

## Multidimenzionálne škálovanie (MŠ) - multidimensional scaling (distance scaling)

- máme maticu vzájom. vzdialeností:  $D \in \mathbb{R}^{n \times n}$ ,  $D_{ij}$  = vzdialenosť medzi  $i$  a  $j$
- máme pôvodné  $x_1, \dots, x_n \in \mathbb{R}^q$
- > vyriešiť v 2/3-normere, reprezentovať v  $q$ -normere  
 $\Rightarrow$  hľadať  $y_1, \dots, y_n \in \mathbb{R}^q$  :  $\|y_i - y_j\| \approx D_{ij}$
- o záj. vzdialenosti (mesta, ...), nepodobnosti (rozdierne zloženie výrobkov, ...)

### 1.) Klasické MŠ

- posunúť včt. bodov nemení vzdialenosti  $\Rightarrow$  BUNV:  $\sum_{i=1}^n x_i = 0_e$  (centrovane!)

$$K = XX^T = \begin{bmatrix} -x_1^T & \dots & -x_n^T \\ \vdots & & \vdots \\ -x_n^T & \dots & -x_n^T \end{bmatrix} \begin{bmatrix} | & & | \\ x_1 & \dots & x_n \\ | & & | \end{bmatrix} = \begin{bmatrix} x_1^T x_1 & \dots & x_1^T x_n \\ \vdots & & \vdots \\ x_n^T x_1 & \dots & x_n^T x_n \end{bmatrix} \quad ; \quad K_{ij} = \langle x_i, x_j \rangle = x_i^T x_j$$

Gramova matica

- matica skal. súčinov

Lemma (od Gram. matice ku vzdialenostiam):

$$K = XX^T, \quad \sum_{i=1}^n x_i = 0_e$$

$$\Rightarrow \|x_i - x_j\|^2 = k_{ii} + k_{jj} - 2k_{ij}$$

$\Rightarrow$  od  $K$  ku  $D$ .

Naopak: od  $D$  ku  $K$ :

Youngova - Hausholderova veta:  $[\sum x_i = 0 \text{ stále}]$

$D_{ij} = \|x_i - x_j\| \Rightarrow$  pre  $K = XX^T$  platí:

$$K_{ij} = -\frac{1}{2} \left[ D_{ij}^2 - \frac{1}{n} \sum_{l=1}^n D_{il}^2 - \frac{1}{n} \sum_{p=1}^n D_{pj}^2 + \frac{1}{n^2} \sum_{p=1}^n \sum_{r=1}^n D_{pr}^2 \right] \quad \forall i, j$$

$\rightarrow$  Bez dôkazu

Maticovo:  $A \in \mathbb{R}^{n \times n}$ :  $A_{ij} = -\frac{1}{2} D_{ij}^2$ ,  $P = \left[ I_n - \frac{1}{n} J_n \right] \in \mathbb{R}^{n \times n}$

$$\Rightarrow K = PAP$$

$K = XX^T$  ( $X$  - nepoznáme)

$\Rightarrow K$  - s.d.

$\Rightarrow$  spekt. rozklad:  $K = U \Lambda U^T$

$\uparrow$  vypočítame!

$n \times n$     $n \times n$     $n \times n$     $n \times n$   
 $\uparrow$     $\uparrow$     $\dots$     $\dots$

↑ vypočítané

$$\Rightarrow \text{spekt. rozklad: } K = U \Delta U^T$$

$\uparrow$  ortog.     $\uparrow$  diag. :  $\text{diag}(\lambda_1, \dots, \lambda_n)$

• ak  $\text{rank}(K) = r \Rightarrow \Delta = \text{diag}(\lambda_1, \dots, \lambda_r, 0, \dots, 0)$

$$\rightarrow K = \underbrace{\begin{pmatrix} u_1 & \dots & u_r \end{pmatrix}}_{U_1 \substack{m \times r}} \underbrace{\begin{pmatrix} \lambda_1 & & 0 \\ & \dots & \\ 0 & & \lambda_r \end{pmatrix}}_{\Delta_1 \substack{r \times r}} \underbrace{\begin{pmatrix} u_1^T \\ \vdots \\ u_r^T \end{pmatrix}}_{U_1^T \substack{r \times m}} = U_1 \Delta_1 U_1^T$$

$$= \underbrace{U_1 \Delta_1^{1/2}}_{Y \in \mathbb{R}^{m \times r}} \underbrace{\Delta_1^{1/2} U_1^T}_{Y^T}$$

$$\rightarrow K = Y Y^T$$

$$Y = \begin{pmatrix} -y_1^T \\ \vdots \\ -y_n^T \end{pmatrix}, \quad y_i \in \mathbb{R}^n$$

