

# ME731 - Métodos em Análise Multivariada – Análise Fatorial I –

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

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



Aula 13

# Agenda I

- 1 Introdução
- 2 Motivação
- 3 Modelo Fatorial
- 4 Estimação

# Introdução

# Introdução

- **Caso 1:** suponha que estamos interessados em estudar o desenvolvimento humano dos países do mundo e que dispomos de um conjunto de variáveis econômicas, sociais e demográficas relacionadas com desenvolvimento humano.

# Introdução

- **Caso 1:** suponha que estamos interessados em estudar o desenvolvimento humano dos países do mundo e que dispomos de um conjunto de variáveis econômicas, sociais e demográficas relacionadas com desenvolvimento humano. **Uma pergunta interessante é se o desenvolvimento de um país pode ser explicado por um pequeno número de fatores tais que, conhecidos seus valores, poderíamos conhecer o conjunto de variáveis de cada país.**

# Introdução

- **Caso 1:** suponha que estamos interessados em estudar o desenvolvimento humano dos países do mundo e que dispomos de um conjunto de variáveis econômicas, sociais e demográficas relacionadas com desenvolvimento humano. **Uma pergunta interessante é se o desenvolvimento de um país pode ser explicado por um pequeno número de fatores tais que, conhecidos seus valores, poderíamos conhecer o conjunto de variáveis de cada país.**
- **Caso 2:** suponha que medimos, através de diversos testes, a capacidade mental de indivíduos para processar informação e resolver problemas.

# Introdução

- **Caso 1:** suponha que estamos interessados em estudar o desenvolvimento humano dos países do mundo e que dispomos de um conjunto de variáveis econômicas, sociais e demográficas relacionadas com desenvolvimento humano. Uma pergunta interessante é se o desenvolvimento de um país pode ser explicado por um pequeno número de fatores tais que, conhecidos seus valores, poderíamos conhecer o conjunto de variáveis de cada país.
- **Caso 2:** suponha que medimos, através de diversos testes, a capacidade mental de indivíduos para processar informação e resolver problemas. Será que existem fatores, não diretamente observáveis, que explicam os resultados observados?

# Introdução

- **Caso 1:** suponha que estamos interessados em estudar o desenvolvimento humano dos países do mundo e que dispomos de um conjunto de variáveis econômicas, sociais e demográficas relacionadas com desenvolvimento humano. **Uma pergunta interessante é se o desenvolvimento de um país pode ser explicado por um pequeno número de fatores tais que, conhecidos seus valores, poderíamos conhecer o conjunto de variáveis de cada país.**
- **Caso 2:** suponha que medimos, através de diversos testes, a capacidade mental de indivíduos para processar informação e resolver problemas. **Será que existem fatores, não diretamente observáveis, que explicam os resultados observados? (esses fatores seriam a *inteligência*, por exemplo).**



# Introdução

- **Caso 1:** suponha que estamos interessados em estudar o desenvolvimento humano dos países do mundo e que dispomos de um conjunto de variáveis econômicas, sociais e demográficas relacionadas com desenvolvimento humano. *Uma pergunta interessante é se o desenvolvimento de um país pode ser explicado por um pequeno número de fatores tais que, conhecidos seus valores, poderíamos conhecer o conjunto de variáveis de cada país.*
- **Caso 2:** suponha que medimos, através de diversos testes, a capacidade mental de indivíduos para processar informação e resolver problemas. *Será que existem fatores, não diretamente observáveis, que explicam os resultados observados? (esses fatores seriam a *inteligência*, por exemplo).*

*Fonte: Análisis de Datos Multivariantes (Daniel Peña, 2002)*

# Introdução

- Análise Fatorial tem como objetivo explicar um conjunto de variáveis através de um pequeno número de variáveis latentes (chamadas de *fatores*).

# Introdução

- Análise Fatorial tem como objetivo explicar um conjunto de variáveis através de um pequeno número de variáveis latentes (chamadas de *fatores*).
- Desde outro ponto de vista, análise fatorial tenta explicar a correlação de um conjunto de variáveis através de um número pequeno de fatores (veremos que ambos pontos de vista implicam no mesmo problema).

# Introdução


- Análise Fatorial tem como objetivo explicar um conjunto de variáveis através de um pequeno número de variáveis latentes (chamadas de *fatores*).
- Desde outro ponto de vista, análise fatorial tenta explicar a correlação de um conjunto de variáveis através de um número pequeno de fatores (veremos que ambos pontos de vista implicam no mesmo problema).
- Embora as variáveis dependam de fatores, também estão sujeitas a perturbações aleatórias.

