

Masini cu suport vectorial

Support vector machines (SVM)

Ruxandra Stoean

rstoean@inf.ucv.ro

<http://inf.ucv.ro/~rstoean>

Bibliografie


- Catalin Stoean, Ruxandra Stoean, Support Vector Machines and Evolutionary Algorithms for Classification: Single or Together?, Intelligent Systems Reference Library, Volume 69, Springer, 2014.
- Simon O. Haykin , Neural Networks and Learning Machines (3rd Edition), Prentice Hall, 2008

Prezentare

- Unelte foarte puternice in:
 - Clasificare
 - Recunoasterea scrisului
 - Recunoasterea obiectelor
 - Recunoasterea vorbirii
 - Categorizare de texte
 - In principiu binara – metode de extindere pentru multe clase
 - Regresie
- Un tip de **masina instruibila supervizata**

- **Faza de antrenament:** invatare
(*exemplu* → *eticheta*)
- **Faza de test:** predictie asupra
(*exemplu nou* → ?)

Clasificare binara



- O multime de date de antrenament


$$\{(x_i, y_i)\}_{i=1,2,\dots,m} \quad x_i \in \mathbb{R}^n \quad y_i \in \{-1, +1\}$$

- O familie de functii


$$\{f_t \mid t \in T\} \quad f_t : \mathbb{R}^n \rightarrow \{-1, +1\}$$

- Gaseste parametrii t pentru a invata corespondenta optima intre fiecare x si y


Invatarea in cadrul SVM



Liniar separabile



Masini cu suport vectorial liniare




Liniar neseperabile




Masini cu suport vectorial liniare

Masini cu suport vectorial neliniare



SVM liniare pentru date separabile



Problema: Multe solutii!

Unele foarte proaste

Sarcina: Din datele disponibile, selecteaza hiperplanul care separa bine "in general"


Oricare dintre acestea ar fi bune...
Dar care este cel **mai bun**?

Cum se pot clasifica aceste date?

● reda +1

■ reda -1

SVM liniare pentru date separabile



Existenta unui hiperplan de
separatie cu ecuatia:
Doua submultimi sunt liniar
separabile daca si numai daca
exista $w \in \langle \mathbb{R}^n, x \rangle$ si $b \in \mathbb{R}$ a.i.:

$$\begin{cases} w \cdot x_i - b \geq 0, y_i = +1 \\ w \cdot x_i - b \leq 0, y_i = -1 \end{cases}$$

