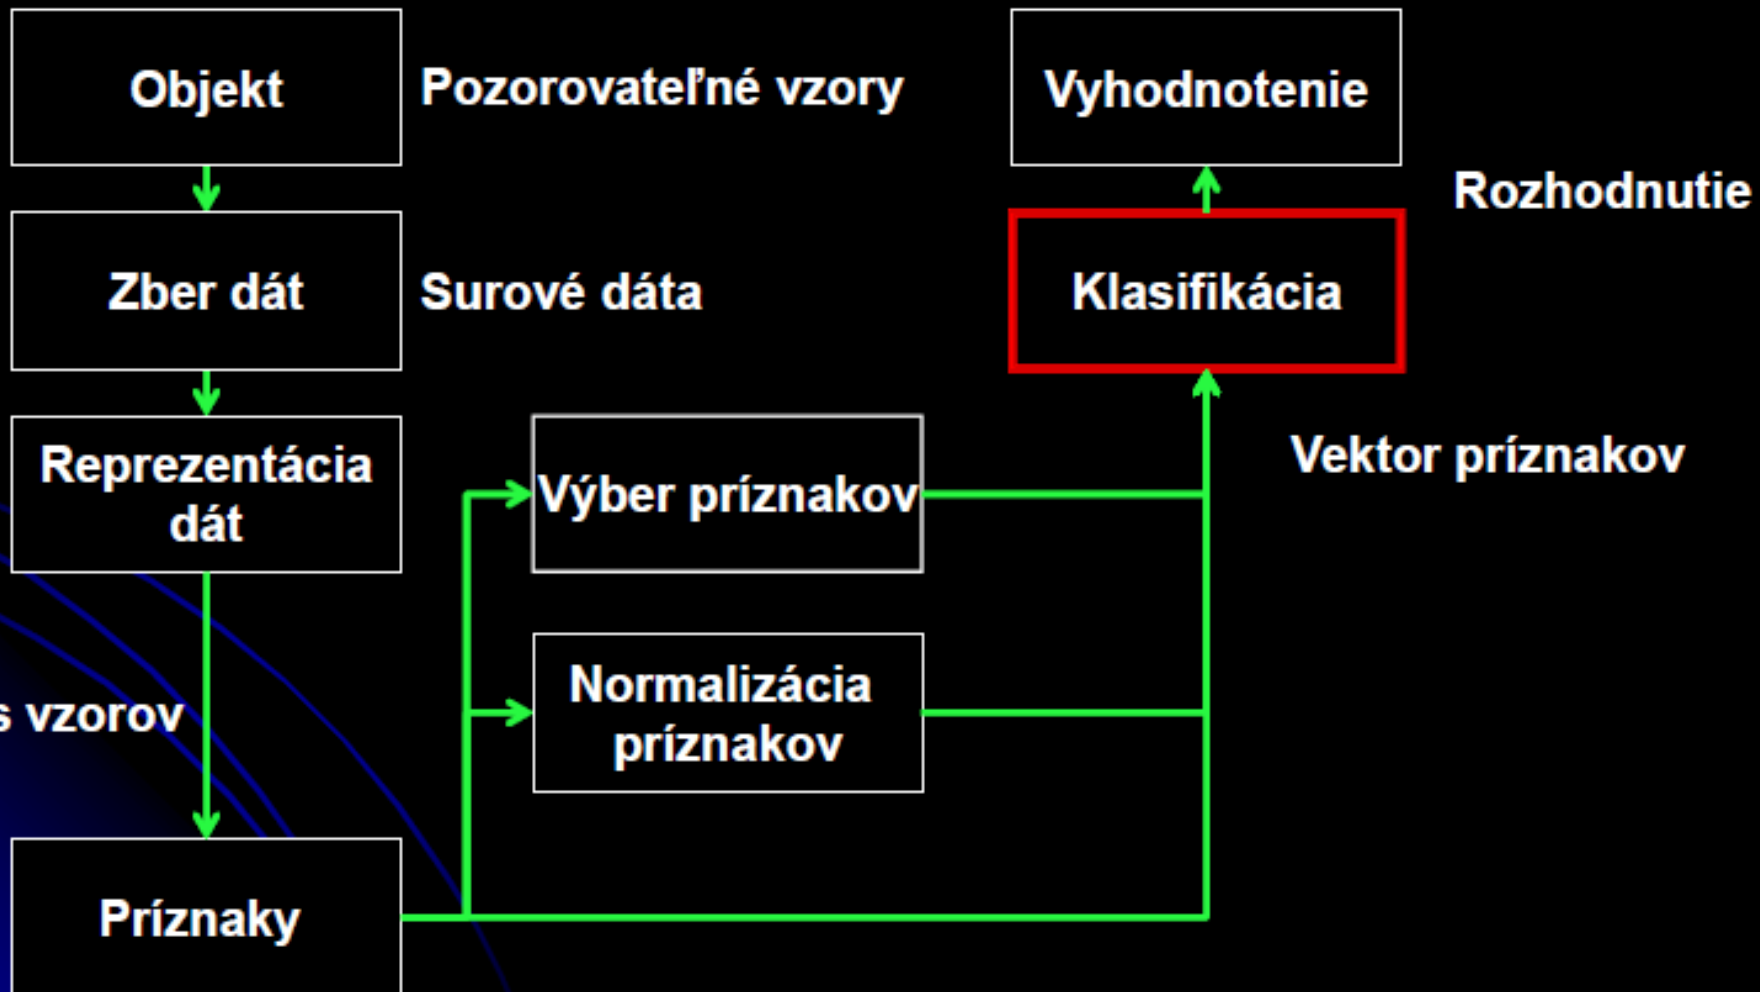


Rozpoznávanie obrazcov šk.r. 2019-20

Lineárny klasifikátor a SVM

Doc. RNDr. Milan Ftáčnik, CSc.

Rozpoznávanie



Klasifikácia

- Rozpoznávanie obrazcov skúma metódy, ako rozhodnúť o priradení neznámeho objektu do triedy objektov – ten proces sa volá klasifikácia a zariadenie, ktoré ho robí sa volá klasifikátor
- Príznakové metódy – rozhodnutie sa robí na základe obrazca (príznakového vektora) popisujúceho objekt (najčastejšie v obraze)
- Iné metódy – priamo z obrazu objektu

Klasifikácia II

- **Príznakové metódy**
 - Diskriminačná analýza
 - Štatistické metódy
 - Vzdialenosti medzi príznakmi
 - Pravidlá (aj nemetrické príznaky)
 - Biologicky inšpirované metódy
- **Iné metódy** – konvolučné neurónové siete

Klasifikácia III

- Klasifikátor nastavujeme (trénujeme) pomocou trénovacej množiny – nastavujú sa vnútorné parametre klasifikátora
- Tento proces sa nazýva učenie a jeho cieľom je čo najmenšia chyba na trénovacej množine
- Klasifikátor môže mať aj hyperparametre, ktoré nastavuje pred učením používateľ a tie sa testujú na validačnej množine

Klasifikácia IV

- Validačná množina je časť trénovacej množiny, obyčajne v pomere trénovacia:validačná 80:20
- Kvalita klasifikátora sa testuje na testovacej množine, v ktorej sú obrazce, ktoré klasifikátor nemal k dispozícii
- Chyba dosiahnutá na testovacej množine, sa nazýva generalizačná chyba a cieľom je, aby bola čo najmenšia

