

## Lezione : Analisi fattoriale

*Docente: Aldo Solari*

Nelle scienze sociali, in particolare in psicologia, spesso è problematico misurare le variabili di interesse direttamente. Ad esempio:

- Intelligenza
- Classe sociale

Queste variabili sono variabili non osservabili (variabili latenti), tuttavia è possibile esaminare queste variabili indirettamente, misurando variabili osservabili che sono ad esse collegate. Ad esempio

- Punteggio in varie prove di intelligenza, etc.
- Occupazione, Tasso di istruzione, Casa di proprietà, etc.

L'obiettivo dell'*analisi fattoriale* è studiare le relazioni tra le variabili osservabili e le variabili latenti (dette fattori comuni).

### 1 Il modello fattoriale con $k$ fattori

$$\begin{aligned}x_1 &= \lambda_{11}f_1 + \dots + \lambda_{1k}f_k + u_1 \\x_2 &= \lambda_{21}f_1 + \dots + \lambda_{2k}f_k + u_2 \\&\vdots \\x_p &= \lambda_{p1}f_1 + \dots + \lambda_{pk}f_k + u_p\end{aligned}$$

dove

- $x_{p \times 1} = (x_1, \dots, x_p)'$  sono le *variabili osservate* (variabili casuali)
- $f_{k \times 1} = (f_1, \dots, f_k)'$  sono i *fattori comuni* (var. casuali non oss.)
- $u_{p \times 1} = (u_1, \dots, u_p)'$  sono i *fattori specifici* (var. casuali non oss.)
- $\lambda_{ij}$  sono i *pesi fattoriali* (costanti incognite)

In forma matriciale:

$$x_{p \times 1} = \Lambda_{p \times k} f_{k \times 1} + u_{p \times 1}$$

## 1.1 Assunzioni

1. Variabili osservate:  $\mathbb{E} \begin{pmatrix} x \\ \vdots \\ x \end{pmatrix}_{p \times 1} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}_{p \times 1}$  (altrimenti si può sempre centrare  $x$  sullo 0 sottraendo la media  $\mu$ )
2. Fattori comuni:  $\mathbb{E} \begin{pmatrix} f \\ \vdots \\ f \end{pmatrix}_{k \times 1} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}_{k \times 1}$ ,  $\text{Cov} \begin{pmatrix} f \\ \vdots \\ f \end{pmatrix}_{k \times 1} = \mathbb{E} \begin{pmatrix} f & f' \\ \vdots & \vdots \\ f & f' \end{pmatrix}_{k \times 11 \times k} = \begin{pmatrix} I \\ \vdots \\ I \end{pmatrix}_{k \times k}$
3. Fattori specifici:  $\mathbb{E} \begin{pmatrix} u \\ \vdots \\ u \end{pmatrix}_{p \times 1} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}_{p \times 1}$ ,  $\text{Cov} \begin{pmatrix} u \\ \vdots \\ u \end{pmatrix}_{p \times 1} = \mathbb{E} \begin{pmatrix} u & u' \\ \vdots & \vdots \\ u & u' \end{pmatrix}_{p \times 11 \times p} = \Psi = \text{diag}(\psi_1, \dots, \psi_p)$
4. Incorrelazione tra  $f$  e  $u$ :  $\text{Cov} \begin{pmatrix} u \\ \vdots \\ u \end{pmatrix}_{p \times 1}, \begin{pmatrix} f \\ \vdots \\ f \end{pmatrix}_{k \times 1} = \mathbb{E} \begin{pmatrix} u & f' \\ \vdots & \vdots \\ u & f' \end{pmatrix}_{p \times 11 \times k} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}_{p \times k}$ ;  
 analogamente  $\text{Cov} \begin{pmatrix} f \\ \vdots \\ f \end{pmatrix}_{k \times 1}, \begin{pmatrix} u \\ \vdots \\ u \end{pmatrix}_{p \times 1} = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix}_{k \times p}$

## 1.2 Proprietà

**Proposition 1.1.** La matrice di varianza/covarianza  $\Sigma$  di  $x$  è data da

$$\Sigma_{p \times p} = \Lambda \Lambda'_{p \times k k \times p} + \Psi_{p \times p}$$

*Dimostrazione.*

$$\begin{aligned} \Sigma_{p \times p} &= \text{Cov} \begin{pmatrix} x \\ \vdots \\ x \end{pmatrix}_{p \times 1} = \mathbb{E} \begin{pmatrix} x & x' \\ \vdots & \vdots \\ x & x' \end{pmatrix}_{p \times 11 \times p} \\ &= \mathbb{E}[(\Lambda f + u)(\Lambda f + u)'] \\ &= \mathbb{E}[\Lambda f(\Lambda f)' + u(\Lambda f)' + (\Lambda f)u' + uu'] \\ &= \Lambda \mathbb{E}(f f') \Lambda' + \mathbb{E}(u f') \Lambda' + \Lambda \mathbb{E}(f u') + \mathbb{E}(u u') \\ &= \Lambda \text{Cov}(f) \Lambda' + \text{Cov}(u, f) \Lambda' + \Lambda \text{Cov}(f, u) + \text{Cov}(u) \\ &= \Lambda \Lambda' + \Psi \end{aligned}$$

