

# **KLASIFIKAČNÍ METODA k NEJBLIŽŠÍCH SOUSEDŮ A HLOUBKA DAT**

Ondřej Vencálek

Přírodovědecká fakulta Univerzity Palackého v Olomouci

12.9.2012

# Obsah

Metoda k nejbližším sousedů

Úloha klasifikace

kNN a jádrové odhady hustoty - dvě strany téže mince


Metoda k nejbližším sousedů a hloubka

Přístup založený na „distribučním“ okolí

Symetrizační přístup

DD přístup

## Úloha klasifikace



$$\mathbf{X} = (X_1, \dots, X_m) = (\text{vek}, \text{BMI}, \text{systol.tlak}, \dots)$$

$$\mathbf{X} \sim P_1 \text{ (hustota } f_1) \quad \mathbf{X} \sim P_2 \text{ (hustota } f_2)$$

$$d : \mathbb{R}^m \rightarrow \{1, 2\}$$

## Optimalita funkce $d$

- ▶ minimalizace pravděpodobnosti chybného zařazení

$$\sum_{i=1}^K P(d(\mathbf{X}) \neq i | \mathbf{X} \sim P_i) P(\mathbf{X} \sim P_i) \quad (1)$$

- ▶ minimalizace střední hodnoty ztráty

$$\sum_{i=1}^K \left[ \sum_{j=1}^K \int_{\{\mathbf{y}: d(\mathbf{y})=j\}} z_{i,j} f_i(\mathbf{y}) d\mathbf{y} \right] P(\mathbf{X} \sim P_i) \quad (2)$$

kde  $z_{i,j}$  je ztráta, když objekt ze skupiny  $i$  přiřadíme do sk.  $j$ ;  
pro  $z_{i,j} = 1$  když  $i \neq j$  a nula jinak se (2) redukuje na (1).



- ▶ minimalizace

$$\max_i P(d(\mathbf{X}) \neq i | \mathbf{X} \sim P_i) \quad (3)$$

## Hustoty $f_i$ známé - Bayesovský klasifikátor

$$d(\mathbf{x}) = \arg \max_i \pi_i f_i(\mathbf{x}),$$

kde  $\pi_i = P(\mathbf{X} \sim P_i)$  ... apriorní pravděp.  
dk. optimality viz *Antoch a Vorlíčková (1992)*.



## Hustoty $f_i$ neznámé

- ▶  $d(\mathbf{x}) = \arg \max_i \pi_i f_i(\mathbf{x})$
- ▶  $d(\mathbf{x}) = \arg \max_i \widehat{\pi}_i \widehat{f}_i(\mathbf{x})$


## Tréningová (trénovací) množina:

| Jméno           | (věk, BMI, tlak1, ...) | skupina |
|-----------------|------------------------|---------|
| Jan Novák       | (51, 30, 140,...)      | ♡       |
| Karel Lucemburk | (32, 25, 135,...)      | ★       |
| Jindřich Feo    | (65, 23, 165,...)      | ♡       |
| Petr Petr       | (40, 31, 150,...)      | ♡       |
| Jakub Hodný     | (54, 22, 130,...)      | ★       |
| :               |                        |         |

| Skupina ♡    |                        |
|--------------|------------------------|
| Jméno        | (věk, BMI, tlak1, ...) |
| Jan Novák    | (51, 30, 140,...)      |
| Jindřich Feo | (65, 23, 165,...)      |
| Petr Petr    | (40, 31, 150,...)      |
| :            |                        |

→

| Skupina 1 |                      |
|-----------|----------------------|
| 1         | $\mathbf{x}_{1,1}$   |
| 2         | $\mathbf{x}_{1,2}$   |
| :         |                      |
| $n_1$     | $\mathbf{x}_{1,n_1}$ |



| Skupina ★       |                        |
|-----------------|------------------------|
| Jméno           | (věk, BMI, tlak1, ...) |
| Karel Lucemburk | (32, 25, 135,...)      |
| Jakub Hodný     | (54, 22, 130,...)      |
| :               |                        |

→

| Skupina 2 |                      |
|-----------|----------------------|
| 1         | $\mathbf{x}_{2,1}$   |
| 2         | $\mathbf{x}_{2,2}$   |
| :         |                      |
| $n_2$     | $\mathbf{x}_{2,n_2}$ |

## Značení:

$$TS_i = \{\mathbf{x}_{i,j}, j = 1, \dots, n_i\} \text{ pro } i = 1, \dots, K$$

...  $i$ -tá část tréningové množiny

$$n = \sum_i n_i$$

... celkový počet prvků tréningové množiny

## Odhad hustoty $f_i$

- ▶ parametrický přístup
    - ▶ LDA (Fisher 1936), QDA
  - ▶ neparametrický přístup
    - ▶ jádrový odhad hustoty (Rosenblatt 1956, Parzen 1962)
    - ▶ metoda k nejbližších sousedů (kNN) (Fix a Hodges 1951)
- 

