



ANALÝZA A KLASIFIKACE DAT



prof. Ing. Jiří Holčík, CSc.




INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

IV. LINEÁRNÍ KLASIFIKACE


PRINCIPY KLASIFIKACE

- ☑ pomocí **diskriminačních funkcí** – funkcí, které určují míru příslušnosti k dané klasifikační třídě;
- ☑ pomocí **definice hranic** mezi jednotlivými třídami a **logických pravidel**;
- ☑ pomocí **vzdálenosti** od **reprezentativních obrazů** (etalonů) klasifikačních tříd;
- ☑ pomocí **ztotožnění s etalony**;


LINEÁRNÍ SEPARABILITA



lineárně separabilní
úloha



lineárně neseparabilní
úloha
lineárně separované
klasifikační třídy



nelineárně
separabilní úloha

DICHOTOMICKÁ ÚLOHA

PRINCIP

nejjednodušší realizace hraniční plochy je lineární funkcí

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0$$

\mathbf{w} je váhový vektor, w_0 je práh;

$$\mathbf{x} \in \omega_1, \text{ když } y(\mathbf{x}) \geq 0$$

$$\mathbf{x} \in \omega_2, \text{ když } y(\mathbf{x}) < 0$$

rovnice hranice je $y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$

((n-1)-rozměrná nadplocha (nadrovina) v n-rozměrném prostoru

DICHOTOMICKÁ ÚLOHA

ZÁKLADNÍ VLASTNOSTI

zápis v jiném (kompaktnějším) tvaru:

$x_0 = 1$ a pak $\tilde{\mathbf{w}} = (w_0, \mathbf{w})$ a $\tilde{\mathbf{x}} = (x_0, \mathbf{x})$

z toho

$$y(\mathbf{x}) = \tilde{\mathbf{w}}^T \cdot \tilde{\mathbf{x}}$$


DICHOTOMICKÁ ÚLOHA

ZÁKLADNÍ VLASTNOSTI

- ☑ pro $\mathbf{x}_A, \mathbf{x}_B$ na hraniční přímce je $y(\mathbf{x}_A) = y(\mathbf{x}_B) = 0$; proto je i $\mathbf{w}^T(\mathbf{x}_A - \mathbf{x}_B) = 0 \Rightarrow$ vektor \mathbf{w} je ortogonální (kolmý) k hraniční přímce;
- ☑ je-li \mathbf{x} na hraniční přímce, je $y(\mathbf{x}) = 0$ a tak normálová vzdálenost počátku od hraniční přímky je dána vztahem

$$\frac{\mathbf{w}^T \mathbf{x}}{\|\mathbf{w}\|} = -\frac{w_0}{\|\mathbf{w}\|}$$

DICHOTOMICKÁ ÚLOHA ZÁKLADNÍ VLASTNOSTI



DICHOTOMICKÁ ÚLOHA

ZÁKLADNÍ VLASTNOSTI

$y(\mathbf{x})$ udává kolmou vzdálenost d bodu \mathbf{x} od hraniční přímky (je-li \mathbf{x}_\perp ortogonální projekce \mathbf{x} na hranici tak, že

$$\mathbf{x} = \mathbf{x}_\perp + d \frac{\mathbf{w}}{\|\mathbf{w}\|}$$

vynásobením obou stran \mathbf{w}^\top , přičtením w_0 a s použitím $y(\mathbf{x}) = \mathbf{w}^\top \mathbf{x} + w_0$ a $y(\mathbf{x}_\perp) = \mathbf{w}^\top \mathbf{x}_\perp + w_0 = 0$, dostaneme

$$d = \frac{y(\mathbf{x})}{\|\mathbf{w}\|}$$

ÚLOHA S VÍCE TŘÍDAMI


☑ kombinace více tříd (problém?):

→ klasifikace „jedna versus zbytek“

$R-1$ hranice oddělí jednu klasifikační třídu od všech dalších

→ klasifikace „jedna versus jedna“

$R(R-1)/2$ binárních hranic mezi každými dvěma třídami



ÚLOHA S VÍCE TŘÍDAMI

☑ jak se vyhnout „problémům“?