□

Il modello fattoriale con  $k$  fattori ipotizza che

$$p(p+1)/2$$

parametri corrispondenti alle  $p$  varianze e alle  $p(p-1)/2$  covarianze di  $\Sigma_{p \times p}$  possano essere espressi con

$$p(k+1)$$

parametri corrispondenti ai  $pk$  pesi fattoriali di  $\Lambda_{p \times k}$  e le  $p$  varianze specifiche di  $\Psi_{p \times p}$ .

Per esempio, se abbiamo  $p = 12$  variabili osservabili  $x_{p \times 1}$  e un modello fattoriale con  $k = 2$  fattori,

allora i  $p(p+1)/2 = 78$  parametri di  $\Sigma_{p \times p}$  possono essere ridotti ai  $p(k+1) = 36$  parametri di  $\Lambda_{p \times k}$  e  $\Psi_{p \times p}$ .

La varianza di  $x_i$  si può esprimere come

$$\begin{aligned} \sigma_{ii} &= \text{Var}(x_i) = \{\Sigma_{p \times p}\}_{ii} = \{\Lambda\Lambda'\}_{ii} + \{\Psi\}_{ii} \\ &= \sum_{j=1}^k \lambda_{ij}^2 + \psi_i \\ &= \underbrace{h_i^2}_{\text{comunalita'}} + \underbrace{\psi_i}_{\text{var. specifica}} \end{aligned}$$

dove

- $h_i^2 = \lambda_{i1}^2 + \dots + \lambda_{ik}^2$  è la comunalità, ovvero la varianza dovuta ai  $k$  fattori comuni
- $\psi_i$  è la varianza specifica di  $x_i$  non attribuibile ai fattori comuni

La covarianza tra  $x_i$  e  $x_j$  si può esprimere come

$$\begin{aligned} \sigma_{ij} &= \text{Cov}(x_i, x_j) = \{\Sigma_{p \times p}\}_{ij} = \{\Lambda\Lambda'\}_{ij} + \{\Psi\}_{ij} \\ &= \sum_{l=1}^k \lambda_{il}\lambda_{jl} \\ &= \lambda_{i1}\lambda_{j1} + \dots + \lambda_{ik}\lambda_{jk} \end{aligned}$$

La covarianza tra  $x$  e  $f$  si può esprimere come

$$\begin{aligned} \text{Cov}\left(\begin{matrix} x \\ p \times 1 \end{matrix}, \begin{matrix} f \\ k \times 1 \end{matrix}\right) &= \mathbb{E}\left(\begin{matrix} x \\ p \times 1 \end{matrix} \begin{matrix} f' \\ 1 \times k \end{matrix}\right) \\ &= \mathbb{E}[(\Lambda f + u)f'] \\ &= \Lambda \mathbb{E}(ff') + \mathbb{E}(uf') \\ &= \Lambda_{p \times k} \end{aligned}$$

quindi il peso fattoriale  $\lambda_{ij}$  rappresenta la covarianza tra  $x_i$  e  $f_j$ :

$$\text{Cov}(x_i, f_j) = \{\Lambda_{p \times k}\}_{ij} = \lambda_{ij}$$

### 1.3 Invarianza rispetto a trasformazioni di scala

Assumiamo il modello fattoriale per  $x$ :

$$\begin{matrix} x \\ p \times 1 \end{matrix} = \begin{matrix} \Lambda \\ p \times k \end{matrix} \begin{matrix} f \\ k \times 1 \end{matrix} + \begin{matrix} u \\ p \times 1 \end{matrix}$$

Consideriamo una trasformazione di scala per  $x$ :

$$\underset{p \times 1}{y} = \underset{p \times p}{A} \underset{p \times 1}{x}$$

dove  $\underset{p \times p}{A} = \text{diag}(a_1, \dots, a_p)$  è una trasformazione di scala. Il modello fattoriale è ancora valido per  $y$ ? Abbiamo

$$\begin{aligned} \underset{p \times 1}{y} &= \underset{p \times p}{A} \underset{p \times 1}{x} \\ &= \underset{p \times p}{A} \left( \underset{p \times k}{\Lambda} \underset{k \times 1}{f} + \underset{p \times 1}{u} \right) \\ &= \underset{p \times p}{A} \underset{p \times k}{\Lambda} \underset{k \times 1}{f} + \underset{p \times p}{A} \underset{p \times 1}{u} \\ &= \underset{p \times k}{\Lambda_y} \underset{k \times 1}{f} + \underset{p \times 1}{u_y} \end{aligned}$$

e

$$\begin{aligned} \text{Cov}(y) &= \text{Cov}(Ax) \\ &= \mathbb{E}(Axx'A') \\ &= A\text{Cov}(x)A' \\ &= A\Sigma A' \\ &= A\Lambda\Lambda'A' + A\Psi A' \\ &= \Lambda_y\Lambda_y' + \Psi_y \end{aligned}$$

quindi il modello fattoriale è ancora valido per  $y$  con pesi fattoriali  $\Lambda_y = A\Lambda$  e varianze specifiche  $\Psi_y = A\Psi A'$ .

