



ANALÝZA A KLASIFIKACE DAT



prof. Ing. Jiří Holčík, CSc.




INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

V. 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




KLASIFIKACE PODLE DISKRIMINAČNÍCH FUNKCÍ

- ☑ nejjednodušším tvarem diskriminační funkce je funkce lineární, která má tvar

$$g_r(\mathbf{x}) = a_{r0} + a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rn}x_n$$

kde a_{r0} je práh diskriminační funkce posouvající počátek souřadného systému a a_{ri} jsou váhové koeficienty i-tého příznaku x_i

- ☑ lineárně separabilní třídy



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



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

$y(\mathbf{x})$ 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
- ☑ algoritmus podpůrných vektorů

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

$$\tilde{\mathbf{w}}_r = (w_0, \mathbf{w}_r^T) \text{ a } \tilde{\mathbf{x}} = (x_0, \mathbf{x}^T) \text{ , } x_0 = 1$$

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

když cílové vektory trénovací množiny \mathbf{t}_k , $k=1,\dots,K$ splňují lineární funkcí



$$\mathbf{a}^T \cdot \mathbf{t}_k + b = 0$$

pro libovolné k a dané konstanty \mathbf{a} a b , pak lineární klasifikační model pro libovolný obraz splňuje ekvivalentní vztah



$$\mathbf{a}^T \cdot \mathbf{g}(\mathbf{x}) + b = 0$$

To znamená, že pro kódovací schéma 1 z R pro R klasifikačních tříd, je součet prvků vektoru $\mathbf{g}(\mathbf{x})$ roven jedné stejně jako součet prvků vektoru \mathbf{t}_k pro libovolný obrazový vektor \mathbf{x} . Tento požadavek ale není postačující, protože hodnoty vektoru $\mathbf{g}(\mathbf{x})$ nejsou nutně vázány na interval $\langle 0; 1 \rangle$, což by bylo třeba, kdyby měly vyjadřovat odhady pravděpodobností zatřídění do jednotlivých klasifikačních kategorií.

METODA NEJMENŠÍCH ČTVERCŮ

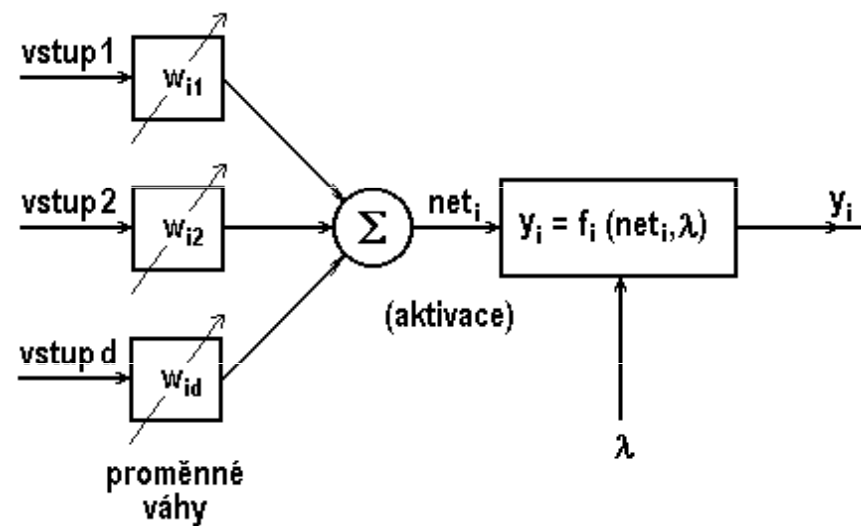



METODA NEJMENŠÍCH ČTVERCŮ




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

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

Lineární model neuronu s prahem

PERCEPTRON

UČENÍ

Obecné požadavky na postup nastavení hodnot váhových koeficientů perceptronu (a nejen perceptronu) jsou:

- ✓ **algoritmická formulace** – tj. metoda musí najít řešení pomocí konečného počtu dílčích kroků;
- ✓ **konvergence** – výpočet by měl být monotónní a pokud možno co nejrychlejší.

