

# Strojno učenje

7

Linearne metode

&

SVM

Tomislav Šmuc

## Linearne metode

The Elements of Statistical Learning

Hastie, Tibshirani, Friedman (1st ed - ch. 4)

## SVM

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

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/>

**SVM Software:**

<http://www.kernel-machines.org/>


- Diskriminativni

(Učenje linije koja razdvaja klase)




- Generativni

Učenje modela za svaku pojedinu klasu



# Diskriminativna funkcije



## Fisherova linearna diskriminantna metoda

Skup  $N$   $d$ -dimenzionalnih primjera ( $\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots, \mathbf{x}_N$ ) – točaka

$N_1$  – broj primjera u podskupu  $D_1$  klase  $y_1$


$N_2$  – broj primjera u podskupu  $D_2$  klase  $y_2$

Tražimo linearnu funkciju od  $\mathbf{x}$  (t.j.  $\mathbf{w}$ ):

$$y = \mathbf{w}^t \mathbf{x}$$

Koja najbolje razdvaja dvije klase.

Osnovna ideja – naći projekciju na liniju u  $d$ - dimenzionalnom prostoru tako da se primjerci različitih klasa mogu na njkoj lako odvojiti



Neke veličine:

$$\boldsymbol{\mu}_i = \frac{1}{N_i} \sum_{\mathbf{x} \in D_i} \mathbf{x}$$

Srednja vrijednost u d-dimenzionalnom prostoru – za klasu  $i$

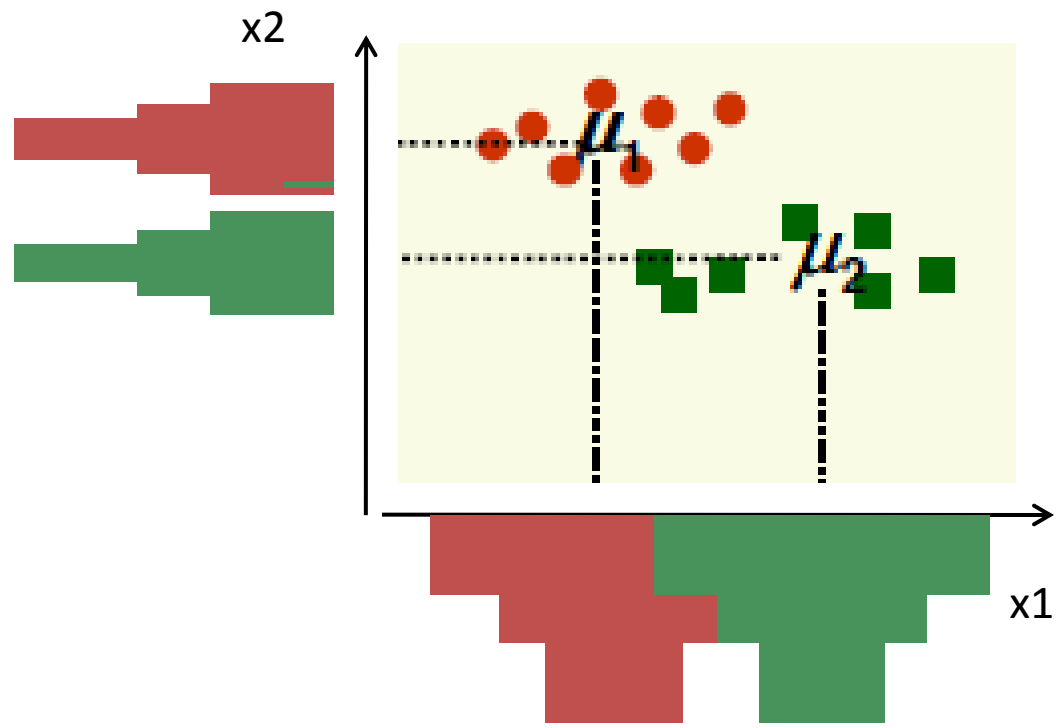
$$\bar{\mu}_i = \frac{1}{N_i} \sum_{y \in Y_i} y = \frac{1}{N_i} \sum_{x \in D_i} \mathbf{w}^t \mathbf{x} = \mathbf{w}^t \boldsymbol{\mu}_i$$

Srednja vrijednost za točke klase  $i$  projicirane na  $\mathbf{w}$

$$|\bar{\mu}_1 - \bar{\mu}_2| = |\mathbf{w}^t (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)|$$

Udaljenost između projiciranih srednjih vrijednosti za dvije klase


Koliko je dobra mjera separacije  $|\bar{\mu}_1 - \bar{\mu}_2|$  ?



Koja od osi je bolja za razdvajanje klasa, x1 ili x2 ?