zavedením principu diskriminační funkce

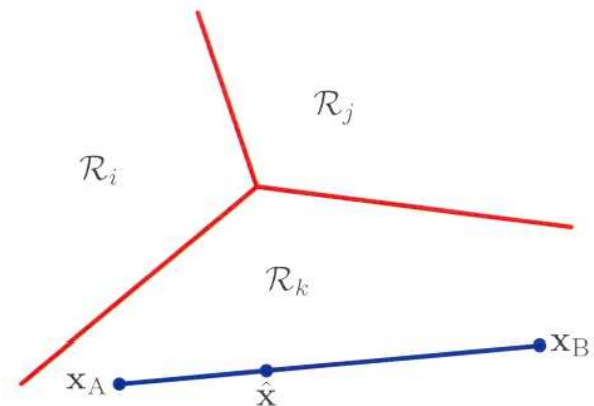
$$g_r(\mathbf{x}) = \mathbf{w}_r^T \mathbf{x} + w_{r0}$$

do r -té třídy ω_r zařadíme obraz \mathbf{x} za předpokladu, že

$$g_r(\mathbf{x}) > g_s(\mathbf{x}) \text{ pro } \forall r \neq s$$

klasifikační hranice je průmět průsečíku

$g_r(\mathbf{x}) = g_s(\mathbf{x})$ do obrazového prostoru
takto definovaný klasifikační
prostor je vždy spojitý a konvexní



METODY STANOVENÍ KLASIFIKAČNÍCH HRANIC

- ☑ metoda nejmenších čtverců
- ☑ perceptron (neuron)
- ☑ Fisherova lineární diskriminace

METODA NEJMENŠÍCH ČTVERCŮ

- ☑ minimalizace součtu čtverců chybové funkce;
- ☑ mějme cílový (klasifikační) vektor vyjádřen binárním kódem $\mathbf{1}$ z R ($\mathbf{t} = (0,0,0,1,0)^T$)
- ☑ každá je třída ω_r popsána lineární funkcí

$$g_r(\mathbf{x}) = \mathbf{w}_r^T \mathbf{x} + w_{r0},$$

kde $r = 1, \dots, R$;

METODA NEJMENŠÍCH ČTVERCŮ

sumární popis těchto reprezentací je

$$\mathbf{g}(\mathbf{x}) = \tilde{\mathbf{W}}^T \cdot \tilde{\mathbf{x}}$$

kde $\tilde{\mathbf{W}}^T$ je matice, jejíž r -tý sloupec zahrnuje $n+1$ dimenzionální vektor

$$\tilde{\mathbf{w}}_r = (w_0, \mathbf{w}_r^T) \text{ a } \tilde{\mathbf{x}} = (x_0, \mathbf{x}^T)$$

hodnota x na vstupu je zařazena do třídy, pro níž je $g_r(\mathbf{x}) = \tilde{\mathbf{w}}_r^T \cdot \tilde{\mathbf{x}}$ největší;

METODA NEJMENŠÍCH ČTVERCŮ

pokud máme učební množinu vyjádřenou $\{\mathbf{x}_i, \mathbf{t}_i\}$, $i=1, \dots, n$ a i -tý řádek matice \mathbf{T} obsahuje vektor \mathbf{t}_i^T a v matici $\tilde{\mathbf{X}}$ je i -tý řádek $\tilde{\mathbf{x}}_i^T$, pak funkce součtu čtverců chyb je

$$E_n(\tilde{\mathbf{W}}) = \frac{1}{2} \text{Tr} \left\{ (\tilde{\mathbf{X}} \cdot \tilde{\mathbf{W}} - \mathbf{T})^T (\tilde{\mathbf{X}} \cdot \tilde{\mathbf{W}} - \mathbf{T}) \right\}$$