# Introdução

- Análise Fatorial tem como objetivo explicar um conjunto de variáveis através de um pequeno número de variáveis latentes (chamadas de *fatores*).
- Desde outro ponto de vista, análise fatorial tenta explicar a correlação de um conjunto de variáveis através de um número pequeno de fatores (veremos que ambos pontos de vista implicam no mesmo problema).
- Embora as variáveis dependam de fatores, também estão sujeitas a perturbações aleatórias.
- Os fatores não são observados diretamente.


# Introdução

## Variáveis não observáveis?



# Introdução

## Variáveis não observáveis?



- Esse conceito é bastante comum em psicologia onde aquilo que queremos mensurar não é diretamente observável (*inteligência*, por exemplo).
- Entre as áreas nas quais esta técnica é utilizada temos: marketing, economia, finanças, ciência política, psicologia, etc.

# Motivação



# Motivação

Um estudo aplicado em crianças mede o desempenho delas em Espanhol ( $X_1$ ), Português ( $X_2$ ) e Inglês ( $X_3$ ).

A Matriz de correlação entre as três variáveis é dada por:

$$\begin{pmatrix} 1 & 0.83 & 0.78 \\ 0.83 & 1 & 0.67 \\ 0.78 & 0.67 & 1 \end{pmatrix}$$

# Motivação

Um estudo aplicado em crianças mede o desempenho delas em Espanhol ( $X_1$ ), Português ( $X_2$ ) e Inglês ( $X_3$ ).

A Matriz de correlação entre as três variáveis é dada por:

$$\begin{pmatrix} 1 & 0.83 & 0.78 \\ 0.83 & 1 & 0.67 \\ 0.78 & 0.67 & 1 \end{pmatrix}$$

E se existir um fator (latente) que nos ajude a entender essa correlação toda?

# Motivação

Se existir esse fator, podemos reescrever as três variáveis da seguinte forma:

$$X_1 = \lambda_1 f + u_1, \quad X_2 = \lambda_2 f + u_2, \quad X_3 = \lambda_3 f + u_3,$$

em que

# Motivação

Se existir esse fator, podemos reescrever as três variáveis da seguinte forma:

$$X_1 = \lambda_1 f + u_1, \quad X_2 = \lambda_2 f + u_2, \quad X_3 = \lambda_3 f + u_3,$$

em que

- $f$  é um *fator comum* não observável,
- $\lambda_1, \lambda_2, \lambda_3$  são *cargas fatoriais*,
- $u_1, u_2, u_3$  são perturbações aleatórias.

$f$  pode ser entendido como uma *habilidade geral* e  $u_i$  terá uma variabilidade pequena se  $x_i$  estiver estreitamente relacionada com essa *habilidade geral*.

# Modelo Fatorial

# Modelo Fatorial

Seja  $\mathbf{X} = (X_1, \dots, X_p)' \sim (\mu, \Sigma)$ . Dizemos que o modelo fatorial (com  $k$  fatores) de  $\mathbf{X}$  acontece se podemos escrever

$$\mathbf{X} = \mu + \Lambda f + \mathbf{u}$$

# Modelo Fatorial

Seja  $\mathbf{X} = (X_1, \dots, X_p)' \sim (\mu, \Sigma)$ . Dizemos que o modelo fatorial (com  $k$  fatores) de  $\mathbf{X}$  acontece se podemos escrever

$$\mathbf{X} = \mu + \Lambda f + \mathbf{u}$$

- $\Lambda_{p \times k}$  é uma matriz de constantes,
- $f_{k \times 1}$  e  $\mathbf{u}_{p \times 1}$  são vetores aleatórios.

# Modelo Fatorial

Seja  $\mathbf{X} = (X_1, \dots, X_p)' \sim (\mu, \Sigma)$ . Dizemos que o modelo fatorial (com  $k$  fatores) de  $\mathbf{X}$  acontece se podemos escrever

$$\mathbf{X} = \mu + \Lambda f + \mathbf{u}$$

- $\Lambda_{p \times k}$  é uma matriz de constantes,
- $f_{k \times 1}$  e  $\mathbf{u}_{p \times 1}$  são vetores aleatórios.

Os elementos de  $f$  são chamados *fatores comuns* (ou simplesmente *fatores*) e os elementos de  $\mathbf{u}$  chamados de *fatores específicos*, *fatores únicos* ou *fatores idiossincráticos*.