PERCEPTRON

UČENÍ

na vstup perceptronu jsou vkládány prvky trénovací množiny a výsledek klasifikace je srovnán s očekávanou správnou klasifikací;

- ☑ pokud je rozdíl mezi klasifikátorem určenou a správnou klasifikací větší než určitá předem daná mez definující přípustnou chybu, pak se parametry klasifikátoru (váhové koeficienty) změní tak, aby se chyba mezi určenou a požadovanou klasifikací minimalizovala;
- ☑ pokud je chyba klasifikace větší než předem stanovená mez, pak učení dále pokračuje, v opačném případě se učení ukončí a klasifikátor je možné použít ke klasifikaci. Kromě zmíněného absolutního kritéria ukončení učicí se fáze se v současné době často používá pro zastavení učení i relativní kritérium založené poklesu chyby během daného časového okna.


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. $\sum_i w_i^2 = 1$
- ☑ s použitím Langrangova součinitele (multiplikátoru) 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 (♥)

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

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 (\Rightarrow) 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

- ☑ rozptyl transformovaných dat ze třídy ω_1 je dána

$$s_r^2 = \sum_{i \in \omega_1} (y_i - m_i)^2$$

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

- ☑ celkový rozptyl 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 je kovarianční matice 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

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

**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 $\mathbf{m}_2 - \mathbf{m}_1$

ALGORITMUS PODPŮRNÝCH VEKTORŮ

Algoritmus podpůrných vektorů (Support Vector Machine - SVM) je metoda strojového učení. SVM hledá nadrovinu, která v prostoru příznaků optimálně rozděluje trénovací data.

Optimální nadrovina je taková, že body leží v opačných poloprostorech a hodnota minima vzdáleností bodů od roviny je co největší. Jinými slovy, okolo nadroviny je na obě strany co nejširší pruh bez bodů.

Na popis nadroviny stačí pouze nejbližší body, kterých je obvykle málo - tyto body se nazývají *podpůrné vektory* (angl. support vectors) a odtud název metody. Tato metoda je ze své přirozenosti binární, tedy rozděluje data do dvou množin. Rozdělující nadrovina je lineární funkcí v prostoru příznaků.

ALGORITMUS PODPŮRNÝCH VEKTORŮ (SUPPORT VECTOR MACHINE – SVM)


SEPARABILNÍ TŘÍDY

mějme v učební množině obrazy \mathbf{x}_i , $i=1,2,\dots,n$, ze dvou lineárně separabilních klasifikačních tříd ω_1 a ω_2

cílem je určení parametrů definující hranici

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


jejíž pomocí klasifikátor správně zařadí všechny obrazy z učební množiny




ALGORITMUS PODPŮRNÝCH VEKTORŮ

- ☑ Důležitou součástí techniky **SUPPORT VECTOR MACHINES** je jádrová transformace (angl. *kernel transformation*) prostoru příznaků dat do prostoru transformovaných příznaků typicky vyšší dimenze. Tato jádrová transformace umožňuje převést původně lineárně neseparovatelnou úlohu na úlohu lineárně separovatelnou, na kterou lze dále aplikovat optimalizační algoritmus pro nalezení rozdělující nadroviny.
- ☑ Používají se různé jádrové transformace. Intuitivně, vyjadřují podobnost dat, tj. svých dvou vstupních argumentů.
- ☑ Výhodou této metody (a jiných metod založených na jádrové transformaci) je, že transformace se dá definovat pro různé typy objektů, nejen body v R^n . Např. pro grafy, stromy, posloupnosti DNA ...


