

• I(z) z minulá - overené

Projektívne sledovanie (PP)

- dynamické vyfreskované: tours - výlety

animate - xy (... guided_tour ...) → PP

(... grand_tour ...) → všetky možné pohľady na data

Factorová analýza (Factor analysis, FA)

- hľadá skryté faktory → špeciálne: rozvoj teórie

→ jednoduchšie vyjadrenie dát / otázok

- psychológia, sociológia, tiež aj marketing, medicína...

teoreticky: náh. vektor $X = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ - popisáť pomocou skrytých (latentných) faktorov F_1, \dots, F_q , $q < n$

model: náh. prem.

$$X_i = \sum_{j=1}^q a_{ij} F_j + U_i, \quad i=1, \dots, n$$

faktorové
náhledy
(factor
loadings)

skryté (latentné) faktory
špecifické faktory

maticovo: $X = AF + U$

$$A = \begin{bmatrix} a_{11} & \dots & a_{1q} \\ \vdots & & \vdots \\ a_{n1} & \dots & a_{nq} \end{bmatrix} \quad \text{- neznáme parametre modelu}$$

$$F = \begin{pmatrix} F_1 \\ \vdots \\ F_q \end{pmatrix}, \quad U = \begin{pmatrix} U_1 \\ \vdots \\ U_n \end{pmatrix}$$

(odtenat: X, U, F)
 $X \quad U \quad F$

uniqueness
všet. špecif. faktorov

Predpoklady:

$$\text{Cov}(F, U) = 0_{q \times n}$$

$$\text{Var}(F) = I_q, \quad E(F) = 0_q$$

$$\text{Var}(U) = D = \text{diag}(d_1, \dots, d_n)$$

tiež neznáme parametre modelu

$$E(U) = 0_n$$

pre jednoduchosť: $E(x_i) = 0, \quad D(x_i) = 1 \quad \forall i = 1, \dots, n$

$$\Rightarrow \text{Var}(X) = \text{Var}(AF + U) = \text{Var}(AF) + \text{Var}(U) = A \text{Var}(F) A^T + \text{Var}(U) = A A^T + D$$

$\underbrace{\quad}_{\substack{\uparrow \\ \text{cov} = 0}} \quad \underbrace{\quad}_{\substack{\uparrow \\ I}} \quad \underbrace{\quad}_{\substack{\uparrow \\ D}}$

$$\underline{\underline{(\Sigma = AA^T + D)}}$$

$$\text{Cov}(X, F) = \text{Cov}(AF + U, F) = \text{Cov}(AF, F) + \text{Cov}(U, F) = A \cdot I_q = A$$

$$\text{Cov}(X, F) = \text{Cov}(AF + U, F) = \text{Cov}(AF, F) + \underbrace{\text{Cov}(U, F)}_0 = A \cdot I_q = A$$

" $A \cdot \text{Cov}(F, F)$ " 0

$$\Rightarrow \rho(x_i, F_j) = \frac{a_{ij}}{\sqrt{\underset{"1"}{D(x_i)} \underset{"1"}{D(F_j)}}} = a_{ij}$$

• vezmeme rotáciu A, F : $\tilde{A} = AV$, V - ortog. matice
 $\tilde{F} = V^T F$

$$X = AF + U$$

$$\tilde{A}\tilde{F} + U = A \underbrace{V V^T}_I F + U = AF + U = X$$

\Rightarrow preparametrisovaný model:

lib. rotácia matice parametrov A tiež vylomuje modelu

\rightarrow nejednoznačnosť matice fakt. nákladov A

\Rightarrow veľa rovnako dobrých modelov daných AV, V - ortog. Môžeme si vybrať ten, ktorý mi vyhovuje.

prakticky: 3 kroky FA:

1.) Odhad A (fakt. nákladov)

$$\Sigma = AA^T + D$$

" $\text{Var}(X)$ "

a) metóda hlavných faktorov: (n. of principal factors)

$$\Sigma = AA^T + D = \begin{bmatrix} \sum_{j=1}^q a_{1j}^2 & & \\ & \dots & \\ \sum_{j=1}^q a_{kj}^2 & & \dots \end{bmatrix} + \begin{bmatrix} d_1 & & 0 \\ & \dots & \\ 0 & & d_q \end{bmatrix}$$

" $\text{Var}(X) = \begin{pmatrix} 1 & & \\ & \dots & \\ & & 1 \end{pmatrix}$ " - odhadujeme ju ako R (kovar. matice)

" $= h_1^2$ " " $= h_2^2$ " : homogeneity

$\hookrightarrow R_{ij} = \frac{S_{ij}}{\sqrt{S_{ii} \cdot S_{jj}}}$ \leftarrow kovar. matice

1. Odhadnime h_i a d_i

$$\hat{h}_i^2 = 1 - \frac{1}{R_{ii}^{-1}} \Rightarrow 1 = \hat{h}_i^2 + d_i$$

$$\rightarrow \hat{d}_i = 1 - \hat{h}_i^2 = \frac{1}{R_{ii}^{-1}}$$

2. odhadnime AA^T : $R = AA^T + D$

$$\Rightarrow \widehat{AA^T} = R - \hat{D} = R^* = R - \text{diag}\left(\frac{1}{R_{11}^{-1}}, \dots, \frac{1}{R_{qq}^{-1}}\right)$$