Il risultato precedente mostra che il modello fattoriale rimane essenzialmente inalterato se effettuiamo una trasformazione di scala. La standardizzazione

$$\underset{p \times 1}{z} = \underset{p \times p}{D}^{-1/2} \underset{p \times 1}{x}$$

è un caso particolare di trasformazione di scala con  $A = D^{-1/2}$  dove

$$D^{-1/2} = \text{diag}(1/\sqrt{\sigma_{11}}, \dots, 1/\sqrt{\sigma_{pp}})$$

Questo significa che, invece di considerare la decomposizione della matrice di varianze/covarianze di  $x$ ,  $\text{Cov}(x)$ , possiamo considerare la decomposizione della matrice di correlazione di  $x$ ,  $\text{Corr}(x)$ , o equivalentemente, la decomposizione della matrice di varianze/covarianze di  $z$ ,  $\text{Cov}(z) = D^{-1/2}\Sigma D^{-1/2} = \text{Corr}(x)$ .

Si noti che sebbene il modello fattoriale è invariante rispetto a trasformazioni di scala, la *stima* dei parametri potrebbe essere influenzata dalle trasformazioni di scala.

## 1.4 Non-unicità dei pesi fattoriali

Sia  $A$  una matrice ortogonale:  $AA' = A'A = I$   
 $k \times k$

$$\begin{aligned} x_{p \times 1} &= \Lambda_{p \times k} f_{k \times 1} + u_{p \times 1} \\ &= \Lambda_{p \times k} A_{k \times k} A'_{k \times k} f_{k \times 1} + u_{p \times 1} \\ &= \Lambda^*_{p \times k} f^*_{k \times 1} + u_{p \times 1} \end{aligned}$$

- $\Lambda^*_{p \times k} = \Lambda_{p \times k} A_{k \times k}$
- $f^*_{k \times 1} = A'_{k \times k} f_{k \times 1}$
- $\mathbb{E}(f^*) = A' \mathbb{E}(f) = 0_{k \times 1}$
- $\text{Cov}(f^*) = A' \text{Cov}(f) A = I_{p \times p}$
- $\text{Cov}(x) = \Sigma = \Lambda \Lambda' + \Psi = \Lambda A A' \Lambda' + \Psi = \Lambda^* \Lambda^{*'} + \Psi$


Il risultato precedente mostra che il modello fattoriale con fattori comuni  $f_{k \times 1}$  e pesi fattoriali  $\Lambda_{p \times k}$ , e il modello fattoriale con fattori comuni  $f^*_{k \times 1}$  e pesi fattoriali  $\Lambda^*_{p \times k}$  sono equivalenti per spiegare la matrice di varianza/covarianza  $\Sigma$  di  $x_{p \times 1}$ .

## 1.5 Rappresentazione grafica del modello


Si consideri il modello fattoriale con  $k = 1$  fattore e  $p = 3$  variabili

$$\begin{aligned} x_1 &= \lambda_1 f + u_1 \\ x_2 &= \lambda_2 f + u_2 \\ x_3 &= \lambda_3 f + u_3 \end{aligned}$$

Questo modello può essere rappresentato graficamente:



Se consideriamo un modello a  $k = 2$  fattori per  $p = 6$  variabili standardizzate, otteniamo:



Per questo modello

$$\text{Cov}(z_1, f_1) = \text{Corr}(z_1, f_1) = \text{Corr}(x_1, f_1) = \lambda_{11}$$

e

$$\text{Cov}(z_1, z_2) = \text{Corr}(z_1, z_2) = \text{Corr}(x_1, x_2) = \lambda_{11}\lambda_{21} + \lambda_{12}\lambda_{22}$$

## 2 Stima del modello fattoriale

Obiettivo: determinare due matrici  $\hat{\Lambda}$  e  $\hat{\Psi}$  tali che  $\widehat{\text{Cov}}(x) = \hat{\Sigma} = S = \hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}$ , oppure determinare due matrici  $\hat{\Lambda}$  e  $\hat{\Psi}$  tali che  $\widehat{\text{Corr}}(x) = R = \hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}$