# Modelo Fatorial

Seja  $\mathbf{X} = (X_1, \dots, X_p)' \sim (\mu, \Sigma)$ . Dizemos que o modelo fatorial (com  $k$  fatores) de  $\mathbf{X}$  acontece se podemos escrever

$$\mathbf{X} = \mu + \Lambda f + \mathbf{u}$$

- $\Lambda_{p \times k}$  é uma matriz de constantes,
- $f_{k \times 1}$  e  $\mathbf{u}_{p \times 1}$  são vetores aleatórios.

Os elementos de  $f$  são chamados *fatores comuns* (ou simplesmente *fatores*) e os elementos de  $\mathbf{u}$  chamados de *fatores específicos*, *fatores únicos* ou *fatores idiossincráticos*.

O modelo é construído sob algumas suposições, as quais são apresentadas a seguir:

# Modelo Fatorial: Suposições

- $\mathbb{E}(f) = 0$  e  $\mathbb{V}(f) = \mathbf{I}$ ,
- $\mathbb{E}(\mathbf{u}) = 0$ ,  $\text{Cov}(u_i, u_j) = 0$  e  $\text{Cov}(f, \mathbf{u}) = 0$
- Consequentemente,  $\mathbb{V}(u) = \mathbf{\Psi} = \text{Diag}\{\psi_1, \dots, \psi_p\}$

## Modelo Fatorial: Suposições

- $\mathbb{E}(f) = 0$  e  $\mathbb{V}(f) = \mathbf{I}$ ,
- $\mathbb{E}(\mathbf{u}) = 0$ ,  $\text{Cov}(u_i, u_j) = 0$  e  $\text{Cov}(f, \mathbf{u}) = 0$
- Consequentemente,  $\mathbb{V}(u) = \mathbf{\Psi} = \text{Diag}\{\psi_1, \dots, \psi_p\}$

Os fatores comuns são não correlacionados (entre eles mesmos e com os fatores idiossincráticos), têm média zero e variância um.

## Modelo Fatorial: Suposições

- $\mathbb{E}(f) = 0$  e  $\mathbb{V}(f) = \mathbf{I}$ ,
- $\mathbb{E}(\mathbf{u}) = 0$ ,  $\text{Cov}(u_i, u_j) = 0$  e  $\text{Cov}(f, \mathbf{u}) = 0$
- Consequentemente,  $\mathbb{V}(u) = \mathbf{\Psi} = \text{Diag}\{\psi_1, \dots, \psi_p\}$

Os fatores comuns são não correlacionados (entre eles mesmos e com os fatores idiossincráticos), têm média zero e variância um.

- Outra suposição às vezes utilizada é que tanto  $f$  quanto  $\mathbf{u}$  tem distribuição Normal multivariada.

# Modelo Fatorial

Modelo Fatorial:  $\mathbf{X} = \mu + \Lambda f + \mathbf{u}$ ,

Pode-se obter facilmente que  $X_i = \mu_i + \sum_{j=1}^k \lambda_{ij} f_j + u_i$ ,  $i = 1, \dots, p$ .

# Modelo Fatorial

Modelo Fatorial:  $\mathbf{X} = \mu + \Lambda f + \mathbf{u}$ ,

Pode-se obter facilmente que  $X_i = \mu_i + \sum_{j=1}^k \lambda_{ij} f_j + u_i$ ,  $i = 1, \dots, p$ .

Assim,  $\mathbb{V}(X_i) = \sigma_i^2 = \underbrace{\sum_{j=1}^k \lambda_{ij}^2}_{h_i^2} + \psi_i^2 = h_i^2 + \psi_i^2$

# Modelo Fatorial

Modelo Fatorial:  $\mathbf{X} = \mu + \Lambda f + \mathbf{u}$ ,

Pode-se obter facilmente que  $X_i = \mu_i + \sum_{j=1}^k \lambda_{ij} f_j + u_i$ ,  $i = 1, \dots, p$ .

Assim, 
$$\mathbb{V}(X_i) = \sigma_i^2 = \underbrace{\sum_{j=1}^k \lambda_{ij}^2}_{h_i^2} + \psi_i^2 = h_i^2 + \psi_i^2$$

- $h_i^2$ : é chamada de *comunalidade* (variância comum) e representa a variância de  $X_i$  que é explicada pelos *fatores comuns*.
- $\psi_i^2$ : é chamada de *variância específica* e representa a variabilidade de  $X_i$  que não é explicada pelos *fatores comuns*.

