \begin{pmatrix} h_1^2 & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{12} & h_2^2 & \cdots & \rho_{2p} \\ \vdots & \ddots & \ddots & \vdots \\ \rho_{p1} & \cdots & \rho_{p-1,p} & h_p^2 \end{pmatrix}$$

em que $h_i^2 = 1 - \psi_i$, $i = 1, \dots, p$, são as comunalidades.

Método dos fatores principais iterativo

Suponha que se estime a matriz LL^\top por R^* dada por

$$R^* = \begin{pmatrix} h_1^{*2} & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{12} & h_2^{*2} & \cdots & \rho_{2p} \\ \vdots & \ddots & \ddots & \vdots \\ \rho_{p1} & \cdots & \rho_{p-1,p} & h_p^{*2} \end{pmatrix} \cong L^* L^{*\top}.$$

As quantidades $h_1^{*2}, \dots, h_p^{*2}$ são as estimativas iniciais das communalidades h_1^2, \dots, h_p^2 . Usando o método das componentes principais, temos

$$L^* = (\sqrt{\widehat{\lambda}_1^*} \widehat{e}_1^*, \dots, \sqrt{\widehat{\lambda}_m^*} \widehat{e}_m^*),$$

em que $\widehat{\lambda}_1^*, \dots, \widehat{\lambda}_m^*$ são os autovalores da matriz R^* com autovetores correspondentes $\widehat{e}_1^*, \dots, \widehat{e}_m^*$.

Método dos fatores principais iterativo

Suponha que se estime a matriz LL^\top por R^* dada por

$$R^* = \begin{pmatrix} h_1^{*2} & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{12} & h_2^{*2} & \cdots & \rho_{2p} \\ \vdots & \ddots & \ddots & \vdots \\ \rho_{p1} & \cdots & \rho_{p-1,p} & h_p^{*2} \end{pmatrix} \cong L^* L^{*\top}.$$

As quantidades $h_1^{*2}, \dots, h_p^{*2}$ são as estimativas iniciais das communalidades h_1^2, \dots, h_p^2 . Usando o método das componentes principais, temos

$$L^* = (\sqrt{\widehat{\lambda}_1^*} \widehat{e}_1^*, \dots, \sqrt{\widehat{\lambda}_m^*} \widehat{e}_m^*),$$

em que $\widehat{\lambda}_1^*, \dots, \widehat{\lambda}_m^*$ são os autovalores da matriz R^* com autovetores correspondentes $\widehat{e}_1^*, \dots, \widehat{e}_m^*$.

Método dos fatores principais iterativo

Suponha que se estime a matriz LL^\top por R^* dada por

$$R^* = \begin{pmatrix} h_1^{*2} & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{12} & h_2^{*2} & \cdots & \rho_{2p} \\ \vdots & \ddots & \ddots & \vdots \\ \rho_{p1} & \cdots & \rho_{p-1,p} & h_p^{*2} \end{pmatrix} \approx L^* L^{*\top}.$$

As quantidades $h_1^{*2}, \dots, h_p^{*2}$ são as estimativas iniciais das comunalidades h_1^2, \dots, h_p^2 . Usando o método das componentes principais, temos

$$L^* = (\sqrt{\widehat{\lambda}_1^*} \widehat{e}_1^*, \dots, \sqrt{\widehat{\lambda}_m^*} \widehat{e}_m^*),$$

em que $\widehat{\lambda}_1^*, \dots, \widehat{\lambda}_m^*$ são os autovalores da matriz R^* com autovetores correspondentes $\widehat{e}_1^*, \dots, \widehat{e}_m^*$.

Método dos fatores principais iterativo

A cada passo, as variâncias específicas são estimadas por

$$\psi_i^* = 1 - h_i^{*2}.$$

A partir da matriz L^* , temos as novas estimativas das comunalidades h_1^2, \dots, h_p^2 , que são então colocadas na diagonal principal da matriz $R^* = L^*L^{*\top}$ e o processo é repetido até que as diferenças nas estimativas das comunalidades de duas iterações sucessivas sejam suficientemente pequenas.