### 2.1 Stima naïve

**Example 2.1.** Si consideri il seguente esempio: sulla base di un campione di voti di studenti su tre materie,  $x_1$  (Classics),  $x_2$  (French) e  $x_3$  (English) si è ottenuta la seguente matrice di correlazione:

$$\mathbf{R} = \begin{matrix} \text{Classics} \\ \text{French} \\ \text{English} \end{matrix} \begin{pmatrix} 1.00 & & \\ 0.83 & 1.00 & \\ 0.78 & 0.67 & 1.00 \end{pmatrix}.$$

*Si consideri il modello fattoriale con  $k = 1$  fattore*

$$\begin{aligned} x_1 &= \lambda_1 f + u_1 \\ x_2 &= \lambda_2 f + u_2 \\ x_3 &= \lambda_3 f + u_3 \end{aligned}$$

*Le sei equazioni derivanti dall'uguaglianza  $R = \Lambda\Lambda' + \Psi$  sono*

$$\mathbf{R} = \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \end{pmatrix} (\lambda_1 \ \lambda_2 \ \lambda_3) + \begin{pmatrix} \psi_1 & 0 & 0 \\ 0 & \psi_2 & 0 \\ 0 & 0 & \psi_3 \end{pmatrix},$$

are

$$\begin{aligned} \hat{\lambda}_1 \lambda_2 &= 0.83, \\ \hat{\lambda}_1 \lambda_3 &= 0.78, \\ \hat{\lambda}_1 \lambda_4 &= 0.67, \\ \psi_1 &= 1.0 - \hat{\lambda}_1^2, \\ \psi_2 &= 1.0 - \hat{\lambda}_2^2, \\ \psi_3 &= 1.0 - \hat{\lambda}_3^2. \end{aligned}$$

The solutions of these equations are

$$\begin{aligned} \hat{\lambda}_1 &= 0.99, \quad \hat{\lambda}_2 = 0.84, \quad \hat{\lambda}_3 = 0.79, \\ \hat{\psi}_1 &= 0.02, \quad \hat{\psi}_2 = 0.30, \quad \hat{\psi}_3 = 0.38. \end{aligned}$$

## Example 2.2. Casi di Heywood

**Esempio 4** (tratto da Everitt e Dunn, 2001):

Si stimino i parametri del modello fattoriale ad un fattore per i punteggi ottenuti nelle tre materie:

$x_1$ : Classics,  $x_2$ : French e  $x_3$ : English.

$$x_1 = \lambda_1 f + u_1,$$

$$x_2 = \lambda_2 f + u_2,$$

$$x_3 = \lambda_3 f + u_3.$$

data la matrice di correlazione campionaria  $R = \begin{matrix} & \begin{matrix} \text{Classics} & \text{French} & \text{English} \end{matrix} \\ \begin{matrix} \text{Classics} \\ \text{French} \\ \text{English} \end{matrix} & \begin{pmatrix} 1.00 & & \\ 0.84 & 1.00 & \\ 0.60 & 0.35 & 1.00 \end{pmatrix} \end{matrix}$

Si ottiene il sistema 
$$\begin{cases} \hat{\psi}_1 = 1.0 - \hat{\lambda}_1^2, & \lambda_1 \lambda_2 = 0.84 \\ \hat{\psi}_2 = 1.0 - \hat{\lambda}_2^2, & \text{e } \lambda_3 \lambda_2 = 0.35 \\ \hat{\psi}_3 = 1.0 - \hat{\lambda}_3^2, & \lambda_1 \lambda_3 = 0.6 \end{cases}$$

da cui la soluzione 
$$\begin{matrix} \hat{\lambda}_1 = 1.2, & \hat{\lambda}_2 = 0.7, & \hat{\lambda}_3 = 0.5, \\ \hat{\psi}_1 = -0.44, & \hat{\psi}_2 = 0.51, & \hat{\psi}_3 = 0.75 \end{matrix}$$

Stime di tipo intuitivo possono condurre a soluzioni non accettabili anche se il modello è identificato esattamente!

## Example 2.3. Modello ad un fattore: $\text{Corr}(x)$

**Esempio 3** (tratto da Hardle e Simar 2003)

Si stimi il modello fattoriale ad un fattore per la matrice di correlazione relativa a valutazioni fornite da 40 clienti su 25 tipologie di auto per le variabili  $X_1$ : economicità,  $X_2$ : accessori,  $X_3$ : deprezzamento

$$R = \begin{pmatrix} 1 & 0.975 & 0.613 \\ 0.975 & 1 & 0.620 \\ 0.613 & 0.620 & 1 \end{pmatrix}$$

