

Strojno učenje

7

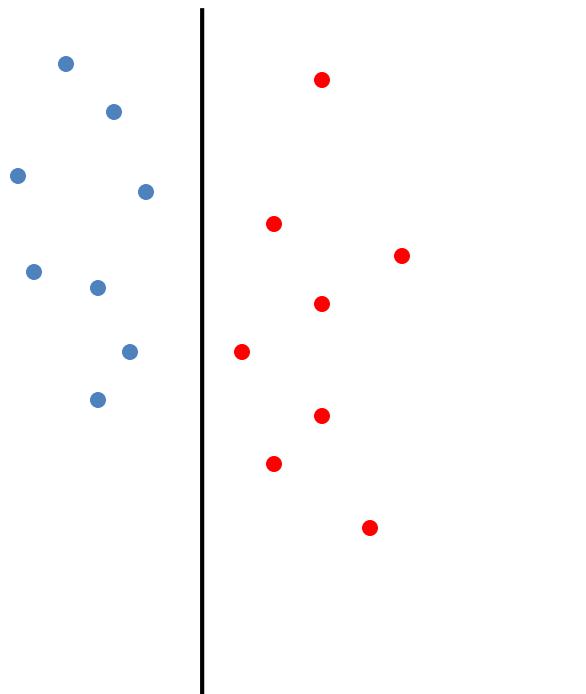
Metoda potpornih vektora (SVM – Support Vector Machines)

Tomislav Šmuc


PMF, Zagreb, 2020

Generativni i diskriminativni modeli

- Diskriminativni
(Učenje linije koja razdvaja klase)



- Generativni
Učenje modela za svaku pojedinu klasu



Diskriminativni algoritmi – do sada

Klasifikacija



- Klasifikator baziran na linearnoj regresiji
- Logistička regresija
- LDA, QDA, FDA
- Diskriminativne funkcije - $\delta_k(x)$ - funkcije koje određuju pripadnost nekoj klasi k

$$C(x) = \arg \max_{k \in C} \delta_k(x)$$

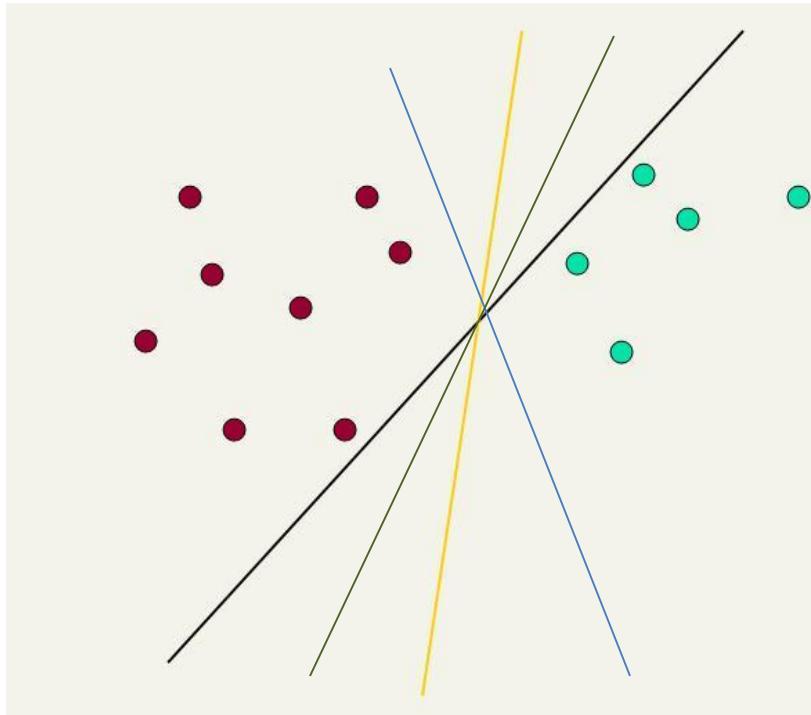
- određene plohe/hiperravnine koje razdvajaju klase

$$\{\mathbf{x} : \delta_k(\mathbf{x}) = \delta_l(\mathbf{x})\}$$

- intuicija: što je $\delta_k(x)$ veća to je vjerojatnost pripadanja klasi k veća \sim udaljenosti od plohe/hiperravnine razdvajanja



Koja hiper-ravnina je najbolja ?