Como estimativas iniciais das comunalidades, podemos também considerar para h_i^2 o coeficiente de determinação R^2 do modelo de regressão linear em que Z_i é a variável resposta e as outras $p - 1$ variáveis são variáveis explicativas.

Método dos fatores principais iterativo

A cada passo, as variâncias específicas são estimadas por

$$\psi_i^* = 1 - h_i^{*2}.$$

A partir da matriz L^* , temos as novas estimativas das comunalidades h_1^2, \dots, h_p^2 , que são então colocadas na diagonal principal da matriz $R^* = L^*L^{*\top}$ e o processo é repetido até que as diferenças nas estimativas das comunalidades de duas iterações sucessivas sejam suficientemente pequenas.

Como estimativas iniciais das comunalidades, podemos também considerar para h_i^2 o coeficiente de determinação R^2 do modelo de regressão linear em que Z_i é a variável resposta e as outras $p - 1$ variáveis são variáveis explicativas.

Método dos fatores principais iterativo

A cada passo, as variâncias específicas são estimadas por

$$\psi_i^* = 1 - h_i^{*2}.$$

A partir da matriz L^* , temos as novas estimativas das comunalidades h_1^2, \dots, h_p^2 , que são então colocadas na diagonal principal da matriz $R^* = L^*L^{*\top}$ e o processo é repetido até que as diferenças nas estimativas das comunalidades de duas iterações sucessivas sejam suficientemente pequenas.

Como estimativas iniciais das comunalidades, podemos também considerar para h_i^2 o coeficiente de determinação R^2 do modelo de regressão linear em que Z_i é a variável resposta e as outras $p - 1$ variáveis são variáveis explicativas.

3. Método da máxima verossimilhança:

Suponha que $\underline{X} \sim N_p(\underline{\mu}, \Sigma)$ e portanto $\underline{Z} \sim N_p(\underline{0}, P)$. Além disso, $\underline{F} \sim N_p(\underline{0}, I)$ e $\underline{\varepsilon} \sim N_p(\underline{0}, \Psi)$.

A função de verossimilhança considerando uma amostra aleatória de tamanho n , $\underline{Z}_1, \dots, \underline{Z}_n$, é expressa por

$$\mathcal{L}(P) = \frac{1}{(2\pi)^{np/2} |P|^{n/2}} \exp\left\{-\frac{1}{2} \sum_{j=1}^n \underline{z}_j^\top P^{-1} \underline{z}_j\right\}$$

Método da máxima verossimilhança

ou seja,

$$\mathcal{L}(L, \Psi) = \frac{1}{(2\pi)^{np/2} |LL^\top + \Psi|^{n/2}} \exp\left\{-\frac{1}{2} \sum_{j=1}^n \tilde{z}_j^\top (LL^\top + \Psi)^{-1} \tilde{z}_j\right\}$$

e devemos encontrar o máximo de $\mathcal{L}(L, \Psi)$ em L e Ψ . Essa maximização é feita em termos numéricos para um valor de m fixo.

Problema: o algoritmo pode não convergir.

Método da máxima verossimilhança

ou seja,

$$\mathcal{L}(L, \Psi) = \frac{1}{(2\pi)^{np/2} |LL^\top + \Psi|^{n/2}} \exp\left\{-\frac{1}{2} \sum_{j=1}^n \tilde{z}_j^\top (LL^\top + \Psi)^{-1} \tilde{z}_j\right\}$$

e devemos encontrar o máximo de $\mathcal{L}(L, \Psi)$ em L e Ψ . Essa maximização é feita em termos numéricos para um valor de m fixo.

Problema: o algoritmo pode não convergir.

Métodos para a estimação das matrizes L e Ψ

Quando usar um método ou outro?

Se a suposição de normalidade é válida, o método da máxima verossimilhança pode produzir estimativas mais precisas.

Se não podemos supor a normalidade multivariada, convém utilizar o método de fatores principais ou fatores principais iterativo.

Observação: Diferentes valores de m podem levar a diferentes estimativas das cargas fatoriais.

Métodos para a estimação das matrizes L e Ψ

Quando usar um método ou outro?

Se a suposição de normalidade é válida, o método da máxima verossimilhança pode produzir estimativas mais precisas.