**Soluzione**

$$\begin{pmatrix} 1 & r_{X_1 X_2} & r_{X_1 X_3} \\ r_{X_1 X_2} & 1 & r_{X_2 X_3} \\ r_{X_1 X_3} & r_{X_2 X_3} & 1 \end{pmatrix} = R = \begin{pmatrix} \hat{\lambda}_1^2 & \hat{\lambda}_1 \hat{\lambda}_2 & \hat{\lambda}_1 \hat{\lambda}_3 \\ & \hat{\lambda}_2^2 & \hat{\lambda}_2 \hat{\lambda}_3 \\ & & \hat{\lambda}_3^2 \end{pmatrix} + \begin{pmatrix} \hat{\psi}_1 & 0 & 0 \\ & \hat{\psi}_2 & 0 \\ & & \hat{\psi}_3 \end{pmatrix}$$

Da cui

$$\frac{r_{X_1 X_2} r_{X_1 X_3}}{r_{X_2 X_3}} = (0.982)^2 = \hat{\lambda}_1^2, \quad \frac{r_{X_1 X_2} r_{X_2 X_3}}{r_{X_1 X_3}} = (0.993)^2 = \hat{\lambda}_2^2, \quad \frac{r_{X_1 X_3} r_{X_2 X_3}}{r_{X_1 X_2}} = (0.624)^2 = \hat{\lambda}_3^2$$

e

$$\psi_1 = 1 - \hat{\lambda}_1^2 = 0.035 \quad \psi_2 = 0.014 \quad \psi_3 = 0.610$$

Le prime due comunali sono  $\approx 1$ .  $X_1$  e  $X_2$  sono ben spiegate dal I° fattore (economicità + accessori)



### Example 2.4. Modello ad un fattore: $\text{Cov}(x)$

Example 11.1 Let  $p = 3$  and  $k = 1$ , then  $d = 0$  and

$$\Sigma = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \sigma_{13} \\ \sigma_{21} & \sigma_{22} & \sigma_{23} \\ \sigma_{31} & \sigma_{32} & \sigma_{33} \end{pmatrix} = \begin{pmatrix} q_1^2 + \psi_{11} & q_1 q_2 & q_1 q_3 \\ q_1 q_2 & q_2^2 + \psi_{22} & q_2 q_3 \\ q_1 q_3 & q_2 q_3 & q_3^2 + \psi_{33} \end{pmatrix}$$

with  $\mathcal{Q} = \begin{pmatrix} q_1 \\ q_2 \\ q_3 \end{pmatrix}$  and  $\Psi = \begin{pmatrix} \psi_{11} & 0 & 0 \\ 0 & \psi_{22} & 0 \\ 0 & 0 & \psi_{33} \end{pmatrix}$ . Note that here the constraint (11.8) is automatically verified since  $k = 1$ . We have

$$q_1^2 = \frac{\sigma_{12}\sigma_{13}}{\sigma_{23}}; \quad q_2^2 = \frac{\sigma_{12}\sigma_{23}}{\sigma_{13}}; \quad q_3^2 = \frac{\sigma_{13}\sigma_{23}}{\sigma_{12}}$$

and

$$\psi_{11} = \sigma_{11} - q_1^2; \quad \psi_{22} = \sigma_{22} - q_2^2; \quad \psi_{33} = \sigma_{33} - q_3^2.$$

In this particular case ( $k = 1$ ), the only rotation is defined by  $\mathcal{G} = -1$ , so the other solution for the loadings is provided by  $-\mathcal{Q}$ .

## 2.2 Vincoli e gradi di libertà

Numero di parametri del modello fattoriale  $\Lambda\Lambda' + \Psi$ :  $pk + p$

Per risolvere il problema della non-unicità dei pesi fattoriali, introduciamo ora il seguente vincolo (Vincolo 1):

$$\Lambda'\Psi^{-1}\Lambda = \text{diag}(b_1, \dots, b_k)$$

con  $b_1 \geq \dots \geq b_k$

Il Vincolo 1 impone  $k(k-1)/2$  restrizioni

Numero di parametri del modello fattoriale  $\Lambda\Lambda' + \Psi$  dato il Vincolo 1:  $pk + p - k(k-1)/2$

Come alternativa al Vincolo 1 si può considerare

Vincolo 2:  $\Lambda'D^{-1}\Lambda = \text{diag}(c_1, \dots, c_k)$  con  $c_1 \geq \dots \geq c_k$  e  $D = \text{diag}(\sigma_{11}, \dots, \sigma_{pp})$

I *gradi di libertà* (= numero dei parametri “liberi”) sono dati dalla differenza tra i  $p(p+1)/2$  parametri di  $\Sigma$  e il numero di parametri del modello fattoriale dato il Vincolo 1 (o 2):

$$d = p(p+1)/2 - (pk + p - k(k-1)/2) = (p-k)^2/2 - (p+k)/2$$

- Se  $d < 0$ , allora ci sono più parametri che equazioni: il modello è indeterminato (ci sono infinite soluzioni)
- Se  $d = 0$ , allora il numero di equazioni è pari al numero di parametri: la soluzione è unica (ma non necessariamente propria, poiché possiamo avere casi di Heywood)
- $d > 0$ , allora ci sono più equazioni che parametri: non c'è una soluzione esatta (ci si accontenta di una approssimazione)