Neparametrický přístup:

mějme bod  $\mathbf{x} \in R^m$  a nějaké jeho okolí  $L_i(\mathbf{x})$ , pak odhad  $f_i(\mathbf{x})$  můžeme založit na approximaci

$$P(\mathbf{X} \in L_i(\mathbf{x}) | \mathbf{X} \sim P_i) = \int_{L_i(\mathbf{x})} f_i(\mathbf{y}) d\mathbf{y} \cong f_i(\mathbf{x}) \lambda(L_i(\mathbf{x}))$$

$$\widehat{f_i(\mathbf{x})} = \frac{k_i}{n_i \lambda(L_i(\mathbf{x}))},$$

kde  $k_i$  ... počet bodů z  $TS_i$ , které náleží  $L_i(\mathbf{x})$ ,  
 $n_i$  ... počet všech bodů z  $TS_i$ .

## Jádrové odhady hustoty

$$\widehat{f_i(\mathbf{x})} = \frac{k_i}{n_i \lambda(L_i(\mathbf{x}))},$$

Nechť  $L_1(\mathbf{x}) = L_2(\mathbf{x}) = \dots = L_K(\mathbf{x}) =: L(\mathbf{x})$

kde  $L(\mathbf{x})$  je takové okolí bodu, že  $\lambda(L(\mathbf{x})) = V$  (konst.)

$$\begin{aligned} d(\mathbf{x}) = \arg \max_i \widehat{\pi}_i \widehat{f_i(\mathbf{x})} &= \arg \max_i \widehat{\pi}_i \frac{1}{n_i \lambda(L(\mathbf{x}))} \sum_{j=1}^{n_i} I_{[\mathbf{x}_{i,j} \in L(\mathbf{x})]} \\ &= \arg \max_i \widehat{\pi}_i \frac{1}{n_i \lambda(L(\mathbf{x}))} \sum_{j=1}^{n_i} Ker(\mathbf{x}, \mathbf{x}_{i,j}, L(\mathbf{x})) \end{aligned}$$


## Metoda k nejbližším sousedů

$$\widehat{f_i(\mathbf{x})} = \frac{k_i}{n_i \lambda(L_i(\mathbf{x}))},$$

Nechť  $L_1(\mathbf{x}) = L_2(\mathbf{x}) = \dots = L_K(\mathbf{x}) =: L(\mathbf{x})$

kde  $L(\mathbf{x})$  je takové okolí bodu, že  $\sum_i k_i = k$  (konst.)

Pro  $\widehat{\pi}_i = \frac{n_i}{n}$  je  $\arg \max_i \widehat{\pi}_i \widehat{f_i(\mathbf{x})} = \arg \max_i k_i$ .



## Kolika sousedů se ptát aneb jak zvolit $k$


$$(P1) \lim_{n_i \rightarrow \infty} k = \infty$$

$$(P1) \lim_{n_i \rightarrow \infty} k/n_i = 0$$

$$\forall \mathbf{x} \in \mathbb{R}^m \quad \widehat{f}_i(\mathbf{x}) = \frac{k_i}{n_i \lambda(L_i(\mathbf{x}))} \xrightarrow{P} f_i(\mathbf{x}) \text{ pro } n_i \rightarrow \infty \Leftrightarrow (P1) \& (P2)$$

Pozor: pro pevné  $k \in \mathbb{N}$  a  $n \in \mathbb{N}$  je  $\int_{\mathbb{R}^m} \widehat{f}_i(\mathbf{x}) d\mathbf{x} \neq 1$ .

Příklad: 1-NN v  $\mathbb{R}^1$ :



$$\int_{x_{max}}^{\infty} \frac{1}{n(x-x_{max})} dx = \frac{1}{n} \int_0^{\infty} \frac{1}{x} dx = \infty.$$

## O nejbližším sousedovi aneb když $k = 1$

$E_{1NN} = P(\text{chybné zařazení pomocí 1-NN})$

$E_{Bayes} = P(\text{chybné zařazení pomocí Bayes. klasifikátoru})$

$$E_{1NN} \leq 2E_{Bayes}$$

Přesněji: pro  $K \geq 2$  skupin platí

$$E_{1NN} \leq E_{Bayes} \left( 2 - \frac{K}{K-1} E_{Bayes} \right)$$

dk. viz *Hand (1981)*.