Koliko je dobra mjera separacije  $|\bar{\mu}_1 - \bar{\mu}_2|$  ?



$x_2$  je bolja, no:

$$|\bar{\mu}_1 - \bar{\mu}_2|_{x_1} > |\bar{\mu}_1 - \bar{\mu}_2|_{x_2}$$

problem je što  $|\bar{\mu}_1 - \bar{\mu}_2|$

ne uzima u obzir varijancu

distribucije primjera.

Ako definiramo:

$$y_i = \mathbf{w}^t \mathbf{x}_i \quad \text{projicirani primjeri}$$


$$\tilde{s}_1^2 = \sum_{y_i \in Cl_1} (|y_i - \bar{\mu}_1|) \quad \text{“raspršenje” primjera klase1}$$

$$s_2^2 = \sum_{y_i \in Cl_2} (|y_i - \bar{\mu}_2|) \quad \text{“raspršenje” primjera klase2}$$

Možemo raspršenje koristiti za normalizaciju udaljenosti projiciranih “centara” između klasa !

- Moramo normalizirati koristeći raspršenje klase 1 i klase 2 !
- FLD dakle svodi se na pronalaženje projekcije na liniju  $\mathbf{w}$  koja maksimizira  $J(\mathbf{w})$ :

$$J(\mathbf{w}) = \frac{|\bar{\mu}_1 - \bar{\mu}_2|}{|\tilde{s}_1^2 + \tilde{s}_2^2|}$$



želimo da brojnik bude što veći



a nazivnik što manji!

$$J(w) = \frac{|\bar{\mu}_1 - \bar{\mu}_2|}{|\tilde{s}_1^2 + \tilde{s}_2^2|}$$

- Kako izraziti  $J(\mathbf{w})$  kao funkciju – radi se zapravo o optimizaciji  $J(\mathbf{w})$ ,  
- u ovisnosti o  $\mathbf{w}$  !
- Treba eksplicitno prikazati  $J$  u ovisnosti o  $\mathbf{w}$  !
- Definiramo matrice raspršenja za svaku klasu – prije projekcije - za originalne primjere

$$\mathbf{S}_1 = \sum_{\mathbf{x}_i \in Cl_1} (\mathbf{x}_i - \mu_1)(\mathbf{x}_i - \mu_1)^t$$

$$\mathbf{S}_2 = \sum_{\mathbf{x}_i \in Cl_2} (\mathbf{x}_i - \mu_2)(\mathbf{x}_i - \mu_2)^t$$

- Definiramo matricu raspršenja *unutar* klasa za svaku klasu

$$\mathbf{S}_W = \mathbf{S}_1 + \mathbf{S}_2$$

- Uz prethodnu definiciju

$$\tilde{s}_1^2 = \sum_{y_i \in Cl_1} (y_i - \bar{\mu}_1)^2$$

- I ako koristimo:

$$y_i = \mathbf{w}^t \mathbf{x}_i \quad \text{i} \quad \bar{\mu}_1 = \mathbf{w}^t \boldsymbol{\mu}_1$$

- Dobivamo:

$$\begin{aligned} \tilde{s}_1^2 &= \sum_{y_i \in Cl} (\mathbf{w}^t \mathbf{x}_i - \mathbf{w}^t \boldsymbol{\mu}_1)^2 \\ &= \sum_{y_i \in Cl} (\mathbf{w}^t (\mathbf{x}_i - \boldsymbol{\mu}_1))^t (\mathbf{w}^t (\mathbf{x}_i - \boldsymbol{\mu}_1)) \\ &= \sum_{y_i \in Cl} ((\mathbf{x}_i - \boldsymbol{\mu}_1)^t \mathbf{w})^t ((\mathbf{x}_i - \boldsymbol{\mu}_1)^t \mathbf{w}) \\ &= \sum_{y_i \in Cl} \mathbf{w}^t (\mathbf{x}_i - \boldsymbol{\mu}_1) (\mathbf{x}_i - \boldsymbol{\mu}_1)^t \mathbf{w} = \mathbf{w}^t \mathbf{S}_1 \mathbf{w} \end{aligned}$$

- Slično kao i za klasu 1

$$\tilde{s}_2^2 = \mathbf{w}^t \mathbf{S}_2 \mathbf{w}$$

- Dakle

$$\tilde{s}_1^2 + \tilde{s}_2^2 = \mathbf{w}^t \mathbf{S}_1 \mathbf{w} + \mathbf{w}^t \mathbf{S}_2 \mathbf{w} = \mathbf{w}^t \mathbf{S}_w \mathbf{w}$$