### Example 2.5. Modello indeterminato

Example 11.2 Suppose now  $p = 2$  and  $k = 1$ , then  $d < 0$  and

$$\Sigma = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} = \begin{pmatrix} q_1^2 + \psi_{11} & q_1 q_2 \\ q_1 q_2 & q_2^2 + \psi_{22} \end{pmatrix}.$$

We have infinitely many solutions: for any  $\alpha$  ( $\rho < \alpha < 1$ ), a solution is provided by

$$q_1 = \alpha; \quad q_2 = \rho/\alpha; \quad \psi_{11} = 1 - \alpha^2; \quad \psi_{22} = 1 - (\rho/\alpha)^2.$$

## 2.3 Metodi di stima

Data  $\hat{\Sigma} = S$  (oppure  $= R$ ), vogliamo stimare  $\hat{\Psi}$  e  $\hat{\Lambda}$  in modo tale che  $\hat{\Sigma} \approx \hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}$  e sia rispettato il Vincolo 1 o 2

- Naïve (senza vincolo)
- Componenti principali
- Fattori principali
- Massima Verosimiglianza (richiede assunzione di Normalità per  $\begin{matrix} x \\ p \times 1 \end{matrix}$ )

Rotazione dei fattori:

Dopo aver stimato il modello fattoriale, può essere utile ruotare i pesi fattoriali  $\hat{\Lambda}$  per ottenere  $\hat{\Lambda}^* = \hat{\Lambda}A$  (con  $A$  matrice ortogonale), al fine di trovare configurazioni più facilmente interpretabili

Numero di fattori:

In pratica, dobbiamo anche determinare il valore di  $k$

## 2.4 Metodo dei fattori principali

Si parte da  $\hat{\Sigma} = \widehat{\text{Corr}}(x) = R$  per trovare  $\hat{\Psi}$  e  $\hat{\Lambda}$  in modo tale che  $R - \hat{\Psi} \approx \hat{\Lambda}\hat{\Lambda}'$  e sia rispettato il Vincolo 2

- $R^* = R - \hat{\Psi}$  è detta *matrice di correlazione ridotta*
- $\{\widehat{\text{Corr}}(x)\}_{ii} = 1 = \hat{h}_i^2 + \psi_i$ , quindi se abbiamo a disposizione una stima iniziale  $\hat{h}_i^2$ , allora  $\{R^*\}_{ii} = 1 - \hat{\psi}_i = \hat{h}_i^2$
- $R^* = R - \hat{\Psi}$  è una matrice simmetrica, quindi la sua decomposizione spettrale è  $R^* = VLV'$  con  $L = \text{diag}(l_1, \dots, l_p)$  e  $V = [v_1, \dots, v_p]$ . Se i primi  $k$  autovalori  $l_1, \dots, l_k$  sono positivi e i rimanenti  $p - k$  autovalori  $l_{k+1}, \dots, l_p$  prossimi a 0, allora

$$R^* \approx V_k L_k V_k'$$

dove  $V_k$  contiene le prime  $k$  colonne di  $V$  e  $L_k = \text{diag}(l_1, \dots, l_k)$

- Segue  $R^* = R - \hat{\Psi} \approx (V_k L_k^{1/2})(V_k L_k^{1/2})' \approx \hat{\Lambda} \hat{\Lambda}'$ , quindi

$$\hat{\Lambda} \approx V_k L_k^{1/2}$$

Inizializzazione:

- Partire dalla stima  $R$  della matrice di correlazione  $\text{Corr}(x)$
- Calcolare la stima iniziale  $\hat{h}_i^2$  della comunalità  $h_i^2$  come
  - $\hat{h}_i^2 = \max_{j \neq i} |\widehat{\text{Corr}}(x_i, x_j)|$
  - $\hat{h}_i^2 = 1 - \frac{1}{r^{ii}}$  dove  $r^{ii} = \{R^{-1}\}_{ii}$ , che equivale il coefficiente di determinazione lineare multiplo tra  $x_i$  e  $x_{-(i)}$
- Ottenere la matrice di correlazione ridotta  $R^*$  da  $R$  ma sostituendo i valori 1 sulla diagonale con  $\hat{h}_1^2, \dots, \hat{h}_p^2$

Algoritmo iterativo:

1.  $R^* \leftarrow R$  e poi  $\{R^*\}_{ii} \leftarrow \hat{h}_i^2, i = 1, \dots, p$
2. Ottenere la decomposizione spettrale  $R^* = V L V'$
3. Fissare  $k$  e determinare  $V_k$  e  $L_k$
4. Stimare  $\Lambda$  con  $\hat{\Lambda} \approx V_k L_k^{1/2}$
5. Aggiornare  $\hat{h}_i^2 \leftarrow \sum_{j=1}^k \hat{\lambda}_{ij}^2$  e  $\{R^*\}_{ii} \leftarrow \hat{h}_i^2$
6. Ripetere i passi 2-5 fino a raggiungere convergenza