# Obsah

Metoda k nejbližším sousedů

Úloha klasifikace

kNN a jádrové odhady hustoty - dvě strany téže mince

Metoda k nejbližším sousedů a hloubka

Přístup založený na „distribučním“ okolí

Symetrizační přístup

DD přístup



## $k$ NN s využitím hloubky, přístup „distribučního“ okolí

Připomeňme:

$$P(\mathbf{X} \in L(\mathbf{x})) \cong f(\mathbf{x}) \cdot \lambda_d(L(\mathbf{x})),$$

kde  $L(\mathbf{x})$  je nějaké okolí bodu  $\mathbf{x}$ :

- ▶  $L(\mathbf{x}) = \{\mathbf{y} \in \mathbb{R}^d : \|\mathbf{x} - \mathbf{y}\| < \eta\}$
- ▶  $L(\mathbf{x}; P) = \{\mathbf{y} \in \mathbb{R}^d : |f(\mathbf{x}; P) - f(\mathbf{y}; P)| < \eta\}.$





## $k$ NN s využitím hloubky, přístup „distribučního“ okolí

Připomeňme:

$$P(\mathbf{X} \in L(\mathbf{x})) \cong f(\mathbf{x}) \cdot \lambda_d(L(\mathbf{x})),$$

kde  $L(\mathbf{x})$  je nějaké okolí bodu  $\mathbf{x}$ :

- ▶  $L(\mathbf{x}) = \{\mathbf{y} \in \mathbb{R}^d : \|\mathbf{x} - \mathbf{y}\| < \eta\}$
- ▶  $L(\mathbf{x}; P) = \{\mathbf{y} \in \mathbb{R}^d : |\mathcal{D}(\mathbf{x}; P) - \mathcal{D}(\mathbf{y}; P)| < \eta\}.$



## *kNN s využitím hloubky, přístup „distribučního“ okolí*


$$f_i(\mathbf{x}) = h_i(D(\mathbf{x}; P_i)) \quad i = 1, \dots, K$$

$$\widehat{\pi}_i \widehat{f}_i(\mathbf{x}) = \frac{n_i}{n} \frac{k_i}{n_i} \frac{1}{\widehat{\lambda}_d(L_i(\mathbf{x}))} = \frac{k_i}{n \widehat{\lambda}_d(L_i(\mathbf{x}))}$$


$$d(\mathbf{x}) = \arg \min_{i=1, \dots, K} \widehat{\lambda}_d(L(\mathbf{x}, \widehat{P}_i)),$$

kde  $L(\mathbf{x}, \widehat{P}_i)$  je „distribučním“ okolí bodu  $\mathbf{x}$ , které obsahuje právě  $k$  bodů z  $TS_i$ .


## $k$ NN s využitím hloubky, symetrizační přístup




## $k$ NN s využitím hloubky, symetrizační přístup




## $k$ NN s využitím hloubky, symetrizační přístup



## $k$ NN s využitím hloubky, symetrizační přístup



## $k$ NN s využitím hloubky, symetrizační přístup




## $k$ NN s využitím hloubky, symetrizační přístup

Příklad:

Okolí bodů  $[0,1]$ ,  $[2,0]$  a  $[\frac{2}{5}\sqrt{5}, \frac{2}{5}\sqrt{5}]$  vzhledem k rozdělení

$$N_2 \left( \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 4 & 0 \\ 0 & 1 \end{pmatrix} \right).$$



## *k*NN s využitím hloubky, symetrizační přístup


Značení:

$\mathbf{X}_1, \dots, \mathbf{X}_n$  ... všechny body tréningové množiny  
 $\mathbf{x}$  ... nové pozorování



Postup:

1. „Reflexe“:  $\mathbf{X}_{n+i} := 2\mathbf{x} - \mathbf{X}_i$  pro  $i = 1, \dots, n$ ,  
body  $\mathbf{X}_1, \dots, \mathbf{X}_{2n}$  určují rozdělení  $P_{\mathbf{x}}^{(n)}$ .
2. Seřad'me body  $\mathbf{X}_1, \dots, \mathbf{X}_n$  tak, aby platilo  
 $D(\mathbf{X}_{(1)}, P_{\mathbf{x}}^{(n)}) \geq D(\mathbf{X}_{(2)}, P_{\mathbf{x}}^{(n)}) \geq \dots \geq D(\mathbf{X}_{(n)}, P_{\mathbf{x}}^{(n)})$ .
3. Pro libovolné  $k \in \{1, \dots, n\}$  představují body  
 $\mathbf{X}_{(i)}, i = 1, \dots, k$ ,  $k$  nejbližších sousedů bodu  $\mathbf{x}$ .



## $k$ NN s využitím hloubky, DD přístup





## $k$ NN s využitím hloubky, DD přístup



## *k*NN s využitím hloubky, DD přístup



## $k$ NN s využitím hloubky, DD přístup



## $k$ NN s využitím hloubky, DD přístup