Riadené a neriadené metódy


- **Riadené metódy** (učenie s učiteľom) – majú informáciu o tom, do ktorej triedy patrí každý príznakový vektor z trénovacej množiny
- Jedna premenná, ktorá sa nazýva cieľová (klasifikačná trieda), riadi proces učenia tak, aby ostatné premenné (prediktory) čo najlepšie predpovedali (na trénovacej množine známu) hodnotu cieľovej premennej

Riadené a neriadené metódy II

- **Neriadené metódy** (učenie bez učiteľa) – informáciu o zaradení do tried nemajú
- Snažia sa:
 - zhlukovať dáta do skupín podobných vzoriek
 - určiť odhad hustoty pravdepodobnosti dát
 - naučiť sa vytvárať vzorky z rozdelenia
 - nájsť krivku, ku ktorej sú dáta blízko

Riadené metódy klasifikácie

- V trénovacej množine máme N pozorovaní $(\mathbf{x}_1, \dots, \mathbf{x}_N)$, $\mathbf{x}_i \in \mathbb{R}^D$ a vektor označenia tried $\mathbf{y} = [y_1 y_2 \dots y_N]$, $y_i \in \{-1, 1\}$
- **Klasifikačný problém:**
Určiť $f(\mathbf{x})$ tak, aby $f(\mathbf{x}_i) = y_i$
- Niekedy sa $f(\mathbf{x})$ označuje ako rozhodovacia funkcia



Diskriminačná analýza

- Predpokladáme, že klasifikačné triedy sú **lineárne separovateľné**
- To znamená, že pre každé dve triedy existuje nadrovina rozdeľujúca príznakový priestor tak, že príznakové vektory (z trénovacej množiny) z rôznych tried ležia v rôznych polpriestoroch
- Nadrovina je $D - 1$ rozmerný podpriestor, ktorý delí príznakový priestor na dve časti

Diskriminačná analýza II

- Nájdeme lineárne diskriminačné funkcie, $g_1(\mathbf{x}), \dots, g_R(\mathbf{x})$, ktorých bude toľko čo tried
- Lineárna diskriminačná funkcia má tvar:
$$g_r(\mathbf{x}) = q_{r0} + q_{r1}x_1 + \dots + q_{rn}x_n$$
kde q_{ri} sú skalárne koeficienty
- Neznámy vektor \mathbf{x} zaradíme do tej triedy, ktorej diskriminačná funkcia vrátila najväčšiu hodnotu

Diskriminačná analýza III

- Z toho vyplýva rozhodovacie pravidlo

$$f(\mathbf{x}) = \omega_r \leftrightarrow g_r(\mathbf{x}) = \max_{s=1,2,\dots,R} g_s(\mathbf{x})$$

- Potom je nadrovina medzi dvoma triedami ω_r a ω_s určená vzťahom

$$g_r(\mathbf{x}) - g_s(\mathbf{x}) = 0$$

- Pre dve triedy nám stačí jedna diskriminačná funkcia; ak bude kladná, zaradíme vektor do ω_1 a ak bude záporná, tak do ω_2

Klasifikácia do dvoch tried

- Definujme funkciu $f(\mathbf{x}) = g_1(\mathbf{x}) - g_2(\mathbf{x})$
- Ak označíme rozdiel skalárov pri jednotlivých príznakoch x_i ako vektor \mathbf{w} a skalár q_0 ako b , tak môžeme napísať vektorovo

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$$

- Potom rovnica nadroviny je $\mathbf{w}^T \mathbf{x} + b = 0$ kde \mathbf{w} predstavuje váhový vektor a platí


$$f(\mathbf{x}) > 0 \text{ ak } \mathbf{x} \in \omega_1$$

$$f(\mathbf{x}) < 0 \text{ ak } \mathbf{x} \in \omega_2$$

Klasifikácia do dvoch tried II

- Ak budeme uvažovať vektory \mathbf{x}_1 a \mathbf{x}_2 , ktoré ležia na oddeľujúcej nadrovine H , tak platí $\mathbf{w}^T \mathbf{x}_1 + b = \mathbf{w}^T \mathbf{x}_2 + b$ alebo $\mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2) = 0$
- Z toho vyplýva, že \mathbf{w} je normála ku každému vektoru, ktorý leží v H
- Pretože $f(\mathbf{x}) > 0$ pre všetky vektory z triedy ω_1 , tak normálový vektor \mathbf{w} ukazuje do polpriestoru zodpovedajúcemu ω_1 , a tiež hovoríme, že je na pozitívnej strane H

Klasifikácia do dvoch tried III



Klasifikácia do dvoch tried IV

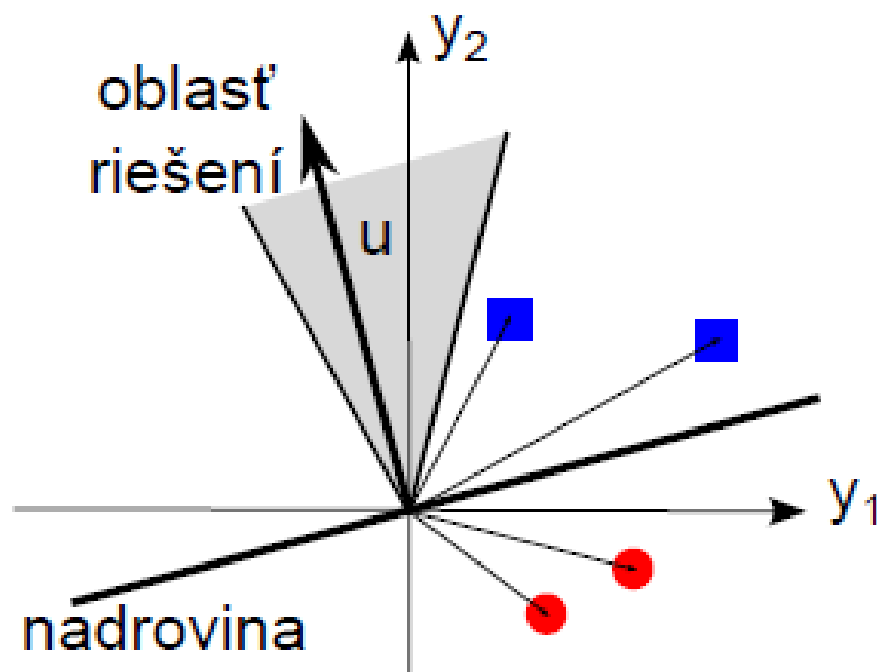
- Diskriminačná funkcia $f(\mathbf{x})$ je algebraickou mierou vzdialenosti \mathbf{x} od H
- Vidíme to, ak si označíme priemet \mathbf{x} na H ako \mathbf{x}_p , potom môžeme napísať $\mathbf{x} = \mathbf{x}_p + r \frac{\mathbf{w}}{\|\mathbf{w}\|}$
- Pretože platí $f(\mathbf{x}_p) = \mathbf{w}^T \mathbf{x}_p + b = 0$, z toho úpravou a s využitím vzťahu $\mathbf{w}^T \mathbf{w} = \|\mathbf{w}\|^2$ dostaneme
$$r = \frac{f(\mathbf{x})}{\|\mathbf{w}\|}$$