Separabilni problem:
Između točaka možemo
provući velik broj
(beskonačan) ploha koje
dobro razdvajaju primjere
dvije klase

Metoda potpornih vektora (metoda jezgrenih funkcija)

SVM - Support Vector Machines

SVM – nalazi hiper-ravninu koja ima najveću **marginu** razdvajanja klasa


- margina - **udaljenost između “kriticnih” točaka** najbliže blizu plohi razdvajanja (en. decision boundary)

Intuicija:

Ako ne postoje točke blizu plohe razdvajanja, to znači da nemamo nesigurnih klasifikacijskih odluka !?


Druga intuicija

- Ako postavimo što je moguće veći “razmak” (marginu) između dviju klasa, postoji manje mogućnosti izbora za funkciju razdvajanja – kapacitet modela se smanjuje (manje šanse za overfitting?)



- SVM dakle **maksimiziraju marginu m** oko hiperravnine (plohe) razdvajanja.
 - (en. large margin classifiers)
- Kod SVM - funkcija odluke definirana je preko podskupa primjera iz skupa za učenje =>
tzv. Potpornih vektora (en. support vectors => SV)
- Problem određivanja SV:
kvadratni optimizacijski problem (en. quadratic programming)

Potporni vektori




Separabilni i neseparabilni problemi

Ako se pokaže da problem nije linearno separabilan:

- Dozvoljene su greške – uz penaliziranje

Osnovni princip ostaje:

- Ploha razdvajanja u principu mora što bolje razdvajati klase (max margina)



SVM – linearno separabilni podaci (2 klase)

Geometrijska intuicija - **konveksna ljuška (Convex hull)**



- K.LJ. – najmanji konveksni skup koji sadrži sve točke skupa točaka $\{\mathbf{x}_i\}$
- Za dani skup točaka $\{\mathbf{x}_i\}$ K.LJ. je skup točaka definiran sa:

$$\mathbf{x} = \sum_i \alpha_i \mathbf{x}_i$$

Uz:

$$\alpha_i \geq 0$$

$$\sum_i \alpha_i = 1$$



- za dva skupa $\{\mathbf{x}_i\}$ i $\{\mathbf{y}_i\}$ vrijedi ako se njihove K.LJ. ne preklapaju – onda se radi o linearno separabilnom problemu !

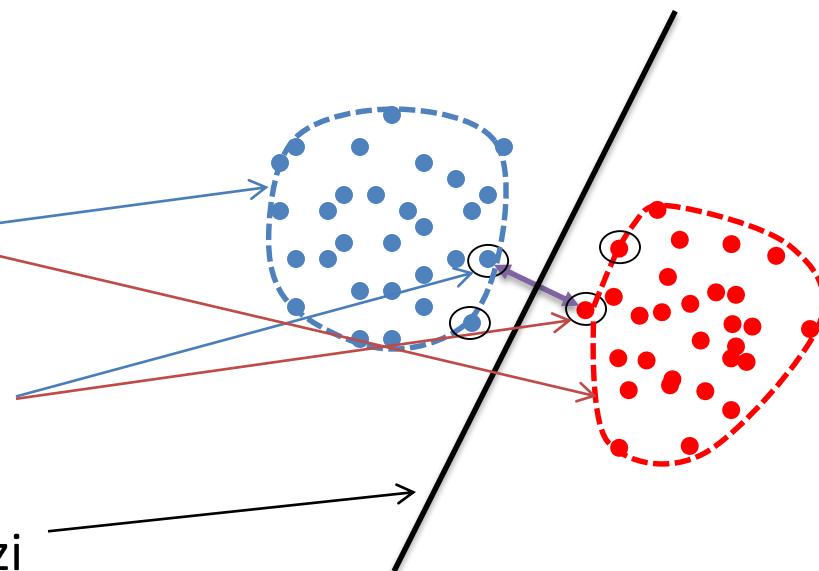
SVM – linearne separabilni podaci (2 klase)

Geometrijska intuicija - Konveksne ljudske

- K.LJ. – najmanji konveksni skup koji sadrži sve točke

Zadatak

- naći konveksnu ljudsku za svaku od klasa
- Naći dvije najbliže točke u dvije konveksne ljudske
- Odrediti ravninu koja prolazi između te dvije točke




Matematička formalizacija - određivanje maksimalne margine

- w : normala na hiperravninu razdvajanja
- x_i : primjer (točka) i
- y_i : klasa primjera i (+1/-1)
- Klasifikator je određen funkcijom $\rightarrow \text{sign}(w^T x_i + b)$
- margina x_i je određena sa $\rightarrow y_i (w^T x_i + b)$