- Ako definiramo matricu raspršenja između klasa  $\mathbf{S}_B$  kao mjeru separacije između srednjih vrijednosti između klasa prije projekcije

$$\mathbf{S}_B = (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^t$$

- A razlika između projiciranih srednjih vrijednosti je:

$$\begin{aligned}(\bar{\mu}_1 - \bar{\mu}_2)^2 &= (\mathbf{w}^t \boldsymbol{\mu}_1 - \mathbf{w}^t \boldsymbol{\mu}_2)^2 \\&= \mathbf{w}^t (\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)^t \mathbf{w} \\&= \mathbf{w}^t \mathbf{S}_B \mathbf{w}\end{aligned}$$

- Na kraju je naša funkcija cilja

$$J(\mathbf{w}) = \frac{(\bar{\mu}_1 - \bar{\mu}_2)^2}{\tilde{s}_1^2 + \tilde{s}_2^2} = \frac{\mathbf{w}^t \mathbf{S}_B \mathbf{w}}{\mathbf{w}^t \mathbf{S}_W \mathbf{w}}$$

- Da bi je optimirali, našli maximum – prva derivacija po  $\mathbf{w}$  se mora izjednačiti s nulom

$$\frac{d}{d\mathbf{w}} J(\mathbf{w}) = 0$$

- Na koncu se to svede na problem određivanja svojstvenih vrijednosti

$$\Rightarrow \mathbf{S}_B \mathbf{w} = \lambda \mathbf{S}_W \mathbf{w}$$

$$\Rightarrow \mathbf{S}_B \mathbf{w} = \lambda \mathbf{S}_W \mathbf{w}$$

- Ako postoji inverzna matrica - nakon sređivanja:

$$\mathbf{w} = \mathbf{S}_W^{-1}(\boldsymbol{\mu}_1 - \boldsymbol{\mu}_2)$$

- Za potrebe klasifikacije - još je potrebno odrediti graničnu vrijednost  $t$ :

$$y_i = \mathbf{w}^t \mathbf{x}_i < t \Rightarrow y_1$$

$$y_i = \mathbf{w}^t \mathbf{x}_i \geq t \Rightarrow y_2$$



# Linearna diskriminativna analiza

- K klasa,  $\mathbf{X}$  (n x p) matrica podataka

$$p(c_k | \mathbf{x}) \propto p(\mathbf{x} | c_k, \theta_k)$$

- Svaka klasa se modelira kao multi-varijantna normalna distribucija

$$p(\mathbf{x} | c_k) = \frac{1}{(2\pi)^{p/2} |\boldsymbol{\Sigma}_k|^{1/2}} e^{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x} - \boldsymbol{\mu}_k)}$$

- LDA pretpostavlja da je  $\boldsymbol{\Sigma}_k = \boldsymbol{\Sigma}$  za sve  $k$ , pa vrijedi:


$$\log \frac{p(c_k | \mathbf{x})}{p(c_l | \mathbf{x})} = \log \frac{p(c_k)}{p(c_l)} - \frac{1}{2} (\boldsymbol{\mu}_k - \boldsymbol{\mu}_l)^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_k - \boldsymbol{\mu}_l) + \mathbf{x}^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu}_k - \boldsymbol{\mu}_l)$$

- U klasifikaciji – klasa se određuje prema – linearnoj diskriminantnoj funkciji :

$$\delta_k(\mathbf{x}) = \mathbf{x}^T \mathbf{\Sigma}^{-1} \boldsymbol{\mu}_k - \frac{1}{2} \boldsymbol{\mu}_k^T \mathbf{\Sigma}^{-1} \boldsymbol{\mu}_k + \log p(c_k)$$

i


$$klasa(\mathbf{x}) = \arg \max \delta_k(\mathbf{x})$$



LDA

QDA

# Koja hiper-ravnina je najbolja ?



## **SVM - Support Vector Machines**

### **– Metoda jezgrenih funkcija**

SVM – nalazi optimalnu ravninu razdvajanja


- Maksimizirajući udaljenost između hiperravnina i “kritičnih” točaka blizu ravnine razdvajanja (en. decision boundary)

Intuitivno:


Ako ne postoje točke blizu površine 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)
- Ustvari je funkcija odluke definirana 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






## 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  $\rightarrow y_i (\mathbf{w}^T \mathbf{x}_i + b)$
- Funkcionalna margina cijelog skupa točaka je  
 $\text{minimum } y_i (\mathbf{w}^T \mathbf{x}_i + b)$

# Pojam - geometrijske margine

- Udaljenost između plohe i točke  $x$
- Primjeri najbliže plohi su **potporni vektori**.
- **Margina**  $\rho$  plohe razdvajanja je širina razdvajanja između potpornih vektora suprotnih klasa