→ prvé reprezentujú veľkosti:  $\|y_i - y_j\| = D_{ij}$

• menšej rozmerov: BUNU:  $\lambda_1 \geq \dots \geq \lambda_r > 0$

→ vezme si prvých  $q$  vl. hodnôt a vektorov:

$$Y = \begin{pmatrix} | & & | \\ u_1 & \dots & u_q \\ | & & | \end{pmatrix} \begin{pmatrix} \lambda_1^{1/2} & & 0 \\ & \dots & \\ 0 & & \lambda_q^{1/2} \end{pmatrix} \in \mathbb{R}^{m \times q} \quad ; \quad Y = \begin{pmatrix} y_1^T \\ \vdots \\ y_n^T \end{pmatrix} : y_i \in \mathbb{R}^n$$

$m \times q$                        $q \times q$

→ potom už iba aproximujeme:  $\|y_i - y_j\| \approx D_{ij}$

zhrnutie: 1. Máme  $D$

2. vypočítame  $K$  (Y-H veta)

3.  $K = U \Delta U^T$ : spekt. rozklad  $\Rightarrow K = Y Y^T$  pre  $Y \in \mathbb{R}^{m \times r}$   
 $\approx Y Y^T$  pre  $Y \in \mathbb{R}^{m \times q}$  ( $q < r$ )

• ak máme  $s$   $x_1, \dots, x_n \in \mathbb{R}^m \rightarrow$  vypočítame  $D \Rightarrow PCA = QMS^T$

↳ potom  $QMS^T$  pre  $D = PCA$  na pôvodných dátach

• dostaneme určit možno zrotované vektory súradníc  $y_1, \dots, y_n$  voči prvým  $q$  vl. komponentom

- rotácia: máme  $K = Y Y^T$ ,  $Y \in \mathbb{R}^{m \times r}$

→ vezme si  $\tilde{Y} = Y \cdot D \Rightarrow \tilde{Y} \tilde{Y}^T = Y D D^T Y^T = Y Y^T = K$  :  $n$ : ľub. rotácia

uvaha: máme  $K = Y Y^T$ ,  $Y \in \mathbb{R}^{n \times p}$

→ vezmeme  $\tilde{Y} = Y \cdot Q \Rightarrow \tilde{Y} \tilde{Y}^T = Y Q Q^T Y^T = Y Y^T = K$  : aj ľub. rotácia vyhovuje  $K$   
ortog.,  $n \times n$

- ak  $\Delta$  nie je presne maticou vtd.  $\Rightarrow K$  nemusí byť s.e.d. : môže mať  $\lambda_i < 0$ 
  - záporné vl. h. určite neberieme
  - ak máme  $q$  vl. h. si dostatočne veľké, tieľame dostatočne dobrú aproximáciu
    - časté pravidlo: také najmenšie  $q$  :  $\frac{\lambda_1 + \dots + \lambda_q}{|\lambda_1| + \dots + |\lambda_n|} > 0,8$   
↑  
napr.
- na zjavenie  $\lambda_i < 0$  môžeme skontrolovať: ak všetkým  $D_{ij}$  pripočítame kladnú konštantu ( $i \neq j$ )

## 2.) Metrické MS (Metric MS)

- zovšeobecnenie z MS

klasické:  $D_{ij} \approx d_{ij}$ ,  $d_{ij}$  - vzd. medzi  $y_i$  a  $y_j$

metrické:  $f(D_{ij}) \approx d_{ij}$

$f$  - monotónna funkcia, parametrizovaná

- napr.  $f(D_{ij}) = \alpha + \beta D_{ij}$ ,  $\alpha, \beta \geq 0$

- analýza aproximácie pre dané  $\{y_1, \dots, y_n\}$ , parametre  $f$  : vážený súčet štvorcov  
 $y_i \in \mathbb{R}^p$

$$\sum_{i < j} w_{ij} (f(D_{ij}) - d_{ij})^2 = S(Y)$$

↑  
chyba fitu

↑  
stress function

veľky (voľne)