Pojam - geometrijske margine

- Primjeri najbliže plohi su ***potporni vektori***.
- ***Margina* ρ** plohe razdvajanja je širina razdvajanja između potpornih vektora suprotnih klasa



Linearni SVM - izvod (binarni klasifikacijski problem)

- Pretpostavimo da vrijedi da se sve točke nalaze najmanje na distanci 1 od plohe razdvajanja
- Tada vrijede dva ograničenja na skupu primjera za učenje $\{(\mathbf{x}_i, y_i)\}$

$$\mathbf{w}^T \mathbf{x}_i + b \geq 1 \quad \text{ako je } y_i = 1$$

$$\mathbf{w}^T \mathbf{x}_i + b \leq -1 \quad \text{ako je } y_i = -1$$

- Za **potporne vektore** (točke koje se nalaze na margini), ove nejednakosti su jednakosti;
- S obzirom da je udaljenost svakog primjera od plohe razdvajanja:

$$r = \frac{\mathbf{w}^T \mathbf{x} + b}{\|\mathbf{w}\|}$$

- Margina je: $\rho = \frac{2}{\|\mathbf{w}\|}$

Linearni SVM

Ploha razdvajanja

$$\mathbf{w}^T \mathbf{x} + b = 0$$


Uz ograničenja:

$$\min_{i=1,\dots,n} |\mathbf{w}^T \mathbf{x}_i + b| = 1$$

Dolazimo do vrijednosti za marginu razdvajanja:

$$\mathbf{w}^T (\mathbf{x}_a - \mathbf{x}_b) = 2$$

$$\rho = ||\mathbf{x}_a - \mathbf{x}_b|| = 2 / ||\mathbf{w}||$$



Linearni SVM - formulacija optimizacijskog problema

Pronađi \mathbf{w} i b tako da je

$$\rho = \frac{2}{\|\mathbf{w}\|} \Rightarrow \text{maksimalna}$$

a za sve zadane $\{(\mathbf{x}_i, y_i)\}$ mora vrijediti:

$$\mathbf{w}^T \mathbf{x}_i + b \geq 1 \quad \text{ako je } y_i = 1;$$

$$\mathbf{w}^T \mathbf{x}_i + b \leq -1 \quad \text{ako je } y_i = -1$$

Linearni SVM - formulacija optimizacijskog problema

- Bolja formulacija – kao minimizacijski problem
 - $\min ||\mathbf{w}|| = \max (2/ ||\mathbf{w}||)$
- Povoljniji oblik za rješavanje
 - kvadratni optimizacijski problem uz ograničenja:
umjesto $\min ||\mathbf{w}|| \Rightarrow \min (\mathbf{w}^T \mathbf{w})$

Naći \mathbf{w} i b - takve da je:

$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w}$ je minimalno;

A za sve $\{(\mathbf{x}_i, y_i)\}$ vrijedi :

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

Rješavanje optimizacijskog problema => optimizacija uz ograničenja

Nađi \mathbf{w} i b - takve da je:

$$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} \quad - \text{minimalno};$$

A za sve $\{\mathbf{x}_i, y_i\}$ vrijedi :

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

- Ova formulacija – minimizacija kvadratne funkcije uz linearne ograničenja (nejednakosti) => **primalna formulacija**
- Dobro poznati i rješivi problem – puno (više ili manje složenih) algoritama za njihovo rješavanje (MATLAB, MATHEMATICA)
- Standardno za SVM - prevodenje u **dualni problem** u kojem se tzv. **Lagrangeovim multiplikatorima** optimiraju težinski faktori koji penaliziraju svako ograničenje iz primalnog problema.

Lagrange-ovi multiplikatori => optimizacija uz ograničenja

Minimiziraj funkciju $f(\mathbf{x})$ uz ograničenja u obliku jednakosti $g(\mathbf{x})=0$

- Naći minimum funkcije $f(\mathbf{x}), \mathbf{x} \in R^d$, uz ograničenja $g(\mathbf{x}) = 0, i = 1 \dots m$
- Tada postoji:
 $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_m)$ (Lagr. multiplikatori) za koje u minimumu \mathbf{x}_* , koji zadovoljava sva ograničenja, vrijedi:


$$\nabla f(\mathbf{x}) = \lambda_1 \nabla g_1(\mathbf{x}_*) + \lambda_2 \nabla g_2(\mathbf{x}_*) + \dots + \lambda_m \nabla g_m(\mathbf{x}_*)$$