Klasifikácia do dvoch tried V

- Ako dôsledok z toho vyplýva, že vzdialenosť od počiatku k H je $\frac{b}{\|\mathbf{w}\|}$
- Ak je $b > 0$, tak počiatok leží na pozitívnej strane H , ak je $b < 0$, tak na negatívnej
- Ak je $b = 0$, tak oddeľujúca nadrovina H prechádza cez počiatok
- Orientácia nadroviny H je teda daná normálnym vektorom \mathbf{w} a jej poloha členom b

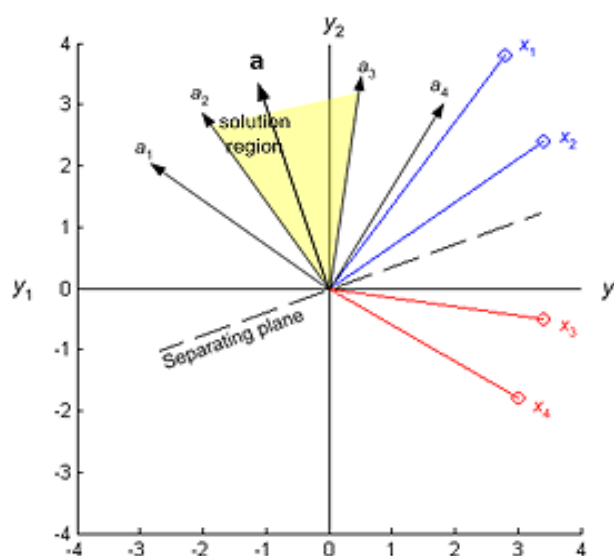



Zovšeobecnený lineárny klasifikátor

- Jeho funkcia je $f(\mathbf{x}) = \mathbf{u}^T \mathbf{y}$
kde $\mathbf{u} = [b, \mathbf{w}^T]^T$ a $\mathbf{y} = [1, \mathbf{x}^T]^T$
- Vzorku \mathbf{y}_i zaradíme
 - do triedy ω_1 ak platí $\mathbf{u}^T \mathbf{y}_i > 0$
 - do triedy ω_2 ak platí $\mathbf{u}^T \mathbf{y}_i < 0$



Zovšeobecnený lineárny klasifikátor II


- Oblasť riešení sú možné polohy vektora \mathbf{u} (na obrázku označeného ako \mathbf{a})



Zovšeobecnený lineárny klasifikátor III

- Označíme

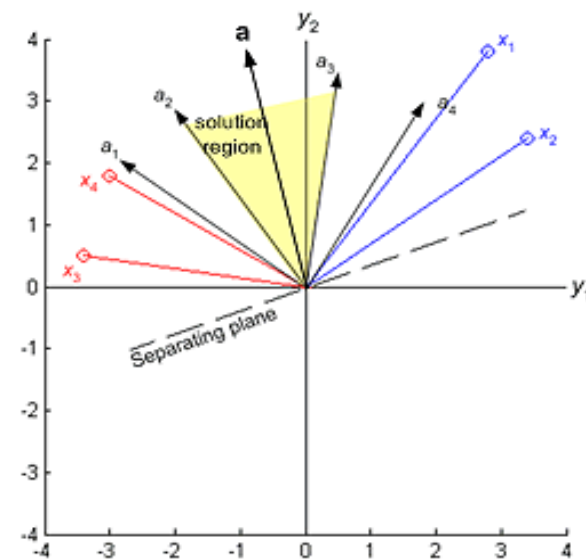



$$\mathbf{z}_i = \begin{cases} \mathbf{y}_i & \text{pre } \mathbf{y} \in \omega_1, \\ -\mathbf{y}_i & \text{pre } \mathbf{y} \in \omega_2, \end{cases}$$



- Našou úlohou je nájsť vektor \mathbf{u} , aby platil pre všetky \mathbf{z}_i vzťah $\mathbf{u}^T \mathbf{z}_i > 0$

Zovšeobecnený lineárny klasifikátor IV

- Oblasť riešení sú možné polohy vektora \mathbf{u} (na obrázku označeného ako \mathbf{a})



Gradientná metóda

- Namiesto riešenia lineárnych nerovníc zvolíme skalárnu účelovú funkciu $O(\mathbf{u})$, ktorej hodnota je minimálna, keď \mathbf{u} je riešením
- Začneme náhodne zvoleným vektorom u_1
- Vypočítame gradient ∇O v bode u_1
- Aktualizujeme hodnotu u tak, že vyberieme vektor z okolia \mathbf{u}_1 v smere najväčšej negatívnej zmeny gradientu $\mathbf{u}_{i+1} = \mathbf{u}_i - \eta(i) \nabla O|_{\mathbf{u}_i}$, kde $\eta(i)$ je (pozitívna) rýchlosť učenia v kroku i

Gradientná metóda II

- Úspešnosť tejto metódy závisí od voľby $\eta(i)$
- Využijeme Taylorov rozvoj a to, že účelová funkcia je diferencovateľná
- $O(\mathbf{a})$ je v okolí bodu \mathbf{u}_i aproximovaná

$$O(\mathbf{a}) \approx O(\mathbf{u}_i) + \nabla O^T (\mathbf{a} - \mathbf{u}_i) + \frac{1}{2} (\mathbf{a} - \mathbf{u}_i)^T \mathbf{H} (\mathbf{a} - \mathbf{u}_i)$$

kde \mathbf{H} je matica druhých parciálnych derivácií funkcie O (Hesseho matica)

Gradientná metóda III

- Ak za \mathbf{a} dosadíme \mathbf{u}_{i+1} , tak dostaneme

$$O(\mathbf{u}_{i+1}) \approx O(\mathbf{u}_i) - \eta(i) \|\nabla O\|^2 + \frac{1}{2} \eta^2(i) \nabla O^T \mathbf{H} \nabla O$$

- Dá sa ukázať, že minimum nadobúda táto funkcia pre

$$\eta(i) = \frac{\|\nabla O\|^2}{\nabla O^T \mathbf{H} \nabla O}$$

- Často je rýchlejšie určiť $\eta(i)$ ako konštantu η menšiu ako je potrebné a urobiť o niečo viac krokov ako v každom počítať optimálne $\eta(i)$

Newtonova metóda

- Je založená na funkcii $\mathbf{u}_{i+1} = \mathbf{u}_i - \mathbf{H}^{-1} \nabla O$ a hľadá riešenie až kým $\mathbf{H}^{-1} \nabla O < \Theta$, kde Θ je prahová hodnota veľkosti chyby
- Newtonov algoritmus dáva väčšinou v jednom kroku lepšie zlepšenie ako gradientná metóda, dokonca aj s optimálnou hodnotou $\eta(i)$
- Ale Newtonov algoritmus sa nedá použiť, ak je Hessianá matica \mathbf{H} singulárna

Perceptrónová kritériálna funkcia

- Využíva iba nesprávne klasifikované vzorky
- Účelová funkcia je po častiach lineárna
perceptrónová funkcia

$$O_P = \sum_{\mathbf{z} \in \mathcal{Z}} (-\mathbf{u}^T \mathbf{z})$$

kde \mathcal{Z} je množina nesprávne klasifikovaných

vzoriek. Potom $\nabla O_P = \sum_{\mathbf{z} \in \mathcal{Z}} (-\mathbf{z})$ a

$$\mathbf{u}_{i+1} = \mathbf{u}_i + \eta(i) \sum_{\mathbf{z} \in \mathcal{Z}_i} \mathbf{z}$$