úloha :  $S(Y) \rightarrow \min$   
 $y_1, \dots, y_n$ , parametre  $f$

- nelineárna optimalizácia : numerické riešenia

- vhodný štartovací bod : výsledok z MS

• príklady váh :  $w_{ij} = \frac{1}{d_{ij}^2}$ ,  $w_{ij} = \frac{1}{\sum_{k < l} d_{kl}^2}$

• podobnosť s jadrovou PCA : dáta transformujeme a potom fitujeme

- podobnosť s jadrovou PCA: dáta transformujeme a potom fitujeme (PCA je špec. prípad MML za istých podmienok)

- Sammonovo mapovanie (Sammon mapping):  
 $L_n$  1969  $w_{ij} = \frac{1}{d_{ij} \sum_{s < l} d_{sl}}$ ,  $f(D_{ij}) = D_{ij}$

$$\Rightarrow S(Y) = \frac{1}{\sum_{s < l} d_{sl}} \sum_{i < j} \frac{(D_{ij} - d_{ij})^2}{d_{ij}} \rightarrow \min$$

→ dáva väčšiu váhu bližším objektom: snaží sa ich fitovať presnejšie

### 3. Nemetrické škálovanie (Nonmetric MS)

- snažíme sa zachovať iba poradie vzdialeností (ranky)

↑ nezaujímavajú nás presné vzdialenosti, alebo ich nepoznáme

- máme iba usporiadanie  $s = \frac{n(n-1)}{2}$  vzdialenosti:  $D_{i_1 j_1} < \dots < D_{i_s j_s}$

- cieľ: ↑ toto aproximovať

- 1.) počiatkové  $y_1, \dots, y_n \in \mathbb{R}^q$  - náhodne, pomocou PCA

$$\bullet d_{ij} = \|y_i - y_j\|$$

$$\rightarrow \text{cieľom: } \underbrace{d_{i_1 j_1}}_{r_1} < \dots < \underbrace{d_{i_s j_s}}_{r_s}$$

- 2.)  $d_{ij}$  aproximujeme pomocou  $\hat{d}_{ij}$

$$\text{rank } r_i \approx \hat{r}_i : \hat{r}_1 \leq \dots \leq \hat{r}_s$$

- a) izotonická (monotónna) regresia (isotonic / monotonic regression)


- ide o postupne po  $r_1, r_2, \dots, r_s$

ak  $r_{i+1} \geq r_i$ , tak sme spokojní

ak  $r_{i+1} < r_i \Rightarrow$  všetky  $r_j, r_{j+1}, \dots, r_i$ , ktoré sú väčšie ako  $r_{i+1}$ , spriemerujeme s  $r_{i+1}$ .


Príklad:

$i$	$r_i$	$\hat{r}_i$
1	1,2	1,2
2	1,4 ✓	<del>1,4</del> 1,43
3	1,6 ✓	<del>1,6</del> 1,43
4	1,3 ✗	1,43
⋮		



$\Rightarrow$  schodiskovité ľeie splňajúce  $\hat{v}_1 \leq \hat{v}_2 \leq \dots \leq \hat{v}_3$ .

b) monotónne splajny : aproximujem  $v_1, \dots, v_3$  splajni (kubicky, kvadraticky, ...)  
a ktorého vyžadujeme monotónnosť



3.) aktualizujem  $y_i$ , aby sa zlepšil stres:  $S(Y) = \sum_{i,j} w_{ij} (d_{ij} - \hat{d}_{ij})^2 \rightarrow \min_{y_1, \dots, y_n}$   
- nevypočítame rovnú optimálnu  $y_i$  - napr. iba 1 krok iteratívneho algoritmu

$\rightarrow$  opakujeme 2.) a 3.) až do konvergence

Volba  $q$  (pre  $mM\bar{S}$ ,  $mM\check{S}$ )

- 2 alebo 3 kroky vyriesenia

- zalesenie optim. hodnoty stresu pre hodnotu  $q$ :  $S_q^*$

$\rightarrow$  hľadáme "elast": hodnotu, po ktorej už pridávanie rozmerov nemá veľký prínos