Ako uvedemo tzv. Lagrangeovu funkciju

$L(\mathbf{x}, \lambda) = f(\mathbf{x}) + \sum_i \lambda_i g_i(\mathbf{x})$, proizlazi da vrijedi u \mathbf{x}_* :

$$\frac{\partial L}{\partial \lambda_i} = g_i(\mathbf{x}) = 0$$

$$\nabla L_x = \nabla f(\mathbf{x}) + \lambda_1 \nabla g_1(\mathbf{x}) + \lambda_2 \nabla g_2(\mathbf{x}) + \dots + \lambda_m \nabla g_m(\mathbf{x})$$




Moramo pronaći stacionarnu točku $L(\mathbf{x}, \lambda)$ - s obzirom na \mathbf{x} i λ !

Lagrange-ovi multiplikatori => optimizacija uz ograničenja


Minimiziraj funkciju $f(\mathbf{x})$ uz ograničenja tipa nejednakosti $g(\mathbf{x}) \geq 0$

- Rješenje \mathbf{x}_* može biti:
 - unutar plohe $g_i(\mathbf{x})$ – tada vrijedi $g_i(\mathbf{x}) > 0$. U tom slučaju ograničenje i nije aktivno => $\lambda_i = 0$!
 - Na $g_i(\mathbf{x})=0$ – tada je ograničenje aktivno => $\lambda_i \geq 0$!



Lagrange-ovi multiplikatori => optimizacija uz ograničenja


Slučaj sa ograničenjem u obliku nejednakosti



a) Aktivno ograničenje

$$\min f(x) \neq \min(L(x))$$

$$g_i(x) \geq 0$$




b) Ograničenje nije aktivno

$$\min f(x) = \min(L(x))$$

$$g_i(x) \geq 0$$

Slučaj sa ograničenjem u obliku jednakosti



$$h_j(x) = 0$$

$\clubsuit \Rightarrow \text{Min } f(\mathbf{x})$ (neograničeni minimum)

$\bullet \Rightarrow \text{Min } L(\mathbf{x})$ (ograničeni minimum $f(\mathbf{x})$)

Lagrange-ovi multiplikatori => optimizacija uz ograničenja

Karush-Kuhn-Tucker (KKT) uvjeti
(generalizacija metode LM na ograničenja u obliku nejednakosti)

- Rješenje za nelinearne optimizacijski problem tipa:

$$\min_{\mathbf{x}} f(\mathbf{x})$$

$$s.t. \quad g_i(\mathbf{x}) \geq 0$$

- Dobije se optimizacijom s obzirom na \mathbf{x} i λ :

$$L(\mathbf{x}, \lambda) = f(\mathbf{x}) + \sum_i \lambda_i g_i(\mathbf{x})$$

- Uz ograničenja u (ograničenom) minimumu \mathbf{x}^* vrijedi:

$$g_i(\mathbf{x}^*) \geq 0;$$

$$\lambda_i \geq 0;$$

$$\lambda_i g_i(\mathbf{x}^*) = 0;$$

Lagrange-ova funkcija i min-max dualnost

Primalna formulacija:

$$\min_w \max_{\lambda} L(w, \lambda)$$

Dualna formulacija:

$$\max_{\lambda} \min_w L(w, \lambda)$$

Za konveksni problem:

$$\min_w \max_{\lambda} L(w, \lambda) = \max_{\lambda} \min_w L(w, \lambda)$$

Wolfe dual:

$$\max_{\lambda \geq 0} L(w, \lambda)$$

$$\text{uz } \frac{\partial}{\partial w} L(w, \lambda) = 0$$

- Primalna formulacija Lagr. Multiplikatori + KKT uvjeti => dualna formulacija

$$L(w, \lambda, b) = \frac{1}{2} ||w||^2 - \sum_{j=1}^N \lambda_j \{y_j(w^T x_j + b) - 1\}$$

$$\frac{\partial L}{\partial w} = 0 \Leftrightarrow w - \sum_{j=1}^N \lambda_j y_j x_j = 0 \Leftrightarrow w = \sum_{j=1}^N \lambda_j y_j x_j$$

$$\frac{\partial L}{\partial b} = 0 \Leftrightarrow \sum_{j=1}^N \lambda_j y_j = 0$$

Uz

$$\begin{aligned}\lambda_i &\geq 0, i = 1, \dots, N \\ \lambda_i(y_i(w^T x_i + b) - 1) &= 0, i = 1, \dots, N \\ (y_i(w^T x_i + b) - 1) &\geq 0, i = 1, \dots, N\end{aligned}$$