# Modelo Fatorial

Modelo Fatorial:  $\mathbf{X} = \mu + \Lambda f + \mathbf{u},$



# Modelo Fatorial

$$\text{Modelo Fatorial: } \mathbf{X} = \mu + \Lambda f + \mathbf{u},$$

Se o modelo fatorial acontece, então  $\mathbb{V}(\mathbf{X})$ , denotada por  $\Sigma$  é dada por

$$\mathbb{V}(\mathbf{X}) = \Sigma = \Lambda\Lambda' + \Psi \quad (1)$$

O contrário também é válido. Se (1) acontece, então o modelo fatorial acontece para  $\mathbf{X}$ .

# Modelo Fatorial

## Propriedades:

$$\text{Cov}(\mathbf{X}, f) = \Lambda$$

# Modelo Fatorial

## Propriedades:

$$\text{Cov}(\mathbf{X}, f) = \Lambda$$

$$\text{Cov}(\mathbf{X}, f) = \text{Cov}(\mu + \Lambda f + \mathbf{u}, f) \quad (2)$$

$$= \Lambda \underbrace{\text{Cov}(f, f)}_1 + \underbrace{\text{Cov}(\mathbf{u}, f)}_0 \quad (3)$$

$$= \Lambda \quad (4)$$

# Modelo Fatorial: Invariância

## Propriedades:

Seja  $C = \text{diag}\{c_1, \dots, c_p\}$ , o que acontece se mudamos a escala de  $\mathbf{X}$  para  $\mathbf{Y} = \mathbf{C}\mathbf{X}$ ?

## Modelo Fatorial: Invariância

### Propriedades:

Seja  $C = \text{diag}\{c_1, \dots, c_p\}$ , o que acontece se mudamos a escala de  $\mathbf{X}$  para  $\mathbf{Y} = C\mathbf{X}$ ?

Se o modelo fatorial acontecer para  $\mathbf{X}$  temos que  $\mathbf{X} = \mu + \Lambda f + \mathbf{u}$

# Modelo Fatorial: Invariância

## Propriedades:

Seja  $C = \text{diag}\{c_1, \dots, c_p\}$ , o que acontece se mudamos a escala de  $\mathbf{X}$  para  $\mathbf{Y} = C\mathbf{X}$ ?

Se o modelo fatorial acontecer para  $\mathbf{X}$  temos que  $\mathbf{X} = \mu + \Lambda f + \mathbf{u}$

Então,

$$\bullet \mathbf{Y} = C\mathbf{X} = \underbrace{C\mu}_{\mu_y} + \underbrace{C\Lambda}_{\Lambda_y} f + \underbrace{C\mathbf{u}}_{\mathbf{u}_y}$$

$$\bullet \mathbb{V}(\mathbf{Y}) = \mathbb{V}(C\mathbf{X}) = C\mathbb{V}(\mathbf{X})C' = C[\Lambda\Lambda' + \Psi]C' = \underbrace{C\Lambda}_{\Lambda_y} \underbrace{\Lambda'C'}_{\Lambda'_y} + \underbrace{C\Psi C'}_{\Psi_{u_y}}$$

# Modelo Fatorial: Invariância

## Propriedades:

Seja  $C = \text{diag}\{c_1, \dots, c_p\}$ , o que acontece se mudamos a escala de  $\mathbf{X}$  para  $\mathbf{Y} = \mathbf{C}\mathbf{X}$ ?

Se o modelo fatorial acontecer para  $\mathbf{X}$  temos que  $\mathbf{X} = \boldsymbol{\mu} + \boldsymbol{\Lambda}f + \mathbf{u}$

Então,

- $\mathbf{Y} = \mathbf{C}\mathbf{X} = \underbrace{\mathbf{C}\boldsymbol{\mu}}_{\boldsymbol{\mu}_y} + \underbrace{\mathbf{C}\boldsymbol{\Lambda}}_{\boldsymbol{\Lambda}_y} f + \underbrace{\mathbf{C}\mathbf{u}}_{\mathbf{u}_y}$
- $\mathbb{V}(\mathbf{Y}) = \mathbb{V}(\mathbf{C}\mathbf{X}) = \mathbf{C}\mathbb{V}(\mathbf{X})\mathbf{C}' = \mathbf{C}[\boldsymbol{\Lambda}\boldsymbol{\Lambda}' + \boldsymbol{\Psi}]\mathbf{C}' = \underbrace{\mathbf{C}\boldsymbol{\Lambda}}_{\boldsymbol{\Lambda}_y} \underbrace{\boldsymbol{\Lambda}'\mathbf{C}'}_{\boldsymbol{\Lambda}'_y} + \underbrace{\mathbf{C}\boldsymbol{\Psi}\mathbf{C}'}_{\boldsymbol{\Psi}_{u_y}}$

O modelo fatorial também acontece para  $\mathbf{Y}$ , tem matriz de cargas fatoriais dada por  $\boldsymbol{\Lambda}_y = \mathbf{C}\boldsymbol{\Lambda}$ , variância específica  $\boldsymbol{\Psi}_{u_y} = \mathbf{C}\boldsymbol{\Psi}\mathbf{C}$  e fator  $f$ .