Derivací podle $\tilde{\mathbf{W}}$, kterou položíme rovno nule dostáváme

$$\tilde{\mathbf{W}} = (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{T} = \tilde{\mathbf{X}}^S \mathbf{T}$$



kde $\tilde{\mathbf{X}}^S$ je tzv. pseudoinverzní matice k matici $\tilde{\mathbf{X}}$. Diskriminační funkce pak jsou ve tvaru

$$\mathbf{g}(\mathbf{x}) = \tilde{\mathbf{W}}^T \cdot \tilde{\mathbf{x}} = \mathbf{T}^T (\tilde{\mathbf{X}}^S)^T \cdot \tilde{\mathbf{x}}$$

METODA NEJMENŠÍCH ČTVERCŮ





METODA NEJMENŠÍCH ČTVERCŮ




PERCEPTRON

MODEL NEURONU



MODEL NEURONU

vstupy



vstup

$$\sum_{k=1}^d x_k w_k < T$$

$$\sum_{k=1}^d x_k w_k \geq T$$

výstup

0

1

$$\xi = \sum_{i=1}^n w_i x_i - \theta = \sum_{i=0}^n w_i x_i$$

Lineární model neuronu s prahem

PERCEPTRON

- ☑ předpokládejme, že

$$\mathbf{w}^{*T} \mathbf{x} > 0 \text{ pro } \forall \mathbf{x} \in \omega_1$$

$$\mathbf{w}^{*T} \mathbf{x} < 0 \text{ pro } \forall \mathbf{x} \in \omega_2$$

- ☑ snažíme se o nalezení extrému ztrátové funkce perceptronu

$$J(\mathbf{w}) = \sum_{\mathbf{x} \in Y} (\delta_{\mathbf{x}} \mathbf{w}^T \mathbf{x}) \quad (\text{💡})$$

- ☑ Y je podmnožina učební množiny, jejíž obrazy byly chybně klasifikovány s daným nastavením váhového vektoru \mathbf{w} ; hodnoty proměnné $\delta_{\mathbf{x}}$ jsou stanoveny tak, že $\delta_{\mathbf{x}} = -1$ pro $\mathbf{x} \in \omega_1$ a $\delta_{\mathbf{x}} = 1$ pro $\mathbf{x} \in \omega_2$.
- ☑ součet (💡) je zřejmě vždycky nezáporný a roven nule pokud Y je prázdná množina.
- ☑ je to funkce spojitá a po částech lineární (gradient není definován ve chvíli, kdy se mění počet chybně klasifikovaných vektorů \mathbf{x})

PERCEPTRON

algoritmus výpočtu \mathbf{w}^* (gradientní metoda):

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \left. \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} \right|_{\mathbf{w}=\mathbf{w}(t)}$$

$\mathbf{w}(t)$ je vektor váhových koeficientů v t-tém kroku iterace;

$$\rho_t > 0$$

tam kde je gradient definován je

$$\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = \sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \mathbf{x}$$


po dosazení do definičního vztahu je

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \mathbf{x}$$


PERCEPTRON

algoritmus výpočtu \mathbf{w}^* - pseudokód:

- zvolte náhodně $\mathbf{w}(0)$
- zvolte ρ_0
- $t=0$
- repeat
 - $Y = \{\emptyset\}$
 - for $i=1$ to N
 - if $\delta_{x_i} \mathbf{w}(t)^T \mathbf{x}_i \geq 0$ then $Y = Y \cup \{\mathbf{x}_i\}$
 - $\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \mathbf{x}$
 - nastavte ρ_t
 - $t=t+1$
- until $Y = \{\emptyset\}$





PERCEPTRON



FISHEROVA DISKRIMINACE

- ☑ redukce dimenzionality?
- ☑ nejdříve dichotomický problém:
 - předpokládejme na vstupu n-rozměrný vektor \mathbf{x} , který promítneme do jednoho rozměru pomocí $y = \mathbf{w}^T \mathbf{x}$
 - projekcí do jednoho rozměru ztrácíme mnohou zajímavou informací, ale určením prvků váhového vektoru \mathbf{w} můžeme nastavit projekci, která maximalizuje separaci tříd;