Prevođenje u *dualni problem*

- Grace Wahba - Representer teorem

$$w = \sum_{j=1}^N \lambda_j y_j x_j$$

- Ako zamijenimo w u primalnom problemu gornjim izrazom

$$\begin{aligned} w^T x + b &= \left(\sum_{j=1}^N \lambda_j y_j x_j \right)^T x + b = \sum_{j=1}^N \lambda_j y_j (x_j^T x) + b \\ w^T w &= \left(\sum_{j=1}^N \lambda_j y_j x_j \right)^T \left(\sum_{k=1}^N \lambda_k y_k x_k \right) = \sum_{jk} \lambda_j \lambda_k y_j y_k (x_j^T x_k) \end{aligned}$$

SVM - optimizacijski problem

Dualna formulacija:

Naći $\lambda_1, \dots, \lambda_N$ tako da je:

$$\text{Max } Q(\lambda) = \sum \lambda_i - \frac{1}{2} \sum \sum \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

Te da vrijedi

$$(1) \sum \lambda_i y_i = 0 \quad j = 1, N$$

$$(2) \lambda_i \geq 0 \quad \forall i = 1, \dots, N$$

Rješenje optimizacijskog problema

$$\mathbf{w} = \sum \lambda_i y_i \mathbf{x}_i \quad b = y_k - \mathbf{w}^T \mathbf{x}_k, \quad \text{za } \mathbf{x}_k \text{ za koji je } \lambda_k \neq 0 \text{ (t.j. SV)}$$


- **Svaki λ_i koji je različit od 0** – zapravo znači da je taj \mathbf{x}_i – potporni vektor.
- Rješenje je proporcionalno sumi umnožaka - *unutarnjih produkta* $\mathbf{x}_i^T \mathbf{x}$ između nove točke (primjera) \mathbf{x} i svih potpornih vektora \mathbf{x}_i !
- Treba zapamtiti i da je u rješavanju optimizacijskog problema korišten produkt $\mathbf{x}_i^T \mathbf{x}_j$ između svih parova točaka skupa za učenje.
- Konačno – klasifikacijska funkcija ima ovaj oblik:

$$f(\mathbf{x}) = \sum_i (\lambda_i y_i \mathbf{x}_i^T \mathbf{x} + b)$$

- U **linearnim regresijskim problemima** učimo i koristimo \mathbf{w} (\sim broj varijabli)
- **K-nn algoritmi** - koristimo sve *trening točke* ($\sim N$) da bi radili predikcije
- **SVM** – koristi točke iz trening skupa ($\lambda_i \geq 0$) da bi radili predikcije – nešto između LR i k-nn ?!

Što ako problem nije linearno separabilan?

- Dodajemo nove varijable ξ_i (*en. slack variables*)
 - dozvoljavanje krivih klasifikacija za „teške“ ili „šumovite“ primjere



Izvod – SVM s “mekanom” marginom (en. Soft margin)

- Stara formulacija:

Nađi \mathbf{w} i b - takve da je:

$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w}$ is minimalno;

A za sve $\{(\mathbf{x}_i, y_i)\}$ vrijedi :

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

- Nova formulacija sa ξ_i :

Nađi \mathbf{w} i b - takve da je:

$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \cdot \sum \xi_i$ - minimalno;

A za sve $\{(\mathbf{x}_i, y_i)\}$ vrijedi:

$$y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i \quad - te da vrijedi \xi_i \geq 0 \text{ za sve } i$$

Rješenje - SVM s “mekanom” marginom (en. Soft margin)

- Dualni problem za SVM s “mekanom” marginom :

Nadji $\lambda_1 \dots \lambda_N$ tako da je

$$\max Q(\lambda) = \sum \lambda_i - \frac{1}{2} \sum \sum \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

Te da vrijedi

$$(1) \sum \lambda_i y_i = 0$$

$$(2) 0 \leq \lambda_i \leq C \quad \forall \lambda_i$$

- I dalje vrijedi: \mathbf{x}_i sa $\lambda_i > 0$ – su potporni vektori.
- U dualnoj formulaciji – nema slack varijabli, samo ograničenje na λ ($\lambda < C$)
- Rješenje dualnog problema (soft margin):

$$\mathbf{w} = \sum \lambda_i y_i \mathbf{x}_i$$

$$b = y_k (1 - \xi_k) - \mathbf{w}^T \mathbf{x}_k, \quad k = \operatorname{argmax} \lambda_i$$

