

Lezione 11

L'analisi fattoriale: il processo di estrazione dei fattori

Argomenti della lezione:

- **Metodi di estrazione dei fattori**
- **Metodi per stabilire il numero di fattori**

Metodi di Estrazione dei Fattori

Scopo fondamentale dell'AF: estrarre un numero sufficiente di fattori per "rendere conto" della matrice delle correlazioni tra le variabili osservate

Differenze tra metodi di estrazione

- ➔ **Metodi che spiegano il massimo di varianza delle variabili**
- ➔ **Metodi che massimizzano la "riproduzione" di R**
- ➔ **Metodi che richiedono una stima iniziale delle comunaltà**
- ➔ **Metodi che richiedono una stima del numero di fattori da estrarre**

Analisi delle Componenti Principali (ACP)

Identifica una serie di combinazioni lineari ortogonali delle variabili originali X_i ($c_i = X_i V$, V = autovettori di R) che:

- ➔ **spiegano più varianza possibile**
- ➔ **riducono la complessità dei dati**

→ L'ACP analizza la varianza totale delle variabili

→ Analizza la matrice R con valori 1 sulla diagonale principale: la varianza unica viene assorbita dai fattori comuni

→ Le saturazioni fattoriali risultano gonfiate

→ L'ACP estrae il massimo della varianza per ogni componente

→ La prima componente spiega più varianza, la seconda spiega più varianza dopo la prima, ecc...

→ R è perfettamente replicata se vengono estratte tante componenti quante sono le variabili

Analisi dei Fattori Principali (AFP o PAF)

→ Massimizza lo stesso criterio della ACP; analizza R, ma con stime della comunalità inserite nella diagonale principale al posto di 1

→ Analizza solo la varianza attribuibile ai fattori "comuni", per ottenere una soluzione non contaminata dalla varianza unica

→ L' AFP estrae il massimo di varianza per ogni fattore, ma spiega meno varianza della ACP perché considera solo la varianza comune

→ Passo preliminare: rimuovere dalla diagonale principale della matrice R la varianza unica (ovvero la componente $u^2=1-h^2$)

Stima iniziale della comunalità

📄 Coefficiente di correlazione multipla al quadrato (SMC)

📄 Coefficiente di correlazione più elevato

📄 Media delle correlazioni

Minimi Quadrati (ULS e GLS)

📄 Minimizza le differenze al quadrato tra le correlazioni osservate (R), e quelle riprodotte (R^{\wedge}) tramite i fattori estratti

📄 Minimizza le correlazioni residue ($R - R^{\wedge}$) cioè la parte di correlazione tra le variabili che non è spiegata dai fattori comuni

Funzione dei minimi quadrati ordinari (OLS) minimizzata nel processo di estrazione dei fattori:

$$\sum_j \sum_k (r_{jk} - \hat{r}_{jk})^2$$

Viene ottimizzata la riproduzione dei coefficienti fuori della diagonale principale di R

Metodo dei minimi quadrati generalizzati o ponderati (GLS)

Massimizza la stessa funzione del metodo dei minimi quadrati ordinari (OLS)

Ponderazione delle variabili che penalizza quelle con varianza unica più elevata

☞ **Si inizia il processo stabilendo il numero di fattori**

☞ **Si stimano le saturazioni iniziali con l'ACP**

Le saturazioni vengono modificate iterativamente finché lo scarto tra R e R^ non è molto piccolo

Massima verosimiglianza (Maximum Likelihood, ML)

☞ **Stima i valori delle saturazioni nella popolazione**

☞ **Calcola le saturazioni che rendono massima la probabilità di osservare la matrice R**

☞ **Identifica la soluzione fattoriale che meglio riproduce R**

☞ **Stima le saturazioni della popolazione che hanno la massima verosimiglianza nel produrre la matrice delle correlazioni R**

☞ **Si considerano gli elementi fuori della diagonale principale**

☞ **Bisogna fornire il numero di fattori da estrarre**

☞ **Si stimano le saturazioni iniziali con l'ACP**

La stima delle saturazioni viene modificata iterativamente con una funzione complessa

Per utilizzare il criterio di massima verosimiglianza è necessario che:

$$(n-k)^2 > (n+k)$$

n = numero di variabili

k = numero di fattori

Es.: con $n=5$ possono essere estratti al massimo 2 fattori

Se $k=3$, $(n-k)^2 = 4$, e $(n+k) = 8$

Test di bontà dell'adattamento (goodness of fit)

→ Si ottiene dalle funzioni ML e GLS che vengono minimizzate, se le variabili seguono la distribuzione normale multivariata

**Ipotesi nulla: $H_0: R=R^{\wedge}$
Segue la distribuzione del χ^2**

Gradi di libertà:

$$gdl = [(n-k)^2 - (n+k)]/2$$

n = numero di variabili

k = numero di fattori

Se $(n-k)^2 < (n+k)$
i gradi di libertà sono negativi !