FISHEROVA DISKRIMINACE



FISHEROVA DISKRIMINACE

☑ předpokládejme, že známe učební množinu n_1 obrazů z třídy ω_1 a n_2 obrazů z ω_2 ;

☑ střední vektory reprezentující každou třídu jsou

$$\mathbf{m}_1 = \frac{1}{n_1} \sum_{i \in \omega_1} \mathbf{x}_i \quad \text{a} \quad \mathbf{m}_2 = \frac{1}{n_2} \sum_{i \in \omega_2} \mathbf{x}_i$$

☑ nejjednodušší míra separace klasifikačních tříd, je separace klasifikačních průměrů, tj. stanovení \mathbf{w} tak, aby byla maximalizována hodnota $\mathbf{m}_2 - \mathbf{m}_1 = \mathbf{w}^T (\mathbf{m}_2 - \mathbf{m}_1)$, kde $m_r = \mathbf{w}^T \mathbf{m}_r$ je průměr projektovaných dat ze třídy ω_r ;

FISHEROVA DISKRIMINACE

- ☑ aby hodnota $m_2 - m_1$ neomezeně nerostla s růstem modulu w , předpokládáme jeho jednotkovou délku, tj. $\sum_i w_i^2 = 1$
- ☑ Langrangův součinitel (multiplikátor) pro hledání vázaného extrému

$$\mathbf{w} \propto (\mathbf{m}_2 - \mathbf{m}_1)$$

**Fisherův
diskriminátor**

podle Fisherova pravidla stanovíme pouze optimální směr souřadnice, na kterou promítáme obrazy klasifikovaných tříd.

abychom stanovili rozhodovací pravidlo, musíme určit hodnotu prahu w_0

LANGRANGŮV SOUČINITEL

☑ Langragova metoda neurčitých koeficientů

Nechť $f(x,y)$ a $g(x,y)$ mají v okolí bodů křivky $g(x,y)=0$ totální diferenciál. Nechť v každém bodě křivky $g(x,y)=0$ je aspoň jedna z derivací $\partial g/\partial x$, $\partial g/\partial y$ různá od nuly. Má-li funkce $z=f(x,y)$ v bodě $[x_0,y_0]$ křivky $g(x,y)=0$ lokální extrém na této křivce, pak existuje taková konstanta λ , že pro funkci

$$F(x,y)=f(x,y) + \lambda \cdot g(x,y) \quad (\heartsuit)$$

jsou v bodě $[x_0,y_0]$ splněny rovnice

$$\partial F(x_0,y_0)/\partial x=0; \partial F(x_0,y_0)/\partial y=0 \quad (\heartsuit)$$

a samozřejmě $g(x_0,y_0)=0$ (**podmínky nutné**).

Vázané extrémy lze tedy hledat tak, že sestrojíme funkci (\heartsuit) a řešíme rovnice (\heartsuit) pro neznámé x_0,y_0, λ (λ nazýváme Lagrangeův součinitel (multiplikátor)).

LANGRANGŮV SOUČINITEL

- ☑ Langragova metoda neurčitých koeficientů

totální diferenciál:

Je-li $f(x,y)$ v $[x_0,y_0]$ diferencovatelná, nazývá se výraz

$$dz = (\partial f / \partial x) \cdot dx + (\partial f / \partial y) \cdot dy$$

totální diferenciál funkce $z=f(x,y)$.

LANGRANGŮV SOUČINITEL

☑ Langragova metoda neurčitých koeficientů

podmínky postačující:

Sestrojme v bodě $[x_0, y_0]$ druhý diferenciál funkce (♥)

$$d^2F(x_0, y_0) = \partial^2 F(x_0, y_0) / \partial x^2 + 2\partial^2 F(x_0, y_0) / \partial x \partial y + \partial^2 F(x_0, y_0) / \partial y^2 (\Rightarrow)$$

Jestliže pro všechny body $[x_0 + dx, y_0 + dy]$ z určitého okolí bodu $[x_0, y_0]$ takové, že $g(x_0 + dx, y_0 + dy) = 0$ a že dx a dy nejsou zároveň rovny nule, je (⇒) kladné, resp. záporné, pak je v bodě $[x_0, y_0]$ vázaný lokální extrém, a to minimum (resp. maximum).

