


Strojno učenje

Metoda potpornih vektora
(SVM – Support Vector Machines)

Tomislav Šmuc


- **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, FDA, QDA
- Diskriminativne funkcije - $\delta_k(x)$ - funkcije koje određuju pripadnost nekoj klasi k

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


- 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 “kritičnih” 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*)
- Problem određivanja SV:
kvadratni optimizacijski problem (en. *quadratic programming*)




Separabilni i neseeparabilni 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



SVM – linearno separabilni podaci (2 klase)

Geometrijska intuicija - konveksna ljuska (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 – linearno separabilni podaci (2 klase)

Geometrijska intuicija - Konveksne ljuske

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

Zadatak

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




Formalizacija- određivanje maksimalne margine

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

Pojam - geometrijske margine

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



Udaljenost između plohe i točke x

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

Linearni SVM - izvod

- Pretpostavimo da vrijedi da se sve točke nalaze 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 (kvadratni optimizacijski problem uz ograničenja):

$$\min ||\mathbf{w}|| = \max (2/ ||\mathbf{w}||)$$

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:

$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w}$ - 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 linearna ograničenja (nejednakosti)
- Dobro poznati i rješivi problem – puno (više ili manje složenih) algoritama za njihovo rješavanje (MATLAB, MATHEMATICA)
- Standardno za SVM - prevođenje u *dualni problem* u kojem se tzv. *Lagrange-ovim multiplikatorima* (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 postoje:
 $\lambda = (\lambda_1, \lambda_2, \dots, \lambda_m)$ (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}_* :

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

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




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



Slučaj sa ograničenjem u obliku jednakosti



- $\times \Rightarrow \text{Min } f(\mathbf{x})$ (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 (konveksni problem):

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

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

SVM - optimizacijski problem

Dualna formulacija:

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

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

Te da vrijedi

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

$$(2) \lambda_i \geq 0 \quad \forall \alpha_i$$

Rješenje optimizacijskog problema

$$\mathbf{w} = \sum \lambda_i y_i \mathbf{x}_i \quad b = y_k - \mathbf{w}^T \mathbf{x}_k \text{ za bilo koji } \mathbf{x}_k \text{ za koji je } \alpha_k \neq 0$$


- Svaki α_i koji je različit od 0 – zapravo znači da je taj \mathbf{x}_i – potporni vektor.
- Konačno – klasifikacijska funkcija ima ovaj oblik:

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

- 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 također korišten produkt $\mathbf{x}_i^T \mathbf{x}_j$ između svih parova točaka skupa za učenje.

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:

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

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

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

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

- Dualni problem za SVM s “mekanom” marginom :

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

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

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):

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


$$b = y_k (1 - \xi_k) - \mathbf{w}^T \mathbf{x}_k \text{ gdje je } k = \arg \max_k \lambda_k$$

\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 $(\mathbf{w}\mathbf{x} + b = \sum \lambda_i y_i \mathbf{x}_i^T \mathbf{x} + b)$
 - Dodatno \Rightarrow 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 algoritmima
- Rješavani problem je kvadratni optimizacijski problem s linearnim ograničenjima .
- 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

$Q(\lambda) = \sum \lambda_i - \frac{1}{2} \sum \sum \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$ - 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 problem koji su linearno separabilni (i uz razumni 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-više-dimenzionalni prostor - gdje će naš problem biti (linearno) separabilan (rješiv)



“Kernel trik”

- Linearni SVM - skalarni produkt između vektora $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j$
- Transformacija kojom svaku točku mapiramo u neki novi prostor

$$\Phi: \mathbf{x} \rightarrow \phi(\mathbf{x})$$

- Sada bi skalarni produkt trebao izgledati drukčije:

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

- *Kernel funkcija* - funkcija koja korespondira nutarnjem produktu u nekom “ekspandiranom” prostoru novih varijabli

“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 $\phi(\mathbf{x}) = [1, x_1^2, \sqrt{2} x_1 x_2, x_2^2, \sqrt{2} x_1, \sqrt{2} x_2]$

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

Kerneli

- Zašto?
 - Omogućavaju pretvaranje neseparabilnih problema u separabilne.
 - Mapiranje u bolje (reprezentacijski) – višedimenzionalne prostore
- Uobičajeni kerneli
 - Linearni $K(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i^T \mathbf{x}_j)$
 - Polinomijalni $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^d$
 - 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





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

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



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-ostalim $\Rightarrow (K - 1)$ binarnih klasifikatora
- Svaki-protiv-svakog $\Rightarrow (K * (K - 1) / 2)$ 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 najboljih metoda strojnog učenja ukupno gledajući
- Popularna i vrlo dobri rezultati – text mining
- U praksi – mnoge druge metode rade otprilike isto dobro
 - Postoji mnogo komparacija koje to pokazuju

Važno je: Razumijevanje i iskustvo za efektivno korištenju

- Odabir kernela, odabir parametara (C, parametri kernela)
- Dobro je kombinirati selekciju varijabli i SVM u praktičnim primjerima
- RapidMiner, Matlab, R (više SVM varijanti + vizualizacija)

Sažetak

- Definiranje plohe razdvajanja preko potpornih vektora
 - Potporni vektor = “kritične” točke (primjeri) najbliži plohi razdvajanja
- Pojam kernela:
 - Moćan alat za mapiranje u visoko-dimenzionalne prostore, kao i (re)definiranje metrika sličnosti
- Samostalni paketi i okruženja koja imaju SVM:
 - SVM Torch; SVMLight; LibSVM
 - RapidMiner, WEKA, MATLAB, R
 - www.kernel-machines.org

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

A User's Guide to Support Vector Machines, Ben-Hur & Weston

T. Joachims, *Learning to Classify Text using Support Vector Machines*.
Kluwer, 2002.

Classic' Reuters data set: <http://www.daviddlewis.com/resources/testcollections/reuters21578/>