χ^2 non significativo \Rightarrow
non vi sono più fattori da estrarre
Non si può rifiutare $H_0: R=R^{\wedge}$

χ^2 significativo \Rightarrow
è necessario procedere
all'estrazione di fattori ulteriori

**Test fortemente dipendente
dall'ampiezza del campione**

Stabilire il numero di fattori

→ **Decisione che ha conseguenze cruciali per la soluzione fattoriale**

→ **Salvaguardare la parsimonia della soluzione, e la sua adeguatezza (capacità di riprodurre R)**

Metodi per stabilire il numero di fattori

- **Mineigen (Kaiser-Guttman rule)**
- **Scree test degli autovalori**
- **Test statistico (con GLS e ML)**
- **Percentuale di varianza spiegata**
- **Massima correlazione residua**
- **Replicabilità della soluzione**

Mineigen (Kaiser-Guttman rule)

- Estrae tutti quei fattori che hanno un autovalore maggiore di 1 quando viene analizzata la matrice R completa (diagonale principale)
- I fattori devono spiegare almeno la stessa varianza spiegata dalle variabili osservate

Il numero di autovalori maggiori di 1 è compreso tra $1/3$ e $1/5$ del numero delle variabili

Criterio inappropriato nel caso di soluzioni diverse dall'ACP

Scree test degli autovalori (Cattell e Vogelman)

- I primi fattori sono i più attendibili e i più validi, poiché spiegano una percentuale di varianza maggiore rispetto ai fattori rimanenti
- Questi fattori hanno autovalori più grandi degli altri

Gli autovalori rappresentano una progressione decrescente

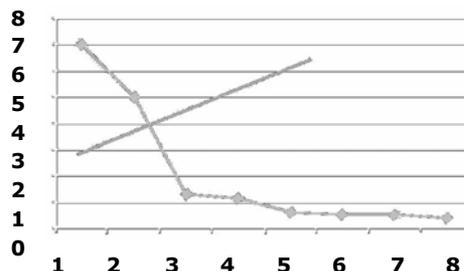
Grafico:

**autovalore \Rightarrow in ordinata
numero del fattore \Rightarrow in ascissa**

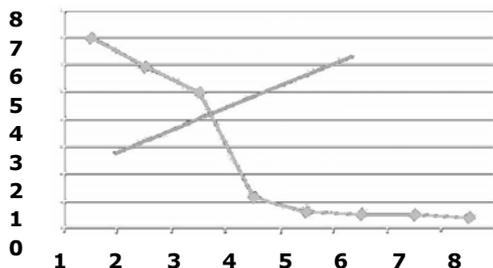
Si interrompe il processo di estrazione nel punto in cui la curva degli autovalori decrescenti cambia pendenza e diventa sostanzialmente piatta

Vanno presi quei fattori i cui autovalori sono al di sopra della linea piatta formata dagli autovalori dei fattori più piccoli

Soluzione con 2 fattori



Soluzione con 3 fattori



L'applicazione di questo test grafico è più attendibile quando:

- il campione è grande
- le comunalità sono elevate
- i fattori saturano più variabili

Test statistico

→ **Tende a sovrastimare il numero di fattori se il numero di soggetti è grande e le variabili sono molte**

Percentuale di varianza spiegata

→ **Specificare la proporzione di varianza totale che deve essere spiegata dall'ultimo fattore. Metodo troppo soggettivo**

Massima correlazione residua

→ **Per ogni elemento di R fuori della diagonale principale si può definire un residuo che è uguale a $(r - r^{\wedge})$, ovvero correlazione osservata meno correlazione riprodotta**

Massima correlazione residua

→ **Matrice dei residui: $E = (R - R^{\wedge})$. Se dopo aver effettuato l'estrazione di un certo numero di fattori tutti i residui sono minori di $|.10|$, non è necessario continuare il processo di estrazione: il nuovo fattore estratto avrebbe saturazioni molto basse**

Replicabilità della soluzione

- **I fattori "validi" sono quelli che risultano più facilmente replicabili su campioni diversi da quelli nei quali sono stati individuati**
- **I fattori "spuri" risultano poco generalizzabili e sono determinati sostanzialmente dall'errore campionario**

CONCLUSIONE

→ **Estrazione dei fattori**

→ **Scelta del numero
dei fattori**