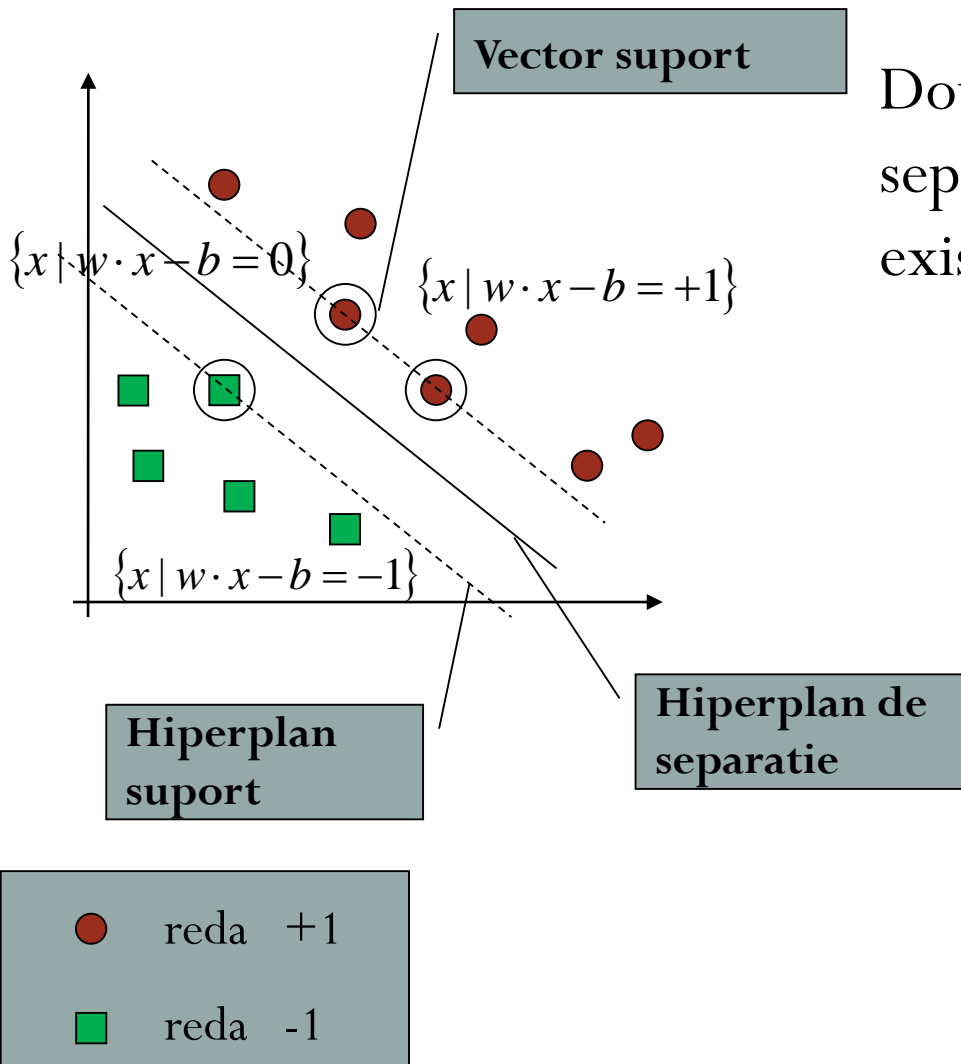
$$i = 1, 2, \dots, m$$

● reda +1

■ reda -1

- w – vectorul ponderilor
- b – bias (deplasare)

SVM liniare pentru date separabile



Doua submultimi sunt linear separabile daca si numai daca exista $w \in R^n$ si $b \in R$ a.i.:

$$\begin{cases} w \cdot x_i - b \geq +1, y_i = +1 \\ w \cdot x_i - b \leq -1, y_i = -1 \end{cases}$$

$$i = 1, 2, \dots, m$$

SVM liniare pentru date separabile

- O familie de functii:

$$\{f_{w,b} \mid w \in \mathbb{R}^n, b \in \mathbb{R}\} \quad f_{w,b} : \mathbb{R}^n \rightarrow \{-1, 1\} \quad f_{w,b}(x) = \text{sgn}(w \cdot x - b)$$

- O multime de date de antrenament:

$$\{(x_i, y_i)\}_{i=1,2,\dots,m} \quad x_i \in \mathbb{R}^n \quad y_i \in \{-1, +1\}$$

- Invata corespondenta optima

Principiul minimizarii riscului

- Pentru o sarcina de invatare, cu o anumita cantitate finita de date de antrenament, o masina este un bun **generalizator** daca:
 - Are o **acuratete** buna pe multimea de antrenament data
 - Are **capacitatea** de a invata si alte multimi de antrenament fara eroare

Hiperplanul optim la SVM liniare pentru date separabile

$w = ?$ si $b = ?$ a.i.

1. **Acuratete** $y_i(w \cdot x_i - b) - 1 \geq 0$

Latimea cu care granita dintre clase poate fi marita, pana la m ma lovi un exemplu


2. **Marginea de separatie maxima**

→ **minimizeaza** $\frac{\|w\|^2}{2}$ De ce?

Distanta de la fiecare cel mai apropiat punct de hiperplanul de separatie din cele doua parti ale sale este :

$$\frac{|w \cdot x_i - b|}{\|w\|} = \frac{1}{\|w\|} \Rightarrow \frac{2}{\|w\|} \rightarrow \text{maxim}$$

SVM liniare pentru date neseparabile




Cum separam aceste noi date?

Putem relaxa conditia de separare.

● reda +1

■ reda -1

SVM liniare pentru date neseparabile



Fiecare vector de antrenament are o deviatie de la hiperplanul sau suport de

$$\pm \frac{\xi_i}{\|w\|} \quad \xi_i \geq 0$$

●	reda +1
■	reda -1

$\xi_i = 0$ 1 Corect

$\xi_i < 1$ 2 Corect (in margine)

$\xi_i > 1$ 3 Eroare

Hiperplanul optim la SVM liniare pentru date neseparabile

- Se relaxeaza constrangerile :

$$y_i(w \cdot x_i - b) \geq 1 - \xi_i$$