# Modelo Fatorial: Não unicidade das cargas fatoriais

As cargas fatoriais **não** são únicas!



# Modelo Fatorial: Não unicidade das cargas fatoriais

As cargas fatoriais **não** são únicas!

Seja o modelo fatorial para  $\mathbf{X}$

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

e seja  $G$  uma matriz ortogonal qualquer. Então,

$$\mathbf{X} = \mu + \Lambda G(G'f) + \mathbf{u}.$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

As cargas fatoriais **não** são únicas!

Seja o modelo fatorial para  $\mathbf{X}$

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

e seja  $G$  uma matriz ortogonal qualquer. Então,

$$\mathbf{X} = \mu + \Lambda G(G'f) + \mathbf{u}.$$

- Se  $f$  e  $\Lambda$  são os fatores e as cargas fatoriais para  $\mathbf{X}$ , então  $G'f$  e  $\Lambda G$  também são.

# Modelo Fatorial: Não unicidade das cargas fatoriais

As cargas fatoriais **não** são únicas!

Seja o modelo fatorial para  $\mathbf{X}$

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

e seja  $G$  uma matriz ortogonal qualquer. Então,


$$\mathbf{X} = \mu + \Lambda G(G'f) + \mathbf{u}.$$

- Se  $f$  e  $\Lambda$  são os fatores e as cargas fatoriais para  $\mathbf{X}$ , então  $G'f$  e  $\Lambda G$  também são.
- **Isto é bom ou ruim?**

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Pros:

- Premultiplicar  $f$  por uma matriz ortogonal corresponde a uma rotação do sistema de coordenadas.
- A direção do primeiro eixo será dada pela primeira linha da matriz ortogonal.
- Escolher uma rotação apropriadas resultará em uma matriz de cargas  $\Lambda G$  que é **mais facil de interpretar!**



# Modelo Fatorial: Não unicidade das cargas fatoriais



## Contras:

- Desde um ponto de vista numérico, a não unicidade é um problema.
- Temos que encontrar matrizes  $\Lambda$  e  $\Psi$  tais que  $\Sigma = \Lambda\Lambda' + \Psi$ . Infelizmente numericamente isto não é tão simples devido à multiplicidade da solução.

O problema pode ser contornado impondo restrições para obter uma única solução à decomposição (e depois dessa solução podemos tomar vantagem das rotações).

# Modelo Fatorial: Não unicidade das cargas fatoriais

**Quais restrições vamos a impor para eliminar o problema da não unicidade?**

## Modelo Fatorial: Não unicidade das cargas fatoriais

**Quais restrições vamos a impor para eliminar o problema da não unicidade?**

$$\Lambda' \Psi^{-1} \Lambda \quad \text{ou} \quad \Lambda' \mathbf{D}^{-1} \Lambda \quad \text{ser diagonal.} \quad (5)$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

**Quais restrições vamos a impor para eliminar o problema da não unicidade?**

$$\Lambda' \Psi^{-1} \Lambda \quad \text{ou} \quad \Lambda' \mathbf{D}^{-1} \Lambda \quad \text{ser diagonal.} \quad (5)$$

- Note que  $\Sigma$  tem  $p(p + 1)/2$  parametros a serem estimados.
- Por outro lado  $\Lambda' \Lambda + \Psi$  tem  $pk + p$  parametros a serem estimados ( $pk$  vindo de  $\Lambda_{p \times k}$  e  $p$  vindos de  $\Psi$ ).
- (5) introduze  $k(k - 1)/2$  restrições.
- Assim, o número de graus de liberdade do modelo fatorial é

$$d = \frac{1}{2}p(p + 1) - [(pk + p) - \frac{1}{2}k(k - 1)] = \frac{1}{2}(p - k)^2 - \frac{1}{2}(p + k).$$



## Modelo Fatorial: Não unicidade das cargas fatoriais

$$d = \frac{1}{2}p(p+1) - [(pk+p) - \frac{1}{2}k(k-1)] = \frac{1}{2}(p-k)^2 - \frac{1}{2}(p+k).$$

- **Se**  $d < 0$ , o modelo é indeterminado.