Perceptrónová funkcia II

- V prípade, že ak je množina O_P prázdna, tak definujeme $O_P \equiv 0$
- Vieme, že pre nesprávne klasifikované vzorky platí $\mathbf{u}^T \mathbf{z} \leq 0$, a preto O_P nadobúda nezáporné hodnoty
- Nulovú hodnotu nadobúda pre váhové vektory, ktoré sú riešením nášho problému, keď nemáme nesprávne klasifikované vzorky

Perceptrónová funkcia III

- Tento prístup sa volá dávkový, pretože vyhodnocuje všetky zle klasifikované vzorky naraz
- Postup pri vyhodnocovaní vzoriek po jednej

inicializuj $\mathbf{u}_0 = \mathbf{1}$, $i=0$, $k=0$

opakuj

ak \mathbf{z}_k je nesprávne klasifikovaný

$$\mathbf{u}_{i+1} = \mathbf{u}_i + \mathbf{z}_k$$

$$i=i+1$$

koniec ak

$$k=(k+1) \bmod N$$

kým existuje nejaký nesprávne klasifikovaný vektor \mathbf{z}_j

Ukážka postupu algoritmu

$$u = (1, 1, 1)$$

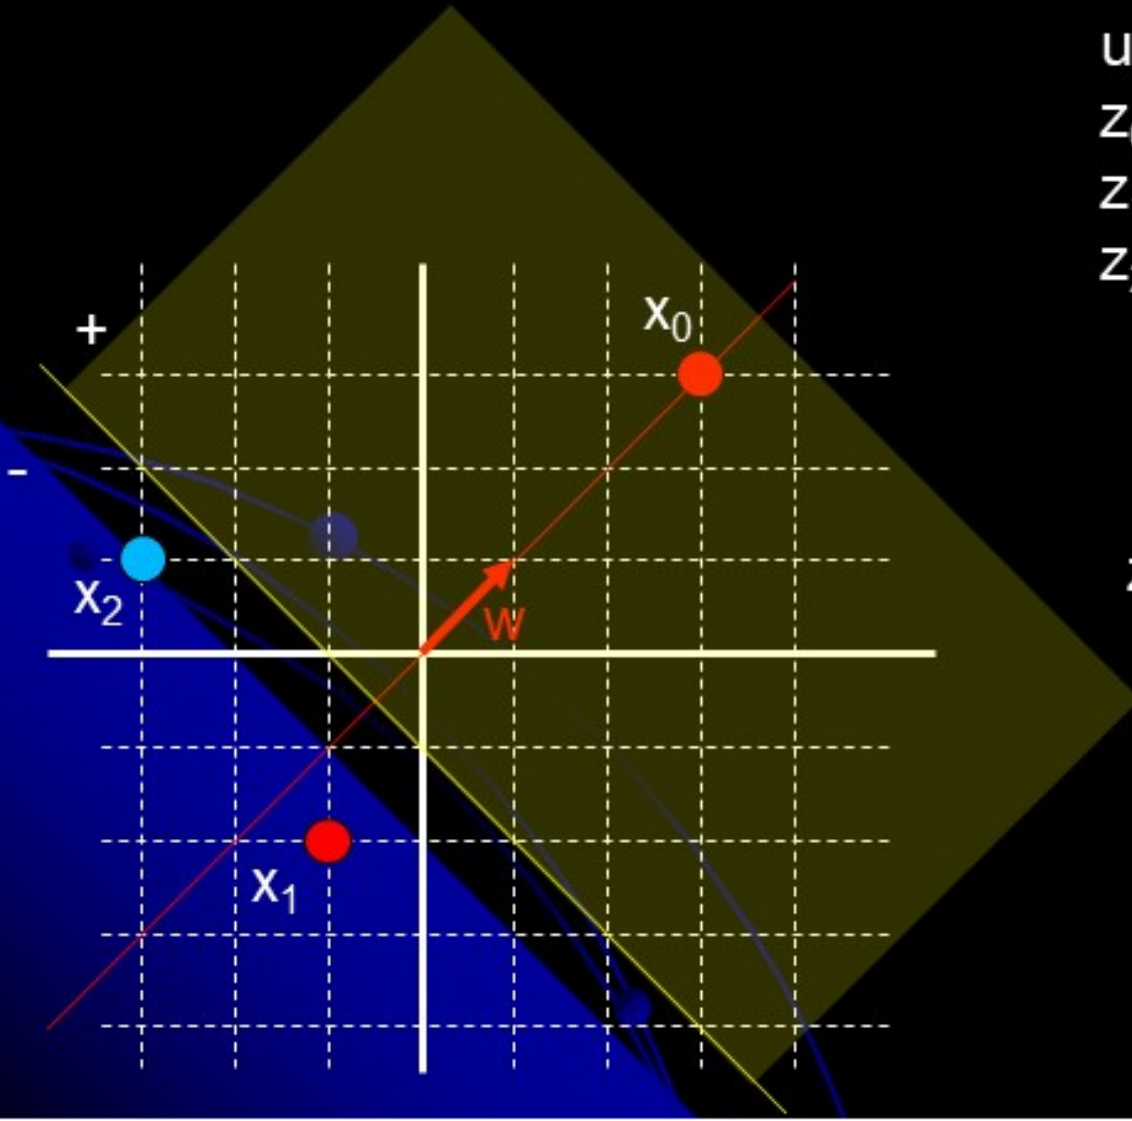