Se não podemos supor a normalidade multivariada, convém utilizar o método de fatores principais ou fatores principais iterativo.

Observação: Diferentes valores de m podem levar a diferentes estimativas das cargas fatoriais.

Métodos para a estimação das matrizes L e Ψ

Quando usar um método ou outro?

Se a suposição de normalidade é válida, o método da máxima verossimilhança pode produzir estimativas mais precisas.

Se não podemos supor a normalidade multivariada, convém utilizar o método de fatores principais ou fatores principais iterativo.

Observação: Diferentes valores de m podem levar a diferentes estimativas das cargas fatoriais.

Métodos para a estimação das matrizes L e Ψ

Quando usar um método ou outro?

Se a suposição de normalidade é válida, o método da máxima verossimilhança pode produzir estimativas mais precisas.

Se não podemos supor a normalidade multivariada, convém utilizar o método de fatores principais ou fatores principais iterativo.

Observação: Diferentes valores de m podem levar a diferentes estimativas das cargas fatoriais.

Rotação ortogonal de fatores (Mingoti, 2007)

Objetivo: Aplicar transformações ortogonais aos fatores originais de modo que os novos fatores obtidos tenham interpretações mais fáceis e diretas.

Ideia: Considerar a matriz T ortogonal tal que $TT^{\top} = T^{\top}T = I$ e rotacionar a matriz de cargas fatoriais fazendo

$$\hat{L}^* = \hat{L}T.$$

Note que

$$\hat{L}^*\hat{L}^{*\top} = (\hat{L}T)(\hat{L}T)^{\top} = \hat{L}\hat{L}^{\top}.$$

Rotação ortogonal de fatores (Mingoti, 2007)

Objetivo: Aplicar transformações ortogonais aos fatores originais de modo que os novos fatores obtidos tenham interpretações mais fáceis e diretas.

Ideia: Considerar a matriz T ortogonal tal que $TT^{\top} = T^{\top}T = I$ e rotacionar a matriz de cargas fatoriais fazendo

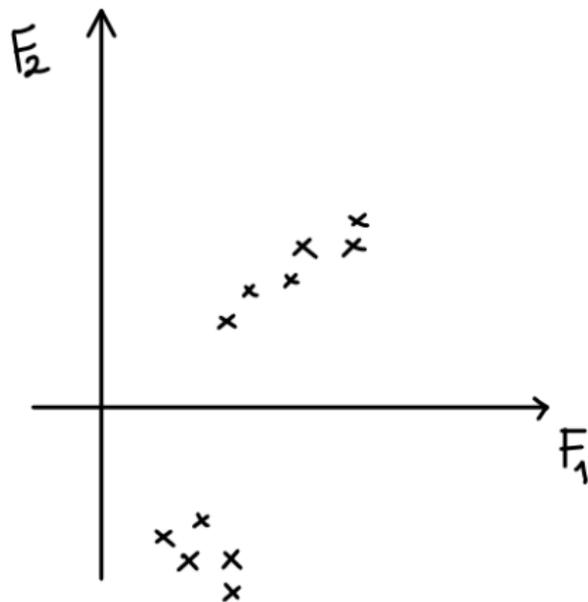
$$\hat{L}^{\star} = \hat{L}T.$$

Note que

$$\hat{L}^{\star}\hat{L}^{\star\top} = (\hat{L}T)(\hat{L}T)^{\top} = \hat{L}\hat{L}^{\top}.$$

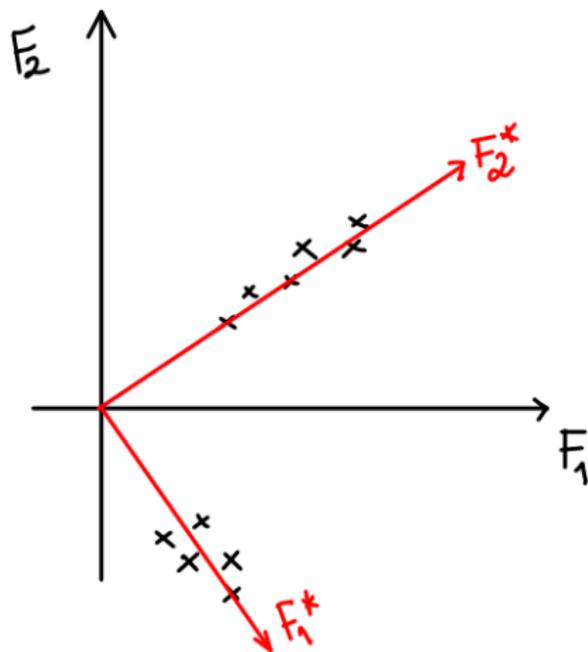
Rotação ortogonal de fatores

Interpretação geométrica ($p = 2$)