\mathbf{w} nije potreban kod procesa klasifikacije – kao i prije !

$$f(\mathbf{x}) = \sum \lambda_i y_i \mathbf{x}_i^T \mathbf{x} + b$$


Klasifikacija

- Uz novu točku (x_1, x_2) ,
 - Odrediti projekciju na normalu plohe razdvajanja:
 - 2 dimenzije: $p = w_1x_1 + w_2x_2 + b$.
 - To ustvari znači $(\mathbf{w}\mathbf{x} + b = \sum \lambda_i y_i \mathbf{x}_i^T \mathbf{x} + b)$
 - Moguće proširenje => ako stavimo neku graničnu mjeru $t > 0$ (pouzdanost)

$f > t: \Rightarrow 1$

$f < -t: \Rightarrow -1$

Inače: suzdržan



Linearni SVM - sažetak

- Klasifikator je posebno određena *ploha razdvajanja* (en. *separating hyperplane*)
- Najvažnije točke - točke iz skupa za učenje koje definiraju plohu razdvajanja
=> potporni vektori
- Potporni vektori se pronalaze – optimizacijskim algoritmom
- Rješavani problem je kvadratni optimizacijski problem s linearnim ograničenjima (=konveksni o.p.).
- U dualnoj formulaciji problema i rješenja – potporni vektori odnosno točke iz skupa za učenje se pojavljuju u skalarnim produktima:

Nađi $\lambda_1, \dots, \lambda_N$ tako da je

$$Q(\lambda) = \sum \lambda_i - \frac{1}{2} \sum \sum \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j - \text{maksimalno i vrijedi:}$$

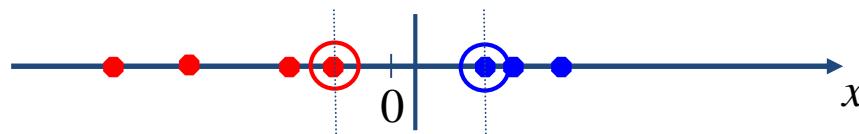
$$(1) \sum \lambda_i y_i = 0$$

$$(2) 0 \leq \lambda_i \leq C \quad \forall \lambda_i$$

$$f(\mathbf{x}) = \sum \lambda_i y_i \mathbf{x}_i^T \mathbf{x} + b$$

Nelinearni SVM


- Za probleme koji su linearno separabilni (i uz razumno šum) – Linearni SVM je OK :



- No, što ako to ne vrijedi ?




- ... mapiranje podataka u (još) više-dimenzionalni prostor !



Nelinearni SVM: prostori novih dimenzija (atributa)

- Osnovna ideja: originalni prostor varijabli – možemo mapirati u novi-višedimenzionalni prostor - gdje će naš problem biti (linearno) separabilan (rješiv)



Nelinearni SVM: prostori novih dimenzija (atributa)

- Primalni problem u transformiranom prostoru

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

- Učenje \mathbf{w} u \mathbb{R}^D - transformiranom prostoru

$$\min_{\mathbf{w} \in \mathbb{R}^D} \|\mathbf{w}\|^2 + C \sum_i^N (1 - y_i f(\mathbf{x}_i))$$

- Problem – ako je $D \gg d$!

Nelinearni SVM: prostori novih dimenzija (atributa)

- Dualni problem u transformiranom prostoru

$$f(\mathbf{x}) = \alpha_i y_i \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_i) + b$$

- Učenje u transformiranom prostoru

$$\max_{\alpha_i \geq 0} \sum_i \alpha_i - \frac{1}{2} \sum_{jk} \alpha_j \alpha_k y_j y_k \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_i)$$

s.t.

$$0 \leq \alpha_i \leq C \text{ za } \forall i, \quad \text{uz} \quad \sum_i \alpha_i y_i = 0$$

- Ako izračunamo skalarne produkte $\varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_i)$ - učimo samo N α_i !
- Možemo li $\varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_i)$ pojednostavniti ?

“Kernel trik”

- Skalarni produkt bi trebao izgledati drugčije:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$$

- *Kernel funkcija* - funkcija koja korespondira unutarnjem produktu u nekom “ekspandiranom” prostoru novih varijabli
 - Ne moramo uopće znati $\phi(\mathbf{x})$ da bi „operirali“ u novom prostoru !!