$$z_0 = (1, 3, 3)$$

$$z_1 = (1, -1, -2)$$

$$z_2 = -(1, -3, 1)$$

z_1 zle klasifikovaný

$$u = u + z_1 = (1, 1, 1) + (1, -1, -2) \\ (2, 0, -1)$$



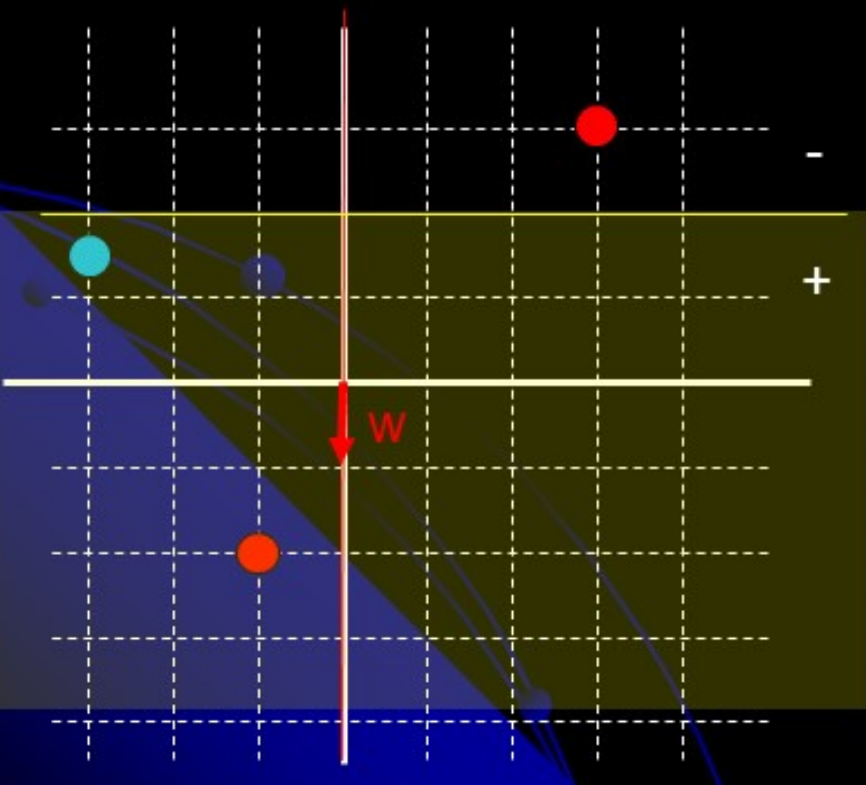
Ukážka postupu algoritmu II

$$u = (2, 0, -1)$$

$$z_0 = (1, 3, 3)$$

$$z_1 = (1, -1, -2)$$

$$z_2 = -(1, -3, 1)$$



z_2 zle klasifikovaný

$$u = u + z_2 = (2, 0, -1) - (1, -3, 1) = (3, 3, -2)$$

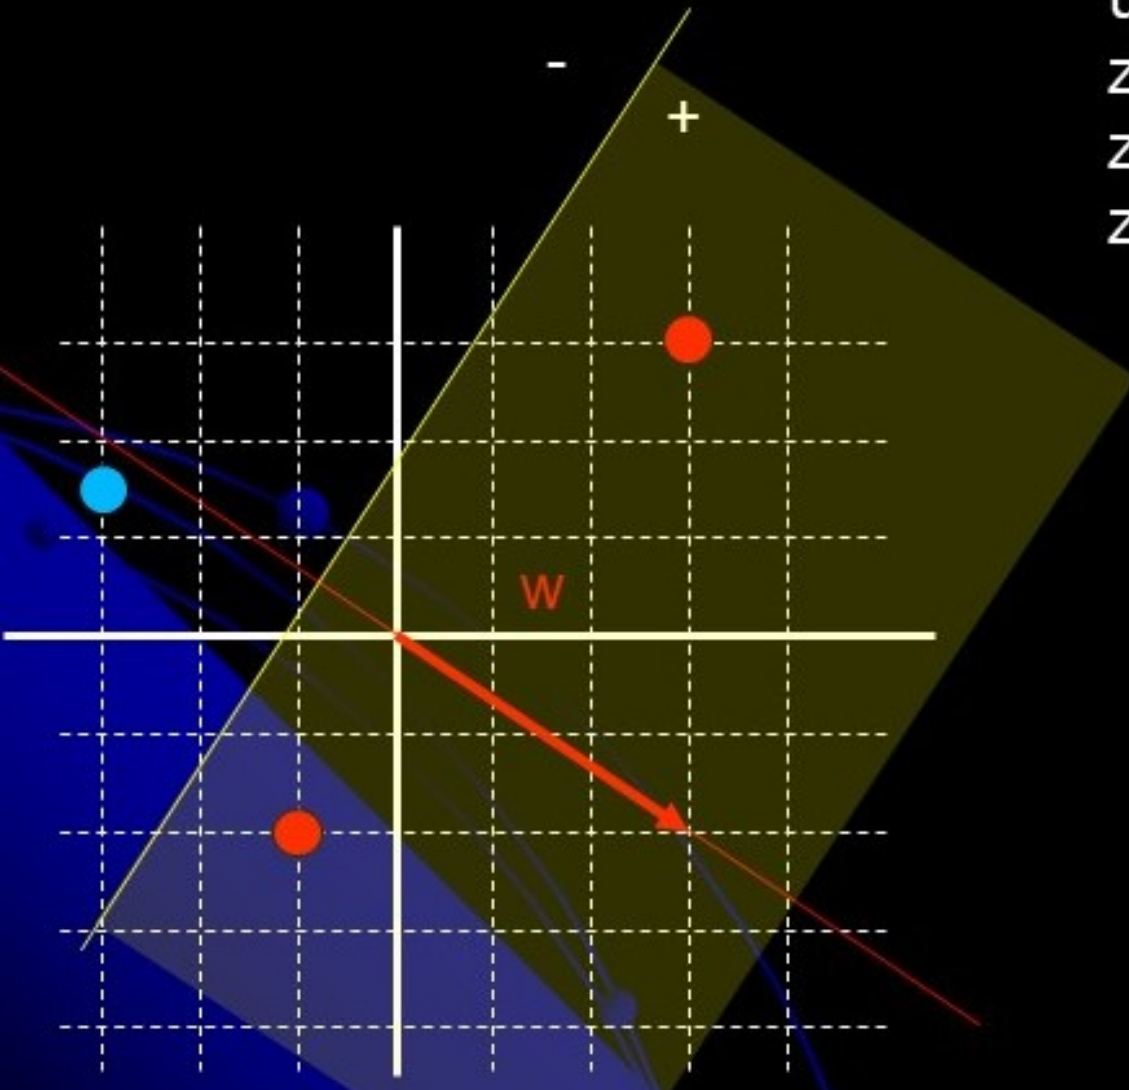
Ukážka postupu algoritmu III

$$u = (3, 3, -2)$$

$$z_0 = (1, 3, 3)$$

$$z_1 = (1, -1, -2)$$

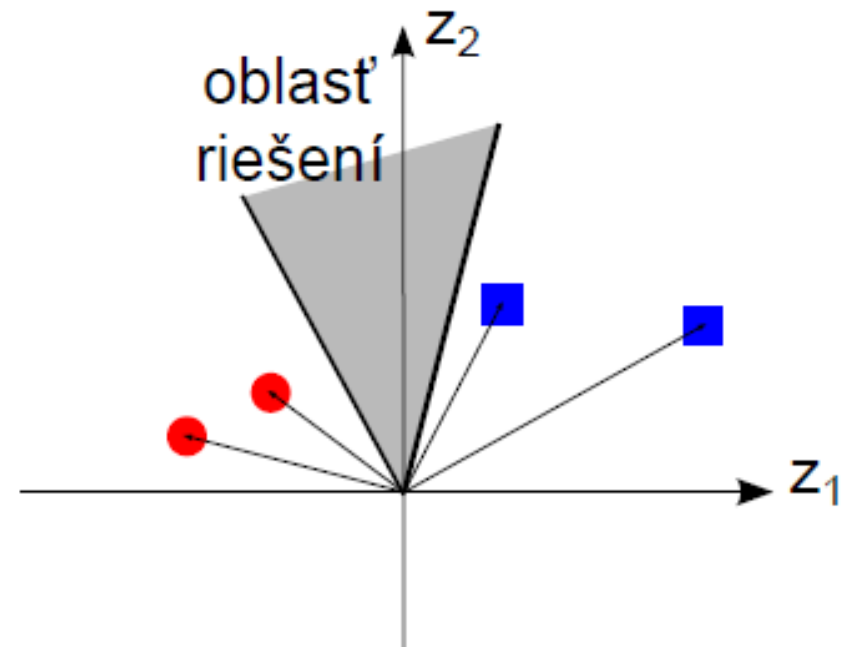
$$z_2 = -(1, -3, 1)$$



Kvadratická účelová funkcia

$$O_Q = \sum_{\mathbf{z} \in \mathcal{Z}_i} (\mathbf{u}^T \mathbf{z})^2$$

- Má spojitý gradient, je príliš hladká
- Môže konvergovať na hranici oblasti riešení
- Dlhšie vektory \mathbf{z} vplývajú na hodnotu O_Q viac ako kratšie