## Modelo Fatorial: Não unicidade das cargas fatoriais

$$d = \frac{1}{2}p(p+1) - [(pk+p) - \frac{1}{2}k(k-1)] = \frac{1}{2}(p-k)^2 - \frac{1}{2}(p+k).$$

- **Se**  $d < 0$ , o modelo é indeterminado. (isto significa que o número de parâmetros do modelo fatorial é maior do que o número de parâmetros do modelo original. Reduzir  $k$  pode ajudar).

## Modelo Fatorial: Não unicidade das cargas fatoriais

$$d = \frac{1}{2}p(p+1) - [(pk+p) - \frac{1}{2}k(k-1)] = \frac{1}{2}(p-k)^2 - \frac{1}{2}(p+k).$$

- **Se**  $d < 0$ , o modelo é indeterminado. (isto significa que o número de parâmetros do modelo fatorial é maior do que o número de parâmetros do modelo original. Reduzir  $k$  pode ajudar).
- **Se**  $d = 0$ , o modelo tem solução única (exceto, é claro, pelas rotações).

## Modelo Fatorial: Não unicidade das cargas fatoriais

$$d = \frac{1}{2}p(p+1) - [(pk+p) - \frac{1}{2}k(k-1)] = \frac{1}{2}(p-k)^2 - \frac{1}{2}(p+k).$$

- **Se**  $d < 0$ , o modelo é indeterminado. (isto significa que o número de parâmetros do modelo fatorial é maior do que o número de parâmetros do modelo original. Reduzir  $k$  pode ajudar).
- **Se**  $d = 0$ , o modelo tem solução única (exceto, é claro, pelas rotações).
- **Se**  $d > 0$  (o que mais acontece na prática), temos mais equações do que parâmetros e não existe uma solução exata

## Modelo Fatorial: Não unicidade das cargas fatoriais

$$d = \frac{1}{2}p(p+1) - [(pk+p) - \frac{1}{2}k(k-1)] = \frac{1}{2}(p-k)^2 - \frac{1}{2}(p+k).$$

- **Se**  $d < 0$ , o modelo é indeterminado. (isto significa que o número de parâmetros do modelo fatorial é maior do que o número de parâmetros do modelo original. Reduzir  $k$  pode ajudar).
- **Se**  $d = 0$ , o modelo tem solução única (exceto, é claro, pelas rotações).
- **Se**  $d > 0$  (o que mais acontece na prática), temos mais equações do que parâmetros e não existe uma solução exata (nestes casos, soluções aproximadas são utilizadas).

## Modelo Fatorial: Não unicidade das cargas fatoriais

$$d = \frac{1}{2}p(p+1) - [(pk+p) - \frac{1}{2}k(k-1)] = \frac{1}{2}(p-k)^2 - \frac{1}{2}(p+k).$$

- **Se**  $d < 0$ , o modelo é indeterminado. (isto significa que o número de parâmetros do modelo fatorial é maior do que o número de parâmetros do modelo original. Reduzir  $k$  pode ajudar).
- **Se**  $d = 0$ , o modelo tem solução única (exceto, é claro, pelas rotações).
- **Se**  $d > 0$  (o que mais acontece na prática), temos mais equações do que parâmetros e não existe uma solução exata (nestes casos, soluções aproximadas são utilizadas).

**Para pensar:** Se tivermos  $p = 4$  variáveis, utilizaria  $k = 2$  fatores?

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 1:

Suponha  $p = 2$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} = \Lambda\Lambda' + \Psi = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1\lambda_2 \\ \lambda_1\lambda_2 & \lambda_2^2 + \psi_{22} \end{pmatrix}$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 1:

Suponha  $p = 2$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} = \Lambda\Lambda' + \Psi = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1\lambda_2 \\ \lambda_1\lambda_2 & \lambda_2^2 + \psi_{22} \end{pmatrix}$$

- $1 = \lambda_1^2 + \psi_{11}$ ,  $\rho = \lambda_1\lambda_2$  e  $1 = \lambda_2^2 + \psi_{22}$ .



# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 1:

Suponha  $p = 2$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} = \Lambda\Lambda' + \Psi = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1\lambda_2 \\ \lambda_1\lambda_2 & \lambda_2^2 + \psi_{22} \end{pmatrix}$$

- $1 = \lambda_1^2 + \psi_{11}$ ,  $\rho = \lambda_1\lambda_2$  e  $1 = \lambda_2^2 + \psi_{22}$ .
- $\lambda_2 = \rho/\lambda_1$ ,  $\psi_{11} = 1 - \lambda_1^2$  e  $\psi_{22} = 1 - (\rho/\lambda_1)^2$

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 1:

Suponha  $p = 2$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} = \Lambda\Lambda' + \Psi = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1\lambda_2 \\ \lambda_1\lambda_2 & \lambda_2^2 + \psi_{22} \end{pmatrix}$$

