

Minule: Fakt. analyza

$$X = AF + U$$

$n \times n$ $n \times k$ $k \times 1$ $n \times 1$

hidden factors
fact. loadings
uniqueness

1.) Odhad A

- a) hl. faktory
- b) HLE

2.) Rotacie

varimax
kramax

3.) Odhad faktorovych skore: $\hat{F}^{(i)} = \hat{A}^T (\hat{A} \hat{A}^T + \hat{D})^{-1} x_i$, $i = 1, \dots, n$

Kritika:

- nejednozrucnost \Rightarrow prilis si možeme vymyslet interpretaciu
- normalnost \sim HLE - nemusit byt v datech
- numericke problemy - lok. maxima
- Heywood cases - degenerovane pripady: niektory koef. > 1

Prilo: psych tests. csv

- vysledky studentov na 24 testoch (Chicago, 30-ke roky)
- \hookrightarrow 2 skoly

F1: \sim 5-9 - slovy, jazykovy faktor

F2: \sim 1-4, (13), 23 - vizualna schopnost, rozuzovanie vzťahov

F3: \sim 10-13 - rychlost

F4: \sim 14-18 - pamät

\hookrightarrow namiesto 24 čísel môžeme reprezentovať výsledky pomocou 4 faktorov

2.) Nelinearne metody extrakcie premennych

- nelinearne v datech

Nelinearna PCA (nPCA)

- rozšírit' myšlienku PCA na nelinearne štruktury (nie vs iba priamky ...)

- PCA - max. rozptyl

- nejmenšie vzdialenosti dát od projekcie:
mohoviny prechádzajúce "stredom" dát



moderný prechádzajúce "stredom" dát




1. Hlavné křivky a plochy (principal curves and p. surfaces)

- hlavná křivka, kt. prechádza "stredom" dát
- historický význam: Hastie (1984) ... → jedna z prvej PCA
- hlavná křivka: hlavná křivka, kt. prechádza stredom dát
- hl. povrch: hlavný povrch, -||-

křivka: $f: (a, b) \rightarrow \mathbb{R}^2$, $f(t) = \begin{pmatrix} f_1(t) \\ \vdots \\ f_k(t) \end{pmatrix}$

$x \in \mathbb{R}^2 \Rightarrow$ najbližší bod na křivke $f: \|x - f(t)\| \rightarrow \min_t$
 $\hookrightarrow t^*: \|x - f(t^*)\| = \min_t \|x - f(t)\|$



- môže byť nejednoznačná: zvolíme ten, kt. je na křivke najbližšie

$t^* = \max \{ \tilde{t} \mid \|x - f(\tilde{t})\| = \min_t \|x - f(t)\| \} = t_f(x)$

výberovo/dátovo: \hat{f}
 hl. křivka

hladíme $RE(x, \hat{f}) = \sum_{i=1}^n \|x_i - f(t_f(x_i))\|^2 \rightarrow \min_{\hat{f}}$
 reconstruction error vzdialenosť od projekcie na křivku

- minimalizujeme vzdial. křivky od dát
- optimum: křivka prechádzajúca dátami
- ⇒ vyjadrujeme isté vyhladenie




- v praxi: křivka prechádzajúca stredom dát:

Algoritmus (Projection-Expectation)

- začneme s $f^{(0)} = PC_1$: prvého hlavného princ. hl. komponentu

(i) projekčný krok: pre danú množinu dát dopocítame t_f : $t_i = t_f(x_i)$ $i=1, \dots, n$

⇒ $f(t_f)$, proj. x na f



foed(t_i)

(ii) prumerovaci funk: pre dane t₁, ..., t_n

- nove' hodnoty funk v t_i: spricemerujeme x-ov, kt. sa
projektuju do oblasti t_i


Prime: • usporiadame t_i: t₍₁₎ < t₍₂₎ < ... < t_(n)

a k nim: x₍₁₎, x₍₂₎, ..., x_(n)

N(t) = množina bodov t ⇒ N_(i) = { x_(j) | t_(j) ∈ N(t_i) }

()
↑ tie x_(j), kt. sa projektuju do oblasti t_i

⇒ f_{New}(t_i) = 1 / |N_(i)| · ∑_{x_(j) ∈ N_(i)} x_(j) : prumer x-ov z N_(i)




→ ziskame f_{New} v bodoch t₍₁₎, ..., t_(n)

- medzi nimi: vyhladenie, napr. kubicky splajn

⇒ N₍₅₎ = { x₍₃₎, x₍₄₎, x₍₅₎, x₍₆₎ }

• opatujeme (i), (ii)



• vylepsenia: zníženie vychylenosti (biasu)

• hl. princely: 2-rozmerná analógia - projektujeme do 2-rozmeru

Rko: foed.txt - zloženie jedla