

projekt - zadanie na stránke - 2 metódy aplikované na dátach

- PDF text + prezentácia na slidech
- niečo zaujímavého sa dozvedieť

na stránku dnes dajú formulár - spätná väzba → napíšte, ak chcete niečo zmeniť

Minule: Proj. sledovanie

$q=1$: $Y = Q^T X$ - najzaujímavejší zmysel
 $\varphi(Y) \rightarrow \max_{Q \in \mathbb{R}^2}$

prakticky: $Y = X Q$
 $n \times 1 \quad n \times k \quad k \times 1$

φ → čo "najnenormálnejšie" dáta

1) $\varphi(Y) = \lambda(Y) \Rightarrow$ PCA

2) $\varphi(Y) = |z_3(Y)|$

$\varphi(Y) = \frac{z_3(Y)^2}{12} + \frac{z_4(Y)^2}{48}$

max φ : nekonzexná optimalizácia

praktické použitie:

- hľadieť lok. max. - potenciálne zaujímavá proj.
- spustíme veľakrát, zapamätáme si všetky výsledky
- vyhladáme výnate pozor projekcie - výnate pohľady $\varphi(Y)$

Dvoj: uhly medzi smermi Q

↳ napr. ak proj₁ a proj₁₀ sú výnate iné, môžeme ich použiť na 2D reprezentáciu

Príklad: olivy - zloženia olivových olejov

Dalšie φ :

3) Vzdialenosť od hustoty $N(\cdot)$:

$\varphi(Y) = \int_{\mathbb{R}} (f_N(y) - f_Y(y))^2 w(y) dy \rightarrow \max$
 ↑ ↑ ↑
 hustota $N(0,1)$ hustota Y váha

$w(y) \equiv 1 \Rightarrow \varphi(Y) = \left[E(f_N(Y)) - E(f_N(Z)) \right]^2$, kde $Z \sim N(0,1)$
 ↑
 normaliz. váha na všetko
 $= \frac{1}{2\sqrt{\pi}}$

$w(y) = \frac{1}{f_N(y)}$: čím ďalej od stredu, tým väčšia váha

$\Rightarrow \varphi(Y) = \frac{(z_3(Y))^2}{12} + \frac{(z_4(Y))^2}{48} \rightarrow 2.)$

• $w(y) = f_N(y)$: najviac v'ahy do stredu

$\rightarrow \varphi(y) = \left[E(f_N(y)) - E(f_N(z)) \right]^2$: to iste' ako pri $w = 1$

prakticky: $\hat{\varphi}(y) \rightarrow$ cez aproximacie a potom: $\hat{\varphi}_j, \hat{E}$
 \downarrow aproximacia pomocou polynomov

4. Shannonova entropia (SHANNON)

\hookrightarrow miera neuporiadankosti

$\hookrightarrow I(Y) = - \int_{\mathbb{R}} f_Y(y) \ln f_Y(y) dy$

- pre n'ik. veliciny s konstantou variaciou: $I(Y)$ je maxim'alna pre $N()$

~~my~~ my chceme co najmenej normalne: $\varphi(y) = 0$ pre $N()$

$\varphi(y) \geq 0$ pre ~~SETS~~

$\Rightarrow \varphi(y) = I(z) - I(y)$, kde $z \sim N(0,1)$

$\rightarrow \max$

$I(z) = \left(+ \frac{1}{2} (1 + \ln(2\pi)) \right) = 1,419$

v praxi: $\tilde{\varphi}(y) = -I(y) \rightarrow \max$

\uparrow overim : overime!

odhad: $\hat{\varphi}(y) = \frac{1}{n} \sum_{i=1}^n \hat{f}_Y(y_i) \cdot \ln \hat{f}_Y(y_i)$

$\hookrightarrow \hat{f}$: jadrovny' odhad hustoty

aproximacia pomocou momentov: $\varphi(y) = \frac{(\sigma_2^2(y))^2}{12} + \frac{(\sigma_4^2(y))^2}{48}$

$\rightarrow \hat{\kappa}_\pm$



odhad: jadrovny' odhad hustoty (kernel density estimation)

data $x_1, \dots, x_n \rightarrow \hat{F}(x)$: schodkovit' f.

zo spojitel'ho rozd.