- $1 = \lambda_1^2 + \psi_{11}$ ,  $\rho = \lambda_1\lambda_2$  e  $1 = \lambda_2^2 + \psi_{22}$ .
- $\lambda_2 = \rho/\lambda_1$ ,  $\psi_{11} = 1 - \lambda_1^2$  e  $\psi_{22} = 1 - (\rho/\lambda_1)^2$

Infinitas soluções! (o sistema é indeterminado)

$$d = \frac{1}{2}(p - k)^2 - \frac{1}{2}(p + k) = -1$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 2:

Suponha  $p = 3$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} \\ \sigma_{21} & \sigma_{22} & \sigma_{23} \\ \sigma_{31} & \sigma_{32} & \sigma_{33} \end{pmatrix} = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1 \lambda_2 & \lambda_1 \lambda_3 \\ \lambda_1 \lambda_2 & \lambda_2^2 + \psi_{22} & \lambda_2 \lambda_3 \\ \lambda_1 \lambda_3 & \lambda_2 \lambda_3 & \lambda_3^2 + \psi_{33} \end{pmatrix}$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 2:

Suponha  $p = 3$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} \\ \sigma_{21} & \sigma_{22} & \sigma_{23} \\ \sigma_{31} & \sigma_{32} & \sigma_{33} \end{pmatrix} = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1 \lambda_2 & \lambda_1 \lambda_3 \\ \lambda_1 \lambda_2 & \lambda_2^2 + \psi_{22} & \lambda_2 \lambda_3 \\ \lambda_1 \lambda_3 & \lambda_2 \lambda_3 & \lambda_3^2 + \psi_{33} \end{pmatrix}$$

Então,

- $\lambda_1^2 = \frac{\sigma_{12}\sigma_{13}}{\sigma_{23}}$ ,  $\lambda_2^2 = \frac{\sigma_{12}\sigma_{23}}{\sigma_{13}}$  e  $\lambda_3^2 = \frac{\sigma_{13}\sigma_{23}}{\sigma_{12}}$
- $\psi_{11} = \sigma_{11} - \lambda_1^2$ ,  $\psi_{22} = \sigma_{22} - \lambda_2^2$  e  $\psi_{33} = \sigma_{33} - \lambda_3^2$

# Modelo Fatorial: Não unicidade das cargas fatoriais

## Exemplo 2:

Suponha  $p = 3$ ,  $k = 1$  e seja

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} \\ \sigma_{21} & \sigma_{22} & \sigma_{23} \\ \sigma_{31} & \sigma_{32} & \sigma_{33} \end{pmatrix} = \begin{pmatrix} \lambda_1^2 + \psi_{11} & \lambda_1 \lambda_2 & \lambda_1 \lambda_3 \\ \lambda_1 \lambda_2 & \lambda_2^2 + \psi_{22} & \lambda_2 \lambda_3 \\ \lambda_1 \lambda_3 & \lambda_2 \lambda_3 & \lambda_3^2 + \psi_{33} \end{pmatrix}$$

Então,

- $\lambda_1^2 = \frac{\sigma_{12}\sigma_{13}}{\sigma_{23}}$ ,  $\lambda_2^2 = \frac{\sigma_{12}\sigma_{23}}{\sigma_{13}}$  e  $\lambda_3^2 = \frac{\sigma_{13}\sigma_{23}}{\sigma_{12}}$
- $\psi_{11} = \sigma_{11} - \lambda_1^2$ ,  $\psi_{22} = \sigma_{22} - \lambda_2^2$  e  $\psi_{33} = \sigma_{33} - \lambda_3^2$

$$d = \frac{1}{2}(p - k)^2 - \frac{1}{2}(p + k) = 0$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

No caso anterior, utilizemos

$$\Sigma = \begin{pmatrix} 1 & 0.9 & 0.7 \\ 0.9 & 1 & 0.4 \\ 0.7 & 0.4 & 1 \end{pmatrix}$$

# Modelo Fatorial: Não unicidade das cargas fatoriais

No caso anterior, utilizemos

$$\Sigma = \begin{pmatrix} 1 & 0.9 & 0.7 \\ 0.9 & 1 & 0.4 \\ 0.7 & 0.4 & 1 \end{pmatrix}$$