3. odhadnutí A

$$AA^T = W \Delta W^T = \underbrace{W \Delta^{1/2}}_{r \times r} \underbrace{\Delta^{1/2} W^T}_{r \times k}$$

↑
speřit. rozřelení

my chceme A : r x q

$\lambda_1 \geq \dots \geq \lambda_r$. r x r prŕjeh q d: s_i ≥ 0 a dost vel'k' ⇒

$$AA^T \approx \underbrace{\begin{pmatrix} | & & | \\ w_1 & \dots & w_q \\ | & & | \end{pmatrix}}_{W_q} \underbrace{\begin{pmatrix} \sqrt{\lambda_1} & & 0 \\ & \dots & \\ 0 & & \sqrt{\lambda_q} \end{pmatrix}}_{\Delta^{1/2}_q} \underbrace{\begin{pmatrix} \sqrt{\lambda_1} & & 0 \\ & \dots & \\ 0 & & \sqrt{\lambda_q} \end{pmatrix}}_{\Delta^{1/2}_q} \underbrace{\begin{pmatrix} -w_1^T & - \\ \vdots & \\ -w_q^T & - \end{pmatrix}}_{A^T}$$

\hat{A} \hat{A}^T

$$\Rightarrow \hat{A} = W_q \Delta^{1/2}_q$$

... mŕt'eme pokračovat : nov' $\hat{k}_i^T = \sum_{j=1}^q \hat{a}_{ij}^2$ a opakovat proces

→ iterovat, ař se rŕjím sa homogenit' nest'el'ia.

by met. max. viřednosti:

predp.: x_1, \dots, x_n : m'ib. v'ber z $N_r(0_r, AA^T + D)$, $(AA^T + D)_{ii} = 1 \forall i$

$$\Rightarrow L(A, D) = \prod_{i=1}^n f_{N_r(0_r, AA^T + D)}(x_i) \rightarrow \max_{\substack{A: D\text{-diag.} \\ A^T D^{-1} A \text{-diag.}}}$$

← bez toho by bolo ∞-vel'k' r'is.;
v'ody take' r'is. existuje

2.) Rotacia faktorov

- hledat'ne V ortog. a aby $\hat{A}V$ bolo "peřn'ie"

→ aby bolo dobre interpretovatel'ie.

$a_{ij} = \rho(x_i, F_j)$: chceme \tilde{a}_{ij} bližšie $\begin{cases} 1 & : \text{vel'k' korel.} \\ 0 & : \text{nehoreloven'ie} \\ -1 & : \text{vel'k' neg. korel.} \end{cases}$

nech $B_V = \hat{A}V \circ \hat{A}V$ (B_V)_{ij} = ($\hat{A}V$)_{ij}²
↑
Hadamardov n'ic'ik

⇒ chceme (B_V)_{ij} bližšie $\begin{matrix} < 1 \\ 0 \end{matrix}$

$$(\hat{A}V)_{ij} \begin{matrix} < 1 \\ 0 \\ -1 \end{matrix} \Rightarrow$$

$$B_V = \begin{bmatrix} b_{11} & \dots & b_{1q} \\ \vdots & & \vdots \\ b_{r1} & \dots & b_{rq} \end{bmatrix}$$

⊗ max f(b₁₁ ... b_{rq}) , aby to vyplatilo b_{ij} ≈ 0

$$\left. \begin{array}{c} \downarrow \\ F^{(1)} \end{array} \right\} \dots \left. \begin{array}{c} \downarrow \\ F^{(n)} \end{array} \right\} \in \mathbb{R}^q$$

$$\begin{aligned} \text{Var} \left(\begin{pmatrix} * \\ F \end{pmatrix} \right) &= \text{Var} \left(\begin{pmatrix} AF + U \\ F \end{pmatrix} \right) = \text{Var} \left(\underbrace{\begin{pmatrix} I & A \\ 0 & I \end{pmatrix}} \begin{pmatrix} U \\ F \end{pmatrix} \right) = \begin{pmatrix} I & A \\ 0 & I \end{pmatrix} \text{Var} \begin{pmatrix} U \\ F \end{pmatrix} \begin{pmatrix} I & 0 \\ A^T & I \end{pmatrix} \\ &= \begin{pmatrix} AA^T + D & A \\ A^T & I \end{pmatrix} \begin{pmatrix} D & 0 \\ 0 & I \end{pmatrix} \end{aligned}$$

Przep.: $\begin{pmatrix} * \\ F \end{pmatrix} \sim N_{k+q}$

Lemma: Niech $\begin{pmatrix} X \\ F \end{pmatrix} \sim N_{k+q} \left(0, \begin{pmatrix} AA^T + D & A \\ A^T & I \end{pmatrix} \right)$. Potem podmiemy rozdzielenie F za podmiemy $X=x$ je $F|X=x \sim N_q \left(A^T (AA^T + D)^{-1} x, \text{cov} \right)$.

\Rightarrow at i -ty objekt mi $X=x_i$, potom $E(F|X=x_i) = A^T (AA^T + D)^{-1} x_i$.

\Rightarrow odhadneme $\hat{F}^{(i)} = \underline{\underline{A^T (AA^T + D)^{-1} x_i}}$, $i=1, \dots, n$.