Output:  $\hat{\Lambda}, \hat{h}_i^2$  e  $\hat{\psi}_i = 1 - \hat{h}_i^2, i = 1, \dots, p$

Vincolo 2

$D = \text{diag}(\sigma_{11}, \dots, \sigma_{pp}) = I$  perchè consideriamo la matrice di correlazione

Vincolo 2:  $\hat{\Lambda}' \hat{D}^{-1} \hat{\Lambda} = \hat{\Lambda}' \hat{\Lambda} = \text{diag}(c_1, \dots, c_k)$  con  $c_1 \geq \dots \geq c_k$

Quindi  $\hat{\Lambda}$  soddisfa il Vincolo 2 perchè

$$\hat{\Lambda}' \hat{\Lambda} = (V_k L_k^{1/2})' (V_k L_k^{1/2}) = L_k = \text{diag}(l_1, \dots, l_k)$$

Casi di Heywood

Nella procedura di stima iterativa possono succedere casi di Heywood, ovvero  $\hat{\psi}_i < 0$  oppure  $\hat{\psi}_i > 1$

$\hat{\psi}_i < 0$  non ha senso perchè  $\psi_i$  è una varianza, e quindi  $> 0$

$\hat{\psi}_i > 1$  non ha senso perchè  $\text{Var}(x_i) = 1$  è quindi  $\psi_i \leq 1$

## 2.5 Stima di massima verosimiglianza

**Assunzione:**  $x$  segue una distribuzione Normale  $p$ -variata  $\mathcal{N}\left(\begin{matrix} \mu \\ p \times 1 \end{matrix}, \begin{matrix} \Sigma \\ p \times p \end{matrix}\right)$

Funzione di log-verosimiglianza:

$$\begin{aligned} \ell(X; \mu, \Sigma) &= -\frac{1}{2}n \log |2\pi\Sigma| - \frac{1}{2} \sum_{i=1}^n (x_i - \mu)\Sigma^{-1}(x_i - \mu)' \\ &= -\frac{1}{2}n \log |2\pi\Sigma| - \frac{1}{2}n \text{tr}(\Sigma^{-1}S) - \frac{1}{2}n(\bar{x} - \mu)\Sigma^{-1}(\bar{x} - \mu)' \end{aligned}$$

Sostituendo  $\hat{\mu} = \bar{x}$

$$\ell(X; \hat{\mu}, \Sigma) = -\frac{n}{2} \left\{ \log |2\pi\Sigma| + \text{tr}(\Sigma^{-1}S) \right\}$$

e per  $\Sigma = \Lambda\Lambda' + \Psi$  otteniamo

$$\ell(X; \hat{\mu}, \Lambda, \Psi) = -\frac{n}{2} \left\{ \log |2\pi(\Lambda\Lambda' + \Psi)| + \text{tr}[(\Lambda\Lambda' + \Psi)^{-1}S] \right\}$$

Massimizzare

$$\ell(X; \hat{\mu}, \Lambda, \Psi) = -\frac{n}{2} \left\{ \log |2\pi(\Lambda\Lambda' + \Psi)| + \text{tr}[(\Lambda\Lambda' + \Psi)^{-1}S] \right\}$$

rispetto a  $\Psi$  e  $\Lambda$

Stima iterativa:

1. Per  $\Psi$  fissato, massimizza numericamente per  $\Lambda$
2. Per  $\Lambda$  fissato, massimizza numericamente per  $\Psi$ 
  - Implementata nella funzione R `factanal()`
  - Possiamo ottenere casi di Heywood

**Example 2.6.** Voto di  $n = 202$  studenti maschi su  $p = 6$  esami (variabili) Gaelic (non-math), English (non-math), History (non-math), Arithmetic (math), Algebra (math), Geometry (math).

	Gaelic	English	History	Arithmetic	Algebra	Geometry
$\mathbf{R} =$	1.0	.439	.410	.288	.329	.248
		1.0	.351	.354	.320	.329
			1.0	.164	.190	.181
				1.0	.595	.470
					1.0	.464
						1.0

Stima di massima verosimiglianza con  $k = 2$

Table 9.5			
Variable	Estimated factor loadings		Communalities $\hat{h}_i^2$
	$F_1$	$F_2$	
1. Gaelic	.553	.429	.490
2. English	.568	.288	.406
3. History	.392	.450	.356
4. Arithmetic	.740	-.273	.623
5. Algebra	.724	-.211	.569
6. Geometry	.595	-.132	.372