- odhad rozdelenia - histogram

hustota? - \hat{F} zodpoveda' hustote: $+\infty$





$\hat{f}(x) = \frac{1}{n} \sum \mathcal{J}_{x_i}(x) \rightarrow \underline{\underline{ZLE'}}$

$\mathcal{J}_t(x) = \begin{cases} +\infty, & x=t \\ 0 & \text{inak} \end{cases}$


jadrovny' odhad: n bodoch x_i nahradime \mathcal{J}_i kopcickami so stredmi v x_i .

jadrovi' odľady: n bodoch x_i na kladine \mathcal{I}_{x_i} kopčeleni so stredmi x_i



$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n g_{x_i}(x)$$

↑
jadro



bandwidth h : nastřikovanie

: pre $h \rightarrow 0$: veľmi úzke a vysoké kopčedy

formálne:

$$g_{x_i}(x) = \frac{1}{h} \text{ hustota} \left(\frac{x - x_i}{h} \right)$$

↑
jadro

Viacrozmer: $q > 1$

a) najprv 1-D projekcia pomocou h_1^*

• potom transformovať dáta do $\perp h_1^*$ (projektovať na $\mathcal{C}(h_1^*)^\perp$)

• zase 1-D projekcia transformovaných dát

b) $q=1$: $\mathcal{C}(h^T X)$, $h \in \mathbb{R}^2$, $\|h\|=1$

$q > 1$: $\mathcal{C}(H^T X)$, $h_i \in \mathbb{R}^2$, $\|h_i\|=1$

$$H_{n \times q} = (h_1 \dots h_q)$$

$$h_i \perp h_j \quad \forall i \neq j$$

$$\left. \begin{array}{l} \\ \\ \end{array} \right\} H^T H = I_q$$

$$\max_{H \in \mathbb{R}^{n \times q}} \mathcal{C}(H^T X)$$

$H^T H = I_q$

: teoreticky

výhovor: $y_i = H^T x_i$

$$\underbrace{\begin{pmatrix} y_1 \\ \vdots \\ y_m \end{pmatrix}}_{Y^T} = H^T \underbrace{\begin{pmatrix} x_1 \\ \vdots \\ x_m \end{pmatrix}}_{X^T}$$

$$Y = X H$$

$n \times q \quad n \times m \quad m \times q$

- potrebujeme verziu \mathcal{C} pre viacrozmerne Y

- nie vždy ex, nie vždy sa jednoducho rozštri

- napr. entropia: $\mathcal{C}(Y) = \int \int f(y_1, y_2) \ln f(y_1, y_2) dy_1 dy_2$

- napr. entropia: $\varphi(\gamma) = \int_{\mathbb{R}^2} f(y_1, y_2) \ln f(y_1, y_2) dy_1 dy_2$
 ($q=2$)
 $\rightarrow \hat{\varphi}(\gamma) = \frac{1}{n} \sum_{i=1}^n \hat{f}(y_i) \ln \hat{f}(y_i)$ - výpočtová náročnosť
 $\downarrow \in \mathbb{R}^2$

- momenty: 3 2-rozmerné verzie

Dalšie viacrozmerné indexy ($q > 1$)

1. central mass index: $\hat{\varphi}(\gamma) = \frac{\frac{1}{n} \sum_{i=1}^n e^{-\frac{1}{2} y_i^T y_i} - e^{-\frac{q}{2}}}{1 - e^{-q/2}}$

- vyhládava projekcie s veľá dátami v strede

2. holes index: $\hat{\varphi}(\gamma) = \frac{1 - \frac{1}{n} \sum_{i=1}^n e^{-\frac{1}{2} y_i^T y_i}}{1 - e^{-q/2}}$

- vyhl: profi, ktoré majú v strede diery

\rightarrow znorn výšli z blídania nemormality