ALGORITMUS PODPŮRNÝCH VEKTORŮ



ALGORITMUS PODPŮRNÝCH VEKTORŮ



dvourozměrný prostor s
oddělovací hranicí ve tvaru
 $x_1^2 + x_2^2 \leq 1$



tatáž situace zobrazená do
trojrozměrného prostoru
(x_1^2 , x_2^2 , $\sqrt{2}x_1x_2$) – **kruhová
hranice se stane lineární**


ALGORITMUS PODPŮRNÝCH VEKTORŮ

SEPARABILNÍ TŘÍDY

☑ připomenutí:


vzdálenost jakéhokoliv bodu od klasifikační hranice je

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



ALGORITMUS PODPŮRNÝCH VEKTORŮ SEPARABILNÍ TŘÍDY

- ☑ určíme hodnoty váhového vektoru \mathbf{w} a w_0 tak, aby hodnota $y(\mathbf{x})$ v nejbližším bodě třídy ω_1 byla rovna 1 a pro ω_2 rovna -1



ALGORITMUS PODPŮRNÝCH VEKTORŮ

SEPARABILNÍ TŘÍDY

- ☑ máme „ochranné“ klasifikační pásmo o šířce

$$\frac{1}{\|\mathbf{w}\|} + \frac{1}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|}$$

a chceme $\mathbf{w}^T \mathbf{x} + w_0 \geq 1$ pro $\forall \mathbf{x} \in \omega_1$

$$\mathbf{w}^T \mathbf{x} + w_0 \geq -1 \quad \text{pro } \forall \mathbf{x} \in \omega_2$$

nebo také - chceme najít minimální

$$J(\mathbf{w}, w_0) = \frac{1}{2} \|\mathbf{w}\|^2$$

za předpokladu, že

$$t_i(\mathbf{w}^T \mathbf{x} + w_0) \geq 1, \quad i = 1, 2, \dots, n$$

kde $t_i = +1$ pro ω_1 a $t_i = -1$ pro ω_2

(minimalizace normy maximalizuje klasifikační pásmo)

ALGORITMUS PODPŮRNÝCH VEKTORŮ

SEPARABILNÍ TŘÍDY

- ☑ nelineární kvadratická optimalizační úloha se soustavou podmínek formulovaných pomocí lineárních nerovností
- ☑ Karushovy-Kuhnovy-Tuckerovy podmínky praví, že pro to musí být splněno

$$\frac{\partial}{\partial \mathbf{w}} L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = \mathbf{0}$$

$$\frac{\partial}{\partial w_0} L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = 0$$

$$\lambda_i \geq 0, i = 1, 2, \dots, n$$

$$\lambda_i [t_i(\mathbf{w}^T \mathbf{x}_i + w_0) - 1] = 0, i = 1, 2, \dots, n,$$

kde $\boldsymbol{\lambda}$ je vektor Langrangových součinitelů a $L(\mathbf{w}, w_0, \boldsymbol{\lambda})$ je Lagrangova funkce definována vztahem

$$L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^n \lambda_i [t_i(\mathbf{w}^T \mathbf{x}_i + w_0) - 1]$$

ALGORITMUS PODPŮRNÝCH VEKTORŮ

SEPARABILNÍ TŘÍDY

- ☑ když se všechny vztahy z předcházející strany dají dohromady dostaneme

$$\mathbf{w} = \sum_{i=1}^n \lambda_i \mathbf{t}_i \mathbf{x}_i$$

podpůrné vektory

$$\sum_{i=1}^n \lambda_i \mathbf{t}_i = 0$$

ALGORITMUS PODPŮRNÝCH VEKTORŮ


NESEPARABILNÍ TŘÍDY

- ☑ stále ale platí, že klasifikační „ochranné“ pásmo je definováno dvěma paralelními „nadrovinami“ definovanými

$$\mathbf{w}^T \mathbf{x} + w_0 = \pm 1$$

- ☑ obrazy z trénovací množiny patří do následujících tří kategorií:

- obraz leží **vně** pásma a je **správně** klasifikován [platí podmínka $t_i(\mathbf{w}^T \mathbf{x} + w_0) \geq 1$ $i=1,2,\dots,n$];
- obraz leží **uvnitř** pásma a je **správně** klasifikován (čtverečky) [platí pro ně $0 \leq t_i(\mathbf{w}^T \mathbf{x} + w_0) < 1$];
- obraz je chybně klasifikován (kolečka) [platí pro něj $t_i(\mathbf{w}^T \mathbf{x} + w_0) < 0$]



ALGORITMUS PODPŮRNÝCH VEKTORŮ

NESEPARABILNÍ TŘÍDY

- ☑ všechny tři kategorie obrazů mohou být řešeny na základě pro daný typ specifických podmínek

$$t_i(\mathbf{w}^T \mathbf{x} + w_0) \geq 1 - \xi_i$$

pomocí nově zavedených proměnných ξ_i (tzv. volné proměnné - *slack variables*).

První kategorie je pro $\xi_i = 0$, druhá $0 < \xi_i \leq 1$ a třetí pro $\xi_i > 1$.

Cílem návrhu v tomto případě je vytvořit co nejširší „ochranné“ pásmo, ale současně minimalizovat počet obrazů s $\xi_i > 0$, což vyjadřuje kritérium se ztrátovou funkcí

$$J(\mathbf{w}, w_0, \boldsymbol{\xi}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n I(\xi_i)$$

kde $\boldsymbol{\xi}$ je vektor parametrů ξ_i a

$$I(\xi_i) = \begin{cases} 1 & \xi_i > 0 \\ 0 & \xi_i = 0 \end{cases}$$

C je kladná korekční konstanta, která váhuje vliv obou členů v uvedeném vztahu.

ALGORITMUS PODPŮRNÝCH VEKTORŮ

NESEPARABILNÍ TŘÍDY

- optimalizace je obtížná, protože ztrátová funkce je nespojitá (díky funkci $I(\bullet)$). V takových případech se proto používá náhradní ztrátová funkce

$$J(\mathbf{w}, w_0, \boldsymbol{\xi}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i$$

- a cílem návrhu je minimalizovat $J(\mathbf{w}, w_0, \boldsymbol{\xi})$ za podmínek, že

$$t_i(\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1 - \xi_i \text{ a } \xi_i \geq 0, i=1, 2, \dots, n.$$

- Problém lze opět řešit pomocí Langrangeovy funkce

$$L(\mathbf{w}, w_0, \boldsymbol{\xi}, \boldsymbol{\lambda}, \boldsymbol{\mu}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \mu_i \xi_i - \sum_{i=1}^n \lambda_i [t_i(\mathbf{w}^T \mathbf{x}_i + w_0) - 1 + \xi_i]$$

ALGORITMUS PODPŮRNÝCH VEKTORŮ NESEPARABILNÍ TŘÍDY

- ☑ příslušné Karushovy-Kuhnovy-Tuckerovy podmínky jsou

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{0} \text{ nebo } \mathbf{w} = \sum_{i=1}^n \lambda_i t_i \mathbf{x}_i;$$

$$\frac{\partial L}{\partial w_0} = 0 \text{ nebo } \sum_{i=1}^n \lambda_i t_i \mathbf{x}_i;$$

$$\frac{\partial L}{\partial \xi_i} = 0 \text{ nebo } C - \mu_i - \lambda_i = 0, i = 1, 2, \dots, n;$$

$$\lambda_i [t_i (\mathbf{w}^T \mathbf{x} + w_0) - 1 + \xi_i] = 0, i = 1, 2, \dots, n;$$

$$\mu_i \xi_i = 0, i = 1, 2, \dots, n;$$

$$\mu_i \geq 0, \lambda_i \geq 0, i = 1, 2, \dots, n;$$

ALGORITMUS PODPŮRNÝCH VEKTORŮ

NESEPARABILNÍ TŘÍDY

- ☑ z čehož platí požadavek na maximalizaci $L(\mathbf{w}, w_0, \boldsymbol{\lambda}, \boldsymbol{\xi}, \boldsymbol{\mu})$ za podmínek