Stima di MV:  $\hat{h}_1^2 = \hat{\lambda}_{11}^2 + \hat{\lambda}_{12}^2 = (0.553)^2 + (0.429)^2 \approx 0.490$

Primo fattore: intelligenza generale

Secondo fattore: abilità matematica vs abilità verbale

## 2.6 Rotazione dei pesi fattoriali

Per la rotazione dei pesi fattoriali  $\Lambda$ , dobbiamo cercare una matrice ortogonale  $A$  ( $A'A = AA' = I$ ) tale per cui i pesi fattoriali ruotati  $\Lambda^* = \Lambda A$  sono più facilmente interpretabili:

$$A_{2 \times 2} = \begin{bmatrix} \cos \phi & \sin \phi \\ -\sin \phi & \cos \phi \end{bmatrix} \text{ rotazione oraria per } k = 2$$

Questo non cambia la soluzione del modello, solo la sua descrizione. Situazione desiderata per i fini interpretativi:

- i pesi fattoriali sono tutti grandi e positivi o prossimi a 0 (con pochi valori intermedi)
- ogni variabile osservabile è legata in modo pesante al più ad un solo fattore

Per  $k > 2$  il metodo *varimax* identifica la rotazione massimizzando un'opportuna funzione dei pesi fattoriali ruotati che misura la variabilità dei pesi.

**Example 2.7.** Riprendiamo l'esempio precedente:




Table 9.6			
Variable	Estimated rotated factor loadings		Communalities $\hat{h}_i^{*2} = \hat{h}_i^2$
	$F_1^*$	$F_2^*$	
1. Gaelic	.369	.594	.490
2. English	.433	.467	.406
3. History	.211	.558	.356
4. Arithmetic	.789	.001	.623
5. Algebra	.752	.054	.568
6. Geometry	.604	.083	.372

- *Primo fattore*: abilità matematica
- *Secondo fattore*: abilità verbale

## 2.7 Verifica d'ipotesi sul numero di fattori

Un vantaggio della stima di massima verosimiglianza è che permette un test di ipotesi sul numero di fattori

Ipotesi nulla  $H_0$ : il modello fattoriale con  $k$  fattori è corretto

$$\Sigma = \underset{p \times k}{\Lambda} \underset{k \times p}{\Lambda}' + \Psi$$

Ipotesi alternativa  $H_1$ :  $\Sigma$  è una matrice definitiva positiva diversa da quella specificata sotto l'ipotesi nulla

Rifiuto l'ipotesi nulla con un  $p$ -value  $\leq 5\%$

Test sequenziali: parto da  $k = 1$ , se rifiuto proseguo con  $k = 2, 3, \dots$  fino a quando fallisco di rifiutare l'ipotesi

Test rapporto di verosimiglianza

Siano  $\hat{\Lambda}$  e  $\hat{\Psi}$  le stime di massima verosimiglianza per il  $k$  specificato dall'ipotesi nulla  
La statistica test rapporto di verosimiglianza è data da

$$T = -2 \log \left( \frac{\text{MV sotto } H_0}{\text{MV}} \right) = n \log \left( \frac{|\hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}|}{|S|} \right)$$

e sotto  $H_0$  segue asintoticamente una distribuzione

$$\chi^2_{\frac{1}{2}[(p-k)^2 - p - k]}$$

Il  $p$ -value del test si calcola come  $\Pr(\chi^2_{\frac{1}{2}[(p-k)^2 - p - k]} > t)$  dove  $t$  è il valore osservato della statistica test

L'approssimazione  $\chi^2$  può essere migliorata utilizzando la statistica test con la correzione di Bartlett:

$$T_{\text{Bartlett}} = [(n-1) - (2p + 4k + 5)/6] \log \left( \frac{|\hat{\Lambda}\hat{\Lambda}' + \hat{\Psi}|}{|S|} \right)$$

## 2.8 Stima dei punteggi fattoriali

I punteggi fattoriali  $\hat{f}_{k \times 1} = (\hat{f}_1, \dots, \hat{f}_k)'$  sono le “stime” delle variabili non osservabili  $f_{k \times 1} = (f_1, \dots, f_k)'$

Metodo di Thompson (1951)

La distribuzione condizionata di  $f_{k \times 1}$  dato  $x_{p \times 1}$  è

$$\mathcal{N}(\Lambda' \Sigma^{-1} x, I - \Lambda' \Psi^{-1} \Lambda)$$

Per l' $i$ -sima osservazione  $x_i$  (se standardizzata  $z_i$ ),

$$\hat{f}_i = \hat{\Lambda}' S^{-1} x_i \quad (\hat{f}_i = \hat{\Lambda}' R^{-1} z_i)$$

Metodo di Bartlett (1937)

$$\hat{f}_i = (\hat{\Lambda}' \hat{\Psi}^{-1} \hat{\Lambda})^{-1} \hat{\Lambda}' \hat{\Psi}^{-1} x_i$$