“Kernel trik”

Primjer: originalni prostor

2-dimenzionalni vektori $\mathbf{x} = [x_1 \ x_2]$;

Neka je $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^2$,


Pokažimo da vrijedi $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$,
 ako je $\phi(\mathbf{x}) = [1, x_1^2, \sqrt{2}x_1x_2, x_2^2, \sqrt{2}x_1 \ \sqrt{2}x_2]$

$$\begin{aligned}
 K(\mathbf{x}_i, \mathbf{x}_j) &= (1 + \mathbf{x}_i^T \mathbf{x}_j)^2 = 1 + x_{i1}^2 x_{j1}^2 + 2 x_{i1} x_{j1} x_{i2} x_{j2} + x_{i2}^2 x_{j2}^2 + 2 x_{i1} x_{j1} + 2 x_{i2} x_{j2} = \\
 &= [1 \ x_{i1}^2 \ \sqrt{2}x_{i1}x_{i2} \ x_{i2}^2 \ \sqrt{2}x_{i1} \ \sqrt{2}x_{i2}]^T [1 \ x_{j1}^2 \ \sqrt{2}x_{j1}x_{j2} \ x_{j2}^2 \ \sqrt{2}x_{j1} \ \sqrt{2}x_{j2}] \\
 &= \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) !
 \end{aligned}$$

Kerneli

- Zašto kerneli ?
 - Efikasno učenje
 - Mapiranje u bolje (reprezentacijski) – višedimenzionalne prostore
 - Omogućava pretvaranje neseparabilnih problema u separabilne.
- Uobičajeni kerneli
 - Linearni $K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j)$
 - Polinomijalni $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^d$
 $\frac{-\|\mathbf{x}_i - \mathbf{x}_j\|}{2\sigma^2}$
 - RBF $K(\mathbf{x}_i, \mathbf{x}_j) = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}}$
 - Sigmoid $K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma \mathbf{x}_i^T \mathbf{x}_j + r)$

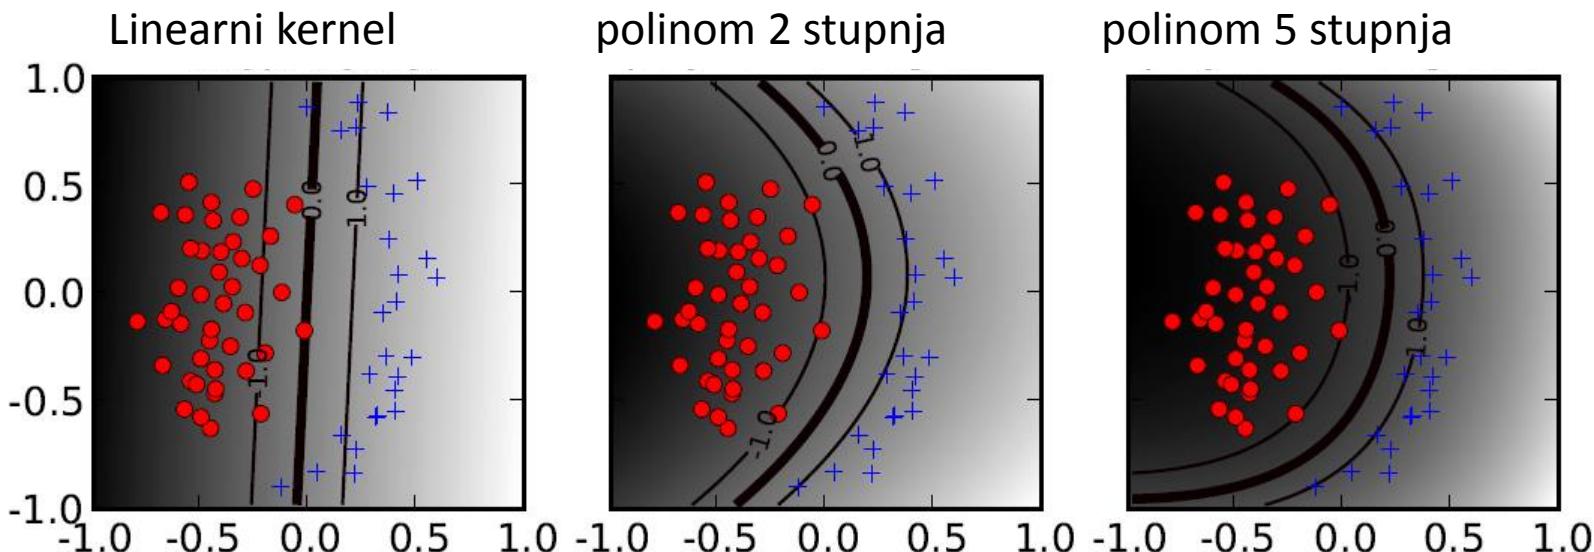
Linearni SVM – efekt različitih vrijednosti parametra C