$$\mathbf{w} = \sum_{i=1}^n \lambda_i \mathbf{t}_i \mathbf{x}_i;$$

$$\sum_{i=1}^n \lambda_i \mathbf{t}_i = 0;$$

$$C - \mu_i - \lambda_i = 0,$$

$$\mu_i \geq 0, \lambda_i \geq 0, i = 1, 2, \dots, n;$$

SOUVISLOSTI MEZI PRINCIPY KLASIFIKACE

KLASIFIKACE PODLE MINIMÁLNÍ VZDÁLENOSTI

- ☑ reprezentativní obrazy klasifikačních tříd - etalony
- ☑ je-li v obrazovém prostoru zadáno R poloh etalonů vektory $\mathbf{x}_{1E}, \mathbf{x}_{2E}, \dots, \mathbf{x}_{RE}$, zařadí klasifikátor podle minimální vzdálenosti klasifikovaný obraz \mathbf{x} do té třídy, jejíž etalon má od bodu \mathbf{x} minimální vzdálenost. Rozhodovací pravidlo je určeno vztahem

$$d(\mathbf{x}) = \|\mathbf{x}_{rE} - \mathbf{x}\| = \min_{\forall s} \|\mathbf{x}_{sE} - \mathbf{x}\|$$

SOUVISLOSTI MEZI PRINCIPY KLASIFIKACE


- ☑ uvažme případ dvou tříd reprezentovaných etalony $\mathbf{x}_{1E} = (x_{11E}, x_{12E})$ a $\mathbf{x}_{2E} = (x_{21E}, x_{22E})$ ve dvoupríznakovém euklidovském prostoru;
- ☑ vzdálenost mezi obrazem $\mathbf{x} = (x_1, x_2)$ a libovolným z obou etalonů je pak definována

$$v(\mathbf{x}_{sE}, \mathbf{x}) = \|\mathbf{x}_{sE} - \mathbf{x}\| = \sqrt{(x_{s1E} - x_1)^2 + (x_{s2E} - x_2)^2}$$

- ☑ hledáme menší z obou vzdáleností, tj. $\min_{s=1,2} v(\mathbf{x}_{sE}, \mathbf{x})$, ale také $\min_{s=1,2} v^2(\mathbf{x}_{sE}, \mathbf{x})$;

$$\begin{aligned} \min_{\forall s} v(\mathbf{x}_{sE}, \mathbf{x}) &\approx \min_{\forall s} v^2(\mathbf{x}_{sE}, \mathbf{x}) = \min_{\forall s} \left((x_{s1E} - x_1)^2 + (x_{s2E} - x_2)^2 \right) = \\ &\min_{\forall s} \left(x_1^2 + x_2^2 - 2[x_{s1E}x_1 + x_{s2E}x_2 - (x_{s1E}^2 + x_{s2E}^2)/2] \right) \end{aligned}$$

SOUVISLOSTI MEZI PRINCIPY KLASIFIKACE



SOUVISLOSTI MEZI PRINCIPY KLASIFIKACE

- ☑ diskriminační kuželové plochy se protínají v parabole a její průmět do obrazové roviny je přímka definovaná vztahem