Rotação ortogonal de fatores

Interpretação geométrica ($p = 2$)



Critérios para a rotação ortogonal de fatores

Critério varimax: (Kaiser 1958)

Objetivo: Encontrar fatores com variabilidade máxima nas cargas fatoriais.

Seja \hat{l}_{ij}^* o coeficiente da i -ésima variável no j -ésimo fator após a rotação.

Seja

$$V = \frac{1}{p} \sum_{j=1}^m \left[\sum_{i=1}^p \tilde{l}_{ij}^4 - \frac{1}{p} \left(\sum_{i=1}^p \tilde{l}_{ij}^2 \right)^2 \right]$$

em que $\tilde{l}_{ij} = \frac{\hat{l}_{ij}^*}{\hat{h}_i}$.

O critério **varimax** busca \tilde{l}_{ij} que levam a V máximo para $i = 1, \dots, p$.

Critérios para a rotação ortogonal de fatores

Critério quartimax: (Jobson, 1996)

Objetivo: Encontrar fatores que levem ao máximo da variabilidade dos quadrados das cargas fatoriais sobre todos os fatores.

Seja \hat{l}_{ij}^* o coeficiente da i -ésima variável no j -ésimo fator após a rotação.
Seja

$$V_Q = \frac{1}{pm} \sum_{j=1}^m \sum_{i=1}^p \hat{l}_{ij}^{*4} - \frac{1}{pm} \sum_{j=1}^m \sum_{i=1}^p (\hat{l}_{ij}^{*2})^2$$

O critério **quartimax** busca \tilde{l}_{ij} que levam a V_Q ao seu valor máximo.

Critérios para a rotação ortogonal de fatores

Critério orthomax: (Jobson, 1996)

Seja \hat{l}_{ij}^* o coeficiente da i -ésima variável no j -ésimo fator após a rotação.

Seja

$$V_M = \frac{1}{pm} \sum_{j=1}^m \left[\sum_{i=1}^p \hat{l}_{ij}^{*4} - \frac{\gamma}{p} \sum_{i=1}^m \sum_{i=1}^p (\hat{l}_{ij}^{*2})^2 \right]$$

O critério **orthomax** busca \hat{l}_{ij}^* que levam a V_M ao seu valor máximo.

Se $\gamma = 0$, temos o critério quartimax.

Se $\gamma = 1$, o critério se assemelha ao varimax.

Se $\gamma = 0,5$, o critério se chama biquartimax.

Estimação dos escores \hat{F} para cada elemento amostral

Os escores das componentes podem ser usados para a ordenação das observações, por exemplo. Duas possíveis estratégias:

Mínimos quadrados ponderados

$$\hat{F}_j = (\hat{L}^\top \hat{\Psi}^{-1} \hat{L})^{-1} (\hat{L}^\top \hat{\Psi}^{-1}) z_j, j = 1, \dots, n$$

Método de regressão

$$\hat{F}_j = \hat{L}^\top \hat{P}^{-1} z_j, j = 1, \dots, n$$

Estimação dos escores \hat{F} para cada elemento amostral

Os escores das componentes podem ser usados para a ordenação das observações, por exemplo. Duas possíveis estratégias:

Mínimos quadrados ponderados

$$\hat{F}_j = (\hat{L}^\top \hat{\Psi}^{-1} \hat{L})^{-1} (\hat{L}^\top \hat{\Psi}^{-1}) z_j, j = 1, \dots, n$$

Método de regressão

$$\hat{F}_j = \hat{L}^\top \hat{P}^{-1} z_j, j = 1, \dots, n$$