Prisjetimo se gdje smo vidjeli C

$$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \cdot \Sigma \cdot \xi_i$$

Odabir kernela – efekti Polinomni kerneli ($C=\text{const.}$)





Odabir parametara kernela – efekti

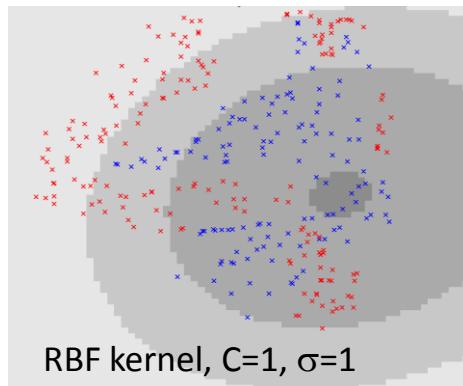


Gaussian kernel, $C=\text{const.}$


$$k(\mathbf{x}, \mathbf{x}') = e^{(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2)}$$




Odabir parametara parametara kernela i faktora C




RBF kernel, $C=1, \sigma=1$




RBF kernel, $C=10, \sigma=1$




RBF kernel, $C=100, \sigma=1$



RBF kernel, $C=1, \sigma=10$



RBF kernel, $C=10, \sigma=10$



RBF kernel, $C=100, \sigma=10$

$$\gamma = 1/\sigma$$

SVM - Sa dvije klase na više klasa

Većina SVM metoda je za binarne klasifikacijske probleme

Uobičajen pristup za višeklasne probleme je preko redukcije problema na više binarnih klasifikacijskih problema, npr. za K-klasni problem:

- Jedan-nasuprot-ostalih => ($K - \text{binarnih klasifikatora}$)
- Svaki-protiv-svakog => ($K*(K-1)/2 - \text{binarnih klasifikatora}$)
- ECOC – Error Correcting Output Codes (... u jednom od slijedećih predavanja)



SVM – Regresija

Problem

$$\min_{\mathbf{w}} C \sum_n E_\epsilon(y_n - f(x_n)) + \lambda \|\mathbf{w}\|$$

Gdje je

$$E_\epsilon(y_n - f(x_n)) = \begin{cases} 0 & \text{za } |y_n - f(x_n)| < \epsilon \\ |y_n - f(x_n)| - \epsilon, & \text{inače} \end{cases}$$



Karakteristike SVM-a

- Jedna od najuspješnijih metoda strojnog učenja ukupno gledajući
- Popularna – linearni SVM + text mining
- U praksi – mnoge druge metode rade otprilike isto dobro
 - Postoji mnogo usporedbi koje to pokazuju

Važno je: Razumijevanje i iskustvo za efektivno korištenje

- Odabir kernela, odabir parametara (C, parametri kernela)
 - Minimalno potrebno - napraviti tzv. „grid search” eksperiment preko intervala parametara
- kombinirati sa selekcijom varijabli (postoje SVM varijante koje implicitne uključuju selekciju varijabli – min ∞ norme w)

Sažetak

- Definiranje plohe razdvajanja preko potpornih vektora
 - Potporna vektor = “kritične” točke (primjeri) najbliži plohi razdvajanja
- Optimizacija margine razdvajanja primjera različitih klasa – kvadratni optimizacijski problem s linearnim ograničenjima
- Pojam kernela:
 - Moćan alat za mapiranje u visoko-dimenzionalne prostore, kao i (re)definiranje metrika sličnosti

SVM literatura i materijali

The Elements of Statistical Learning

Hastie, Tibshirani, Friedman (1st ed - ch. 11)

A Tutorial on Support Vector Machines for Pattern Recognition
(1998) Christopher J. C. Burges

Christopher M. Bishop. Pattern recognition and machine learning,
Springer, 2006 .

Kristin P. Bennet and Campbell. Support Vector Machines: Hype or
Hallelujah? SIGKDD Explorations, vol. 2, 2000

Michael E. Mavroforakis and Sergios Theodoridis. A Geometric
Approach to Support Vector Machine (SVM)
Classification IEEE Transactions on Neural Networks, 2006

SVM Software preporuke

WEKA – SMO (Sequential Minimization Opt. - SVM)

R – e1071, kernlab – paketi

SVM-Light (T Joachims)

LibSVM (Chang & Lin)