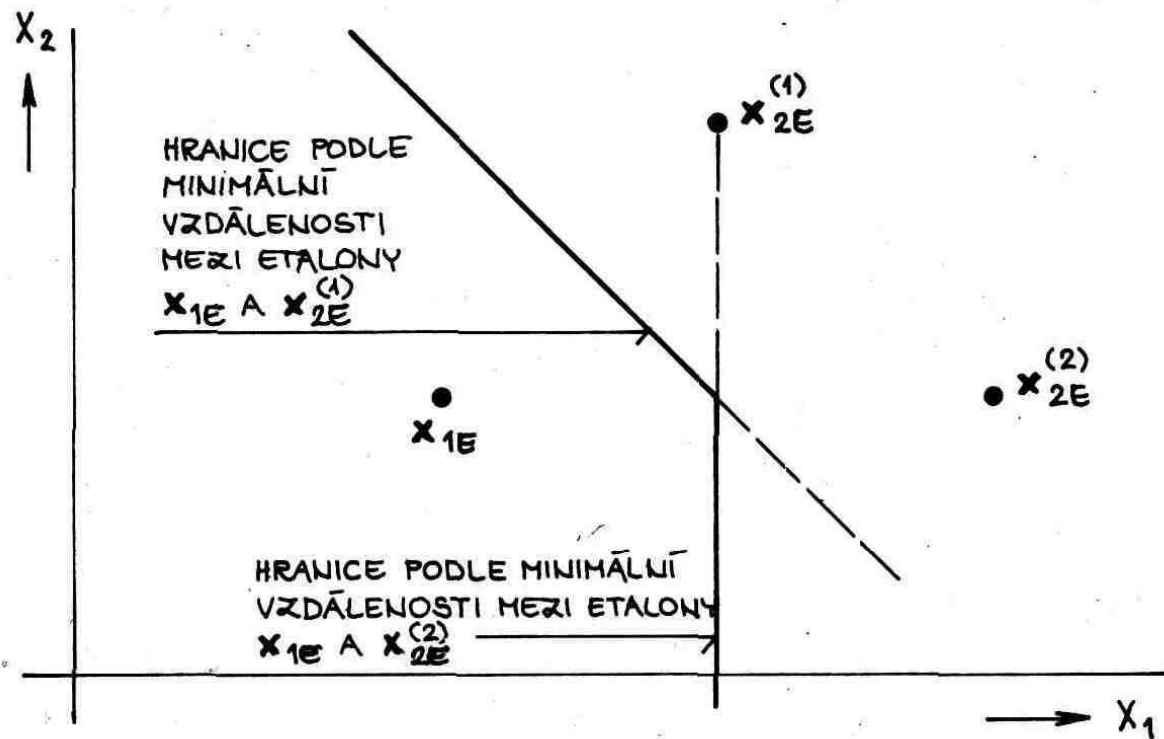
$$x_1(x_{11E} - x_{21E}) + x_2(x_{12E} - x_{22E}) - (x_{12E}^2 + x_{11E}^2 - x_{21E}^2 - x_{22E}^2)/2 = 0$$

Tato hraniční přímka mezi klasifikačními třídami je vždy kolmá na spojnici obou etalonů a tuto spojnici půlí



klasifikátor pracující na základě kritéria minimální vzdálenosti je „ekvivalentní“ lineárnímu klasifikátoru s diskriminačními funkcemi.

SOUVISLOSTI MEZI PRINCIPY KLASIFIKACE



- ☑ Klasifikace podle minimální vzdálenosti s třídami reprezentovanými více etalony je „ekvivalentní“ klasifikaci podle diskriminační funkce s po částech lineární hraniční plochou

SOUVISLOSTI MEZI PRINCIPY KLASIFIKACE

SHRNUTÍ

- ✓ Hranice mezi klasifikačními třídami jsou dány průmětem diskriminačních funkcí do obrazového prostoru.
- ✓ Klasifikace podle minimální vzdálenosti definuje hranici, která je kolmá na spojnici etalonů klasifikačních tříd a pólí ji.
- ✓ Princip klasifikace dle minimální vzdálenosti vede buď přímo, nebo prostřednictvím využití metrik podobnosti k definici diskriminačních funkcí a ty dle prvního ze zde uvedených pravidel k určení hranic mezi klasifikačními třídami.

Příprava nových učebních materiálů
oboru Matematická biologie

je podporována projektem ESF

č. CZ.1.07/2.2.00/28.0043

„INTERDISCIPLINÁRNÍ ROZVOJ STUDIJNÍHO OBORU MATEMATICKÁ BIOLOGIE“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