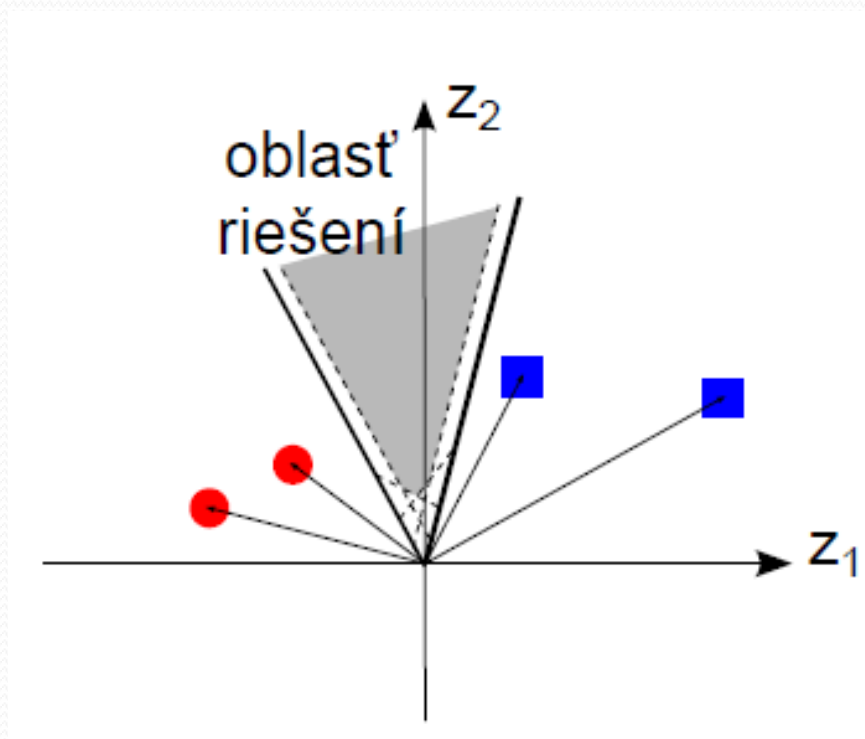


Normalizačný člen

- Pridáme člen určujúci okraj v oblasti riešení

$$O_R = \frac{1}{2} \sum_{\mathbf{z} \in \mathcal{Z}_i} \frac{(\mathbf{u}^T \mathbf{z} - \epsilon)^2}{\|\mathbf{z}\|^2}$$

$$\nabla O_R = \sum_{\mathbf{z} \in \mathcal{Z}_i} \frac{\mathbf{u}^T \mathbf{z} - \epsilon}{\|\mathbf{z}\|^2} \mathbf{z}$$



Úprava algoritmu

- Po doplnení normalizačného člena

inicializuj $\mathbf{u}_0 = 0$, $i=0$, $k=0$

opakuj

$k=(k+1) \bmod N$

ak $\mathbf{u}^T \mathbf{z}_k \leq \epsilon$

$\mathbf{z} = \mathbf{z}_k$

$\mathbf{u}_{i+1} = \mathbf{u}_i + \eta(i) \frac{\epsilon - \mathbf{u}^T \mathbf{z}}{\|\mathbf{z}\|^2} \mathbf{z}$

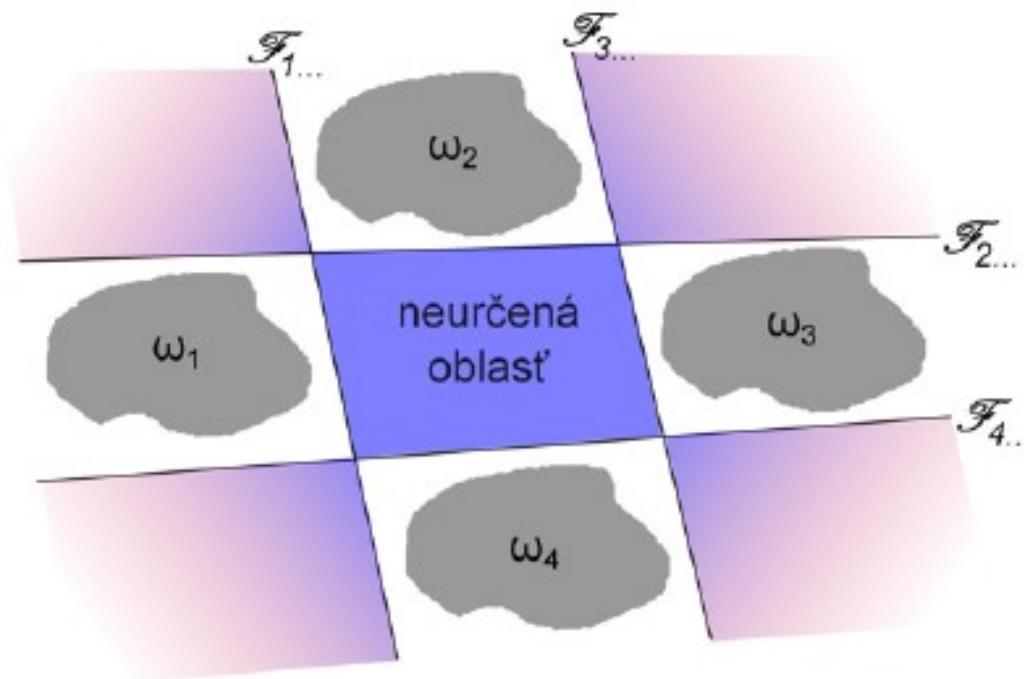
$i=i+1$

koniec ak

kým $\mathbf{u}^T \mathbf{z}_j > \epsilon$ pre všetky \mathbf{z}_j


Klasifikácia do R -tried

- 1. Pre každú klasifikačnú triedu môžeme vytvoriť rozhodovaciu funkciu, ktorá oddelí vzorky tejto triedy od vzoriek ostatných tried.
- Takto budeme mať R rozhodovacích funkcií
- Niektoré oblasti môžu byť neurčené



Klasifikácia do R -tried II

- 2. Pre každú dvojicu rôznych klasifikačných tried vytvoríme rozhodovaciu funkciu oddeľujúcu vzorky týchto dvoch tried bez ohľadu na vzorky ostatných tried.
- Dostaneme $R(R - 1)/2$ rozhodovacích funkcií
- Aj tu môžu byť neurčené oblasti



Lineárny stroj

- Preto vytvoríme R rozhodovacích funkcií


$$\{f_k(\mathbf{x})\}_{k=1}^R$$

- \mathbf{x} zaradíme do tej klasifikačnej triedy, ktorej hodnota rozhodovacej funkcie po dosadení je najväčšia

$$\mathbf{x} \in \omega_i \leftrightarrow \forall_{j \neq i} f_i(\mathbf{x}) > f_j(\mathbf{x})$$

- To rozdelí priestor do R konvexných oblastí

Lineárny stroj II



Lineárny stroj III

- Pre dve susedné oblasti zodpovedajúce ω_i a ω_j je hranica medzi nimi súčasťou nadroviny H_{ij} definovanej rovnosťou

$$f_i(\mathbf{x}) = f_j(\mathbf{x}) \text{ alebo } (\mathbf{w}_i - \mathbf{w}_j)^T \mathbf{x} + (b_i - b_j) = 0$$