LANGRANGŮV SOUČINITEL

☑ Langragova metoda neurčitých koeficientů



Obdobně se řeší úloha najít vázané extrémy funkce několika proměnných, např. nutná podmínka k existenci lokálního extrému funkce $w=f(x,y,z,u,v)$ při podmínkách $F_1(x,y,z,u,v)$, $F_2(x,y,z,u,v)$ je splnění rovnic

$\partial G/\partial x=0$, $\partial G/\partial y=0$, $\partial G/\partial z=0$, $\partial G/\partial u=0$, $\partial G/\partial v=0$, $F_1=0$ a $F_2=0$,

kde $G= f+ \lambda_1 F_1+\lambda_2 F_2$, tj. soustava 7 rovnic pro 7 neznámých.

FISHEROVA DISKRIMINACE

problém:



řešení:

nejen maximální vzdálenost tříd, ale
současně i minimální rozptyl uvnitř tříd

FISHEROVA DISKRIMINACE

- ☑ variance transformovaných dat ze třídy ω_1 je dána $s_r^2 = \sum_{i \in \omega_1} (y_i - m_i)^2$

kde $y_i = \mathbf{w}^T \mathbf{x}_i$;

- ☑ celková variance uvnitř klasifikačních tříd z celé báze dat jednoduše součtem $s_1^2 + s_2^2$

FISHEROVA DISKRIMINACE

- ✓ Fisherovo kritérium:

$$J(\mathbf{w}) = \frac{(m_2 - m_1)^2}{s_1^2 + s_2^2}$$

- ✓ po dosazení maticově:

$$J(\mathbf{w}) = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}} \quad (\text{🔔})$$

kde \mathbf{S}_B matice kovariance mezi třídami

$$\mathbf{S}_B = (\mathbf{m}_2 - \mathbf{m}_1)(\mathbf{m}_2 - \mathbf{m}_1)^T$$

a \mathbf{S}_W je matice celkové kovariance uvnitř tříd

$$\mathbf{S}_W = \sum_{i \in \omega_1} (\mathbf{x}_i - \mathbf{m}_1)(\mathbf{x}_i - \mathbf{m}_1)^T + \sum_{i \in \omega_2} (\mathbf{x}_i - \mathbf{m}_2)(\mathbf{x}_i - \mathbf{m}_2)^T$$

FISHEROVA DISKRIMINACE

- ☑ maximální $J(\mathbf{w})$ určíme po derivaci (🔔) podle \mathbf{w} tehdy, když platí

$$(\mathbf{w}^T \mathbf{S}_B \mathbf{w}) \mathbf{S}_W \mathbf{w} = (\mathbf{w}^T \mathbf{S}_W \mathbf{w}) \mathbf{S}_B \mathbf{w}$$

z toho pak

$$\mathbf{w} \propto \mathbf{S}_W^{-1}(\mathbf{m}_2 - \mathbf{m}_1)$$

α je Lagrangův multiplikátor

**Fisherův
diskriminátor**

směr vektoru $\mathbf{m}_2 - \mathbf{m}_1$ je na rozdíl od původního případu modifikován maticí \mathbf{S}_W ;

pokud je kovariance uvnitř tříd izotropní (rozptyl je týž ve všech směrech), \mathbf{S}_W je úměrná jednotkové matici a \mathbf{w} má opět směr vektoru $\mathbf{m}_2 - \mathbf{m}_1$

FISHEROVA DISKRIMINACE

VÍCE KLASIFIKAČNÍCH TŘÍD

předpoklady:

- počet tříd: $R > 2$
- rozměr dat: $n > R$

zavedeme $n' > 1$ lineárních funkcí $y_k = \mathbf{w}_k^T \mathbf{x}$, kde $k=1,2,\dots,n'$.
Hodnoty y_k tvoří vektor \mathbf{y} . Podobně váhové vektory \mathbf{w}_k reprezentují sloupce matice \mathbf{W}

$$\mathbf{y} = \mathbf{W}^T \mathbf{x}$$

zobecnění matice kovariance uvnitř tříd

$$\mathbf{S}_W = \sum_{r=1}^R \mathbf{S}_r$$

kde

$$\mathbf{S}_r = \sum_{i \in \omega_r} (\mathbf{x}_i - \mathbf{m}_r)(\mathbf{x}_i - \mathbf{m}_r)^T \text{ a } \mathbf{m}_r = \frac{1}{n_r} \cdot \sum_{i \in \omega_r} \mathbf{x}_i$$

n_r je počet vzorků v r -té třídě

FISHEROVA DISKRIMINACE

VÍCE KLASIFIKAČNÍCH TŘÍD

- ☑ abychom byli schopni určit zobecněnou matici kovariance mezi třídami, určíme nejdříve celkovou kovarianční matici

$$\mathbf{S}_T = \sum_{i=1}^n (\mathbf{x}_i - \mathbf{m})(\mathbf{x}_i - \mathbf{m})^T$$

- ☑ kde \mathbf{m} je průměr celé množiny obrazů

$$\mathbf{m} = \frac{1}{n} \cdot \sum_{i=1}^n \mathbf{x}_i = \frac{1}{n} \cdot \sum_{r=1}^R n_r \mathbf{x}_i \text{ a } n = \sum_r n_r$$

- ☑ pro celkovou kovarianční matici platí $\mathbf{S}_T = \mathbf{S}_W + \mathbf{S}_B$, kde

$$\mathbf{S}_B = \sum_{r=1}^R n_r (\mathbf{m}_r - \mathbf{m})(\mathbf{m}_r - \mathbf{m})^T$$

FISHEROVA DISKRIMINACE

VÍCE KLASIFIKAČNÍCH TŘÍD

- ☑ podobně mohou být definovány matice v transformovaném n' -rozměrném prostoru \mathbf{y}

$$\mathbf{s}_W = \sum_{r=1}^R \sum_{i \in \omega_r} (\mathbf{y}_i - \boldsymbol{\mu}_r)(\mathbf{y}_i - \boldsymbol{\mu}_r)^T \text{ a}$$

$$\mathbf{s}_B = \sum_{r=1}^R n_r (\boldsymbol{\mu}_r - \boldsymbol{\mu})(\boldsymbol{\mu}_r - \boldsymbol{\mu})^T,$$

kde

$$\boldsymbol{\mu}_r = \frac{1}{n_r} \sum_{i \in \omega_r} \mathbf{y}_i \text{ a } \boldsymbol{\mu} = \frac{1}{n} \sum_{r=1}^R n_r \boldsymbol{\mu}_r$$

FISHEROVA DISKRIMINACE

VÍCE KLASIFIKAČNÍCH TŘÍD

- ☑ opět chceme určit co největší skalár když je velká kovariance mezi třídami a malá kovariance uvnitř tříd z mnoha kritérií, např.

$$J(\mathbf{W}) = \text{Tr}\{\mathbf{S}_W^{-1} \cdot \mathbf{S}_B\}$$

toto kritérium může být přepsáno do tvaru

$$J(\mathbf{W}) = \text{Tr}\{(\mathbf{W}\mathbf{S}_W\mathbf{W}^T)^{-1}(\mathbf{W}\mathbf{S}_B\mathbf{W}^T)\}$$

- ☑ váhové vektory jsou v tom případě dány vlastními vektory matice $\mathbf{S}_W^{-1}\mathbf{S}_B$, které odpovídají jejím n' největším vlastním číslům

Příprava nových učebních materiálů pro obor Matematická biologie

je podporována projektem ESF

č. CZ.1.07/2.2.00/07.0318

„VÍCEOBOROVÁ INOVACE STUDIA MATEMATICKÉ BIOLOGIE“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