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



# Linearni SVM - izvod

- Pretpostavimo da vrijedi da se sve točke nalaze barem 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 (koji 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 - izvod

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:

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

$$\rho = \|\mathbf{x}_a - \mathbf{x}_b\|_2 = 2 / \|\mathbf{w}\|_2$$



# Linearni SVM - izvod

- Ovaj se problem može formulirati kao *kvadratni optimizacijski problem*:

Pronađi  $\mathbf{w}$  i  $b$  tako da je

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

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 - izvod

- Bolja formulacija – kao minimizacijski problem:

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

Naći  $\mathbf{w}$  i  $b$  - takve da je:

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

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

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

# Rješavanje optimizacijskog problema

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
- Dobro poznati i rješivi problem – puno (više ili manje složenih) algoritama za njihovo rješavanje (MATLAB, MATHEMATICA)
- Ustvari rješavanje se tipično radi nakon prevođenja u tzv. *dualni problem* u kjojem se tzv. *Lagrange-ovim multiplikatorima*  $\alpha_i$  penalizira svako ograničenje iz primarnog problema

# Rješavanje optimizacijskog problema

Dualna formulacija:

Naći  $\alpha_1 \dots \alpha_N$  tako da je:

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

Te da vrijedi

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

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



# Rješenje optimizacijskog problema

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


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

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

- 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  $\xi_i$  (*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  $\xi_i$  :

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  $\alpha_1 \dots \alpha_N$  tako da je

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

Te da vrijedi

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

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

- Ni  $\xi_i$  ali ni Lagrange-ovi multiplikatori se ne nalaze u dualnoj formulaciji!
- No, i dalje vrijedi:  $\mathbf{x}_i$  sa  $\alpha_i > 0$  – *su potporni vektori*.
- Rješenje dualnog problema (soft margin):

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

$$b = y_k (1 - \xi_k) - \mathbf{w}^T \mathbf{x}_k \quad \text{gdje je } k = \underset{k}{\operatorname{argmax}} \alpha_k$$

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

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


# 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  $(wx + b = \sum \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + b)$
  - Ako stavimo neku graničnu mjeru  $t > 0$  (pouzdanost)

$p > t: \Rightarrow 1$

$p < -t: \Rightarrow -1$

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  $\alpha_1 \dots \alpha_N$  tako da je

$Q(\alpha) = \sum \alpha_i - \frac{1}{2} \sum \sum \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$  - maksimalno i vrijedi:


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

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

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

# 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 ? :



TS: Strojno učenje – Linearne metode & SVM

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

$$\begin{aligned}
 K(\mathbf{x}_i, \mathbf{x}_j) &= (1 + \mathbf{x}_i^T \mathbf{x}_j)^2 = 1 + x_{i1}^2 x_{j1}^2 + 2 x_{i1} x_{j1} x_{i2} x_{j2} + x_{i2}^2 x_{j2}^2 + 2 x_{i1} x_{j1} + 2 x_{i2} x_{j2} = \\
 &= [1 \ x_{i1}^2 \ \sqrt{2} x_{i1} x_{i2} \ x_{i2}^2 \ \sqrt{2} x_{i1} \ \sqrt{2} x_{i2}]^T [1 \ x_{j1}^2 \ \sqrt{2} x_{j1} x_{j2} \ x_{j2}^2 \ \sqrt{2} x_{j1} \ \sqrt{2} x_{j2}] \\
 &= \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \quad \text{gdje je } \phi(\mathbf{x}) = [1 \ x_1^2 \ \sqrt{2} x_1 x_2 \ x_2^2 \ \sqrt{2} x_1 \ \sqrt{2} x_2]
 \end{aligned}$$

# Kerneli


- Zašto?
  - Omogućavaju pretvaranje neseparabilnih problema u separabilne.
  - Mapiranje u bolje (reprezentacijski) prostore
- Uobičajeni kerneli
  - Linearni
  - Polinomijalni  $K(\mathbf{x}, \mathbf{z}) = (1 + \mathbf{x}^T \mathbf{z})^d$
  - RBF  $K(\mathbf{x}_i, \mathbf{x}_j) = e^{\frac{-\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}}$

## Linearni SVM – efekt različitih vrijednosti parametra C





# Odabir kernela – efekti

## Polinmni kerneli ( $C=\text{const.}$ )





# Odabir parametara kernela – efekti









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

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



## Odabir parametara parametara kernela i faktora C



## Karakteristike SVM-a

- Po mnogima – najbolja metoda 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 prakti
- RapidMiner (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 software:
  - SVM Torch; SVMLight; LibSVM
  - RapidMiner, WEKA, MATLAB, R ....
  - [www.kernel-machines.org](http://www.kernel-machines.org)