Então a solução

- $\lambda_1^2 = \frac{\sigma_{12}\sigma_{13}}{\sigma_{23}}$ ,  $\lambda_2^2 = \frac{\sigma_{12}\sigma_{23}}{\sigma_{13}}$  e  $\lambda_3^2 = \frac{\sigma_{13}\sigma_{23}}{\sigma_{12}}$
- $\psi_{11} = \sigma_{11} - \lambda_1^2$ ,  $\psi_{22} = \sigma_{22} - \lambda_2^2$  e  $\psi_{33} = \sigma_{33} - \lambda_3^2$

nos levará a:  $\psi_{11} = 1 - \frac{0.9 \times 0.7}{0.4} = -0.575$

# Modelo Fatorial: Não unicidade das cargas fatoriais

No caso anterior, utilizemos

$$\Sigma = \begin{pmatrix} 1 & 0.9 & 0.7 \\ 0.9 & 1 & 0.4 \\ 0.7 & 0.4 & 1 \end{pmatrix}$$

Então a solução

- $\lambda_1^2 = \frac{\sigma_{12}\sigma_{13}}{\sigma_{23}}$ ,  $\lambda_2^2 = \frac{\sigma_{12}\sigma_{23}}{\sigma_{13}}$  e  $\lambda_3^2 = \frac{\sigma_{13}\sigma_{23}}{\sigma_{12}}$
- $\psi_{11} = \sigma_{11} - \lambda_1^2$ ,  $\psi_{22} = \sigma_{22} - \lambda_2^2$  e  $\psi_{33} = \sigma_{33} - \lambda_3^2$

nos levará a:  $\psi_{11} = 1 - \frac{0.9 \times 0.7}{0.4} = -0.575$

**Variância negativa?**



# Modelo Fatorial: Não unicidade das cargas fatoriais

No caso anterior, utilizemos

$$\Sigma = \begin{pmatrix} 1 & 0.9 & 0.7 \\ 0.9 & 1 & 0.4 \\ 0.7 & 0.4 & 1 \end{pmatrix}$$

Então a solução

- $\lambda_1^2 = \frac{\sigma_{12}\sigma_{13}}{\sigma_{23}}$ ,  $\lambda_2^2 = \frac{\sigma_{12}\sigma_{23}}{\sigma_{13}}$  e  $\lambda_3^2 = \frac{\sigma_{13}\sigma_{23}}{\sigma_{12}}$
- $\psi_{11} = \sigma_{11} - \lambda_1^2$ ,  $\psi_{22} = \sigma_{22} - \lambda_2^2$  e  $\psi_{33} = \sigma_{33} - \lambda_3^2$

nos levará a:  $\psi_{11} = 1 - \frac{0.9 \times 0.7}{0.4} = -0.575$

**Variância negativa?** Cuidado! mesmo quando  $d = 0$ , a solução única pode apresentar inconsistências estatísticas.

# Estimação

# Estimação

Na prática temos uma matriz de dados

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

cuja informação pode ser sumarizada por  $\bar{\mathbf{x}}$  e  $\mathbf{S}$ .

# Estimação

Na prática temos uma matriz de dados

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

cuja informação pode ser sumarizada por  $\bar{\mathbf{x}}$  e  $\mathbf{S}$ .

O problema de interesse é estimar  $\Lambda$  e  $\Psi$  ( $\Sigma = \Lambda\Lambda' + \Psi$ ) a partir de  $\mathbf{S}$ .

# Estimação

Na práticas temos uma matriz de dados

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

cuja informação pode ser sumarizada por  $\bar{\mathbf{x}}$  e  $\mathbf{S}$ .

O problema de interesse é estimar  $\Lambda$  e  $\Psi$  ( $\Sigma = \Lambda\Lambda' + \Psi$ ) a partir de  $\mathbf{S}$ .

Ou seja, queremos  $\hat{\Lambda}$  e  $\hat{\Psi}$  tais que  $\mathbf{S} = \hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}$  (pelo menos aproximadamente).

# Estimação

Na práticas temos uma matriz de dados

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

cuja informação pode ser sumarizada por  $\bar{\mathbf{x}}$  e  $\mathbf{S}$ .

O problema de interesse é estimar  $\Lambda$  e  $\Psi$  ( $\Sigma = \Lambda\Lambda' + \Psi$ ) a partir de  $\mathbf{S}$ .

Ou seja, queremos  $\hat{\Lambda}$  e  $\hat{\Psi}$  tais que  $\mathbf{S} = \hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}$  (pelo menos aproximadamente).

Dado  $\hat{\Lambda}$ , é natural fazermos  $\hat{\psi}_{ii} = s_i^2 - \sum_{j=1}^k \hat{\lambda}_{ij}^2 = s_i^2 - \hat{h}_i^2$

# Referências

Na próxima aula veremos alguns métodos de estimação.

## 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.