- Z toho vyplýva, že $\mathbf{w}_i - \mathbf{w}_j$ je normála ku H_{ij} a signovaná vzdialenosť od \mathbf{x} ku H_{ij} určená vzťahom




$$\frac{(f_i(\mathbf{x}) - f_j(\mathbf{x}))}{\|\mathbf{w}_i - \mathbf{w}_j\|}$$

Lineárny stroj IV

- Takže pre lineárny stroj to nie sú váhové vektory, ktoré sú dôležité, ale ich rozdiely
- Celkove je $R(R - 1)/2$ dvojíc oblastí, ktoré zodpovedajú triedam, ale nie všetky musia byť susedné
- Potom celkový počet segmentov nadrovín, ktoré vystupujú v rozhodovacích plochách, môže byť nižší

Support vector machines (SVM)

- Máme nadrovinu, ktorá síce dobre klasifikuje trénovacie dáta, ale pri testovacích dátach dosahuje veľkú chybu
- Čiastočné riešenie: použitie účelovej funkcie O_R , ale optimálna hodnota parametra nie je




SVM II

- Mechanizmus podporných vektorov (SVM) sa snaží nájsť nadrovinu, čo najviac vzdialenú od trénovacích vzoriek dvoch tried
- Podpornými vektormi sú potom tie vzorky každej triedy, ktoré sú najbližšie k oddeľujúcej nadrovine.
- Vzdialenosť medzi podpornými vektormi rôznych tried sa nazýva rozpätie (margin)

SVM III

- Pre takúto nadrovinu platí $\mathbf{w}^T \mathbf{x} + b = \pm 1$ a rozpätie $\frac{2}{\|\mathbf{w}\|}$



SVM IV

- Hľadáme maximum
- A súčasne minimum

$$\mathbf{w}^* = \operatorname{argmax} \frac{2}{\|\mathbf{w}\|}$$

$$(\mathbf{w}^*, b^*) = \operatorname{argmin} \frac{1}{2} \|\mathbf{w}\|^2,$$

aby

$$\mathbf{w}^T \mathbf{x}_i + b \geq 1 \text{ pre } \mathbf{x} \in \omega_1,$$

$$\mathbf{w}^T \mathbf{x}_i + b \leq -1 \text{ pre } \mathbf{x} \in \omega_2.$$

- Ako na to použiť Lagrangeovu funkciu?

SVM V

- Pomôže trik, aby podmienka bola iba jedna
- Spojíme podmienky $(\mathbf{w}^T \mathbf{x}_i + b) k_i \geq 1$ kde

$$k_i = \begin{cases} 1 & \text{pre } \mathbf{x} \in \omega_1 \\ -1 & \text{pre } \mathbf{x} \in \omega_2 \end{cases}$$

- Lagrangián:
$$L(\mathbf{w}, b, \alpha_i) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i ((\mathbf{w}^T \mathbf{x}_i + b) k_i - 1)$$
$$= \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i (\mathbf{w}^T \mathbf{x}_i + b) k_i + \sum_{i=1}^N \alpha_i,$$

aby

$$\alpha_i \geq 0.$$

Kuhn-Tuckerove podmienky

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^N \alpha_i k_i \mathbf{x}_i \equiv 0$$

$$\frac{\partial L}{\partial b} = - \sum_{i=1}^N \alpha_i k_i \equiv 0$$

$$(\mathbf{w}^T \mathbf{x}_i + b) k_i - 1 \geq 0$$

$$\alpha_i \geq 0$$


$$\alpha_i ((\mathbf{w}^T \mathbf{x}_i + b) k_i - 1) = 0$$

$$\mathbf{w} = \sum_{i=1}^N \alpha_i k_i \mathbf{x}_i$$

$$\sum_{i=1}^N \alpha_i k_i = 0$$

$$\alpha_i = 0 \Leftrightarrow (\mathbf{w}^T \mathbf{x}_i + b) k_i > 1$$

$$\alpha_i > 0 \Leftrightarrow (\mathbf{w}^T \mathbf{x}_i + b) k_i = 1$$



Kuhn-Tuckerove podmienky II

$$L(\mathbf{w}, b, \alpha_i) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^N \alpha_i (\mathbf{w}^T \mathbf{x}_i + b) k_i + \sum_{i=1}^N \alpha_i$$

$$\mathbf{w} = \sum_{i=1}^N \alpha_i k_i \mathbf{x}_i$$

$$\sum_{i=1}^N \alpha_i k_i = 0$$

- Aby sme našli α , spočítame duálny problém

$$\tilde{\alpha}_i = \arg \max \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k_i k_j \mathbf{x}_i^T \mathbf{x}_j$$

aby

$$\alpha_i \geq 0$$

$$\sum_{j=1}^N \alpha_j k_j = 0$$

Duálny problém


1. Duálnu úlohu vyriešime metódami kvadratického programovania.

2. Určíme množinu podporných vektorov $\mathbf{x}_i \in SV$, pre ktoré $\alpha_i > 0$.

3. Určíme hodnotu
$$b = \frac{1}{|SV|} \sum_{\mathbf{x}_j \in SV} \left(k_j - \sum_{\mathbf{x}_i \in SV} \alpha_i k_i \mathbf{x}_i^T \mathbf{x}_j \right)$$



4. Zistíme hodnotu klasifikačnej funkcie
$$f(\mathbf{x}) = \sum_{\mathbf{x}_i \in SV} \alpha_i k_i \mathbf{x}_i^T \mathbf{x} + b.$$

Toto je výsledok



Neseparovateľné dáta

- Dáta separovateľné, ale s malou nenulovou chybou
- Dáta neseparovateľné ani pri nenulovej tolerancii



SVM s voľným rozpätím


- Pre prvý prípad zavedieme druhotné premen-
né ξ_i a podmienku nulovej chyby oslabíme

$$(\mathbf{w}^*, b^*, \xi_i^*) = \operatorname{argmin} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i,$$

aby

$$(\mathbf{w}^T \mathbf{x}_i + b) k_i \geq 1 - \xi_i,$$

- C určuje penalizáciu za chybnú klasifikáciu a ovplyvňuje veľkosť rozpätia
- Lagrangián \rightarrow duálny problém



SVM s voľným rozpätím II

- Duálna úloha sa nemení, mení sa podmienka

- Lagrange: $(\tilde{\mathbf{w}}, \tilde{b}, \tilde{\xi}) = \arg \min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i$

$$(\mathbf{w}^T \mathbf{x}_i + b)k_i \geq 1 - \xi_i$$

- Duál: $\tilde{\alpha}_i = \arg \max \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k_i k_j \mathbf{x}_i^T \mathbf{x}_j$

aby

$$0 \leq \alpha_i \leq C$$


$$\sum_{j=1}^N \alpha_j k_j = 0$$

$$\mathbf{w} = \sum_{i=1}^N \alpha_i k_i \mathbf{x}_i = \sum_{i \in SV} \alpha_i k_i \mathbf{x}_i$$


SVM s voľným rozpätím III

- Vhodnú hodnotu C nájdeme vzájomnou validáciou

Effect of C : $C = 1$




Effect of C : $C = 1000$




Nelineárny SVM

- Pre lineárne neseparovateľné nájdeme zobrazenie do iného priestoru, kde to ide lineárne





$$\phi: \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \rightarrow \begin{pmatrix} x_1^2 \\ x_2^2 \\ \sqrt{2}x_1x_2 \end{pmatrix}$$



Nelineárny SVM II

$$\varphi: \mathbb{R}^2 \rightarrow \mathbb{R}^3$$

$$\tilde{\alpha}_i = \arg \max \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k_i k_j \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j)$$



Nelineárny SVM III

1. Duálnu úlohu vyriešime metódami kvadratického programovania.

2. Určíme množinu podporných vektorov $\mathbf{x}_i \in SV$, pre ktoré $\alpha_i > 0$.

3. Určíme hodnotu $b = \frac{1}{|SV|} \sum_{\mathbf{x}_j \in SV} \left(k_j - \sum_{\mathbf{x}_i \in SV} \alpha_i k_i \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \right)$

4. Zistíme hodnotu klasifikačnej funkcie $f(\mathbf{x}) = \sum_{\mathbf{x}_i \in SV} \alpha_i k_i \phi(\mathbf{x}_i)^T \phi(\mathbf{x}) + b$

Kernelový trik

- Takže namiesto transformácie každého príznačkového vektora do viacrozmerného priestoru počítame hodnotu funkcie $K(\cdot)$ pôvodných vektorov
- Funkcia $K(\mathbf{x}, \mathbf{y}) = \phi(\mathbf{x})^T \phi(\mathbf{y})$ sa nazýva kernelová funkcia alebo jadro
- Potom môžeme vzťahy pri výpočte duálnej úlohy zapísať ako:

Kernelový trik II


$$\alpha^* = \operatorname{argmax} \left(\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j k_i k_j K(\mathbf{x}_i, \mathbf{x}_j) \right)$$

$$b = \frac{1}{|SV|} \sum_{\mathbf{x}_j \in SV} \left(k_j - \sum_{\mathbf{x}_i \in SV} \alpha_i k_i K(\mathbf{x}_i, \mathbf{x}_j) \right)$$

$$f(\mathbf{x}) = \sum_{\mathbf{x}_i \in SV} \alpha_i k_i K(\mathbf{x}_i, \mathbf{x}) + b.$$

Kernelový trik III

- Pre prípad



a zobrazenie

$$\phi: \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \rightarrow \begin{pmatrix} x_1^2 \\ x_2^2 \\ \sqrt{2}x_1 x_2 \end{pmatrix}$$

je kernelová funkcia

$$\begin{aligned} K(\mathbf{x}, \mathbf{y}) &= (x_1^2, x_2^2, \sqrt{2}x_1 x_2) \cdot \begin{pmatrix} y_1^2 \\ y_2^2 \\ \sqrt{2}y_1 y_2 \end{pmatrix} = x_1^2 y_1^2 + x_2^2 y_2^2 + 2x_1 y_1 x_2 y_2 = \\ &= (x_1 y_1 + x_2 y_2)^2 = \\ &= (\mathbf{x}^T \mathbf{y})^2 \end{aligned}$$

Kernelový trik - príklad

$$\begin{aligned}K(\mathbf{x}_i, \mathbf{x}_j) &= (\mathbf{x}_i^T \mathbf{x}_j)^2 = \left(\begin{pmatrix} x_{i1} & x_{i2} \end{pmatrix} \begin{pmatrix} x_{j1} \\ x_{j2} \end{pmatrix} \right)^2 = \\ &= (x_{i1}x_{j1} + x_{i2}x_{j2})^2 = \\ &= x_{i1}^2x_{j1}^2 + 2x_{i1}x_{j1}x_{i2}x_{j2} + x_{i2}^2x_{j2}^2\end{aligned}$$

$$\varphi(\mathbf{x}) = \begin{pmatrix} x_1^2 \\ \sqrt{2}x_1x_2 \\ x_2^2 \end{pmatrix}$$

$$\varphi(\mathbf{x}) = \begin{pmatrix} x_1^2 \\ x_1x_2 \\ x_1x_2 \\ x_2^2 \end{pmatrix}$$

$$\varphi(\mathbf{x}) = \frac{1}{\sqrt{2}} \begin{pmatrix} x_1^2 - x_2^2 \\ 2x_1x_2 \\ x_1^2 + x_2^2 \end{pmatrix}$$


Ako nájdeme jadro

- Ako pre ľubovoľnú funkciu K zistíme, či zodpovedá skalárnemu súčinu $\phi(\mathbf{x}_1)^T \phi(\mathbf{x}_2)$ v nejakom priestore?
- Konštruujeme špeciálne funkcie – Mercerove jadrá: Ak K je symetrická ($K(\mathbf{x}_i, \mathbf{x}_j) = K(\mathbf{x}_j, \mathbf{x}_i)$) pozitívne semidefinitná Gramova matica $\forall \mathbf{a} \in \mathbb{R}^N, \mathbf{a}K\mathbf{a} \geq 0$ a $k_{ij} = K(\mathbf{x}_i, \mathbf{x}_j)$, potom K je platné jadro

Príklady jadier


- Polynomiálne jadrá

$$K(\mathbf{x}, \mathbf{y}) = (a + \mathbf{x}^T \mathbf{y})^p$$



- Gaussovské jadrá

$$K(\mathbf{x}, \mathbf{y}) = e^{-\frac{\|\mathbf{x}-\mathbf{y}\|^2}{2\sigma^2}}$$




Príklad

- Majme triedy

Class 1: $x_1=(-1,-1)$, $x_4=(1,1)$

Class 2: $x_2=(-1,1)$, $x_3=(1,-1)$

$$K(x, x') = (x^T x' + 1)^2$$



$$\varphi(x_i) = \left[1 \quad \sqrt{2}x_{i,1} \quad \sqrt{2}x_{i,2} \quad \sqrt{2}x_{i,1}x_{i,2} \quad x_{i,1}^2 \quad x_{i,2}^2 \right]^T$$

$$\tilde{\alpha}_i = \arg \max \alpha_1 + \alpha_2 + \alpha_3 + \alpha_4 - \frac{1}{2} \sum_{i=1}^4 \sum_{j=1}^4 \alpha_i \alpha_j k_i k_j \kappa(\mathbf{x}_i, \mathbf{x}_j)$$

Príklad - pokračovanie

$$9\alpha_1 - \alpha_2 - \alpha_3 + \alpha_4 = 1$$

$$-\alpha_1 + 9\alpha_2 + \alpha_3 - \alpha_4 = 1$$

$$-\alpha_1 + \alpha_2 + 9\alpha_3 - \alpha_4 = 1$$


$$\alpha_1 - \alpha_2 - \alpha_3 + 9\alpha_4 = 1$$

$$\alpha_1 = \alpha_2 = \alpha_3 = \alpha_4 = 0.125$$


$$\mathbf{w} = \sum_{i=1}^4 \alpha_i y_i \varphi(\mathbf{x}_i) = [0 \quad 0 \quad 0 \quad 1/\sqrt{2} \quad 0 \quad 0]^\top$$

$$g(\mathbf{x}) = \sum_{i=1}^6 w_i \varphi_i(\mathbf{x}) = x_1 x_2$$

$$y(\mathbf{x}) = \mathbf{w}^\top \varphi(\mathbf{x}) + b = \sum_{i=1}^N \alpha_i k_i \kappa(\mathbf{x}_i, \mathbf{x}) + b$$



ie obrazcov 2



SVM aplikácie

- Kategorizácia textu a hypertextu
- Klasifikácia obrazov
- Bioinformatika (klasifikácia proteínov, detekcia nádorov)
- Rozpoznávanie písaného textu
- ...

Motivačné dáta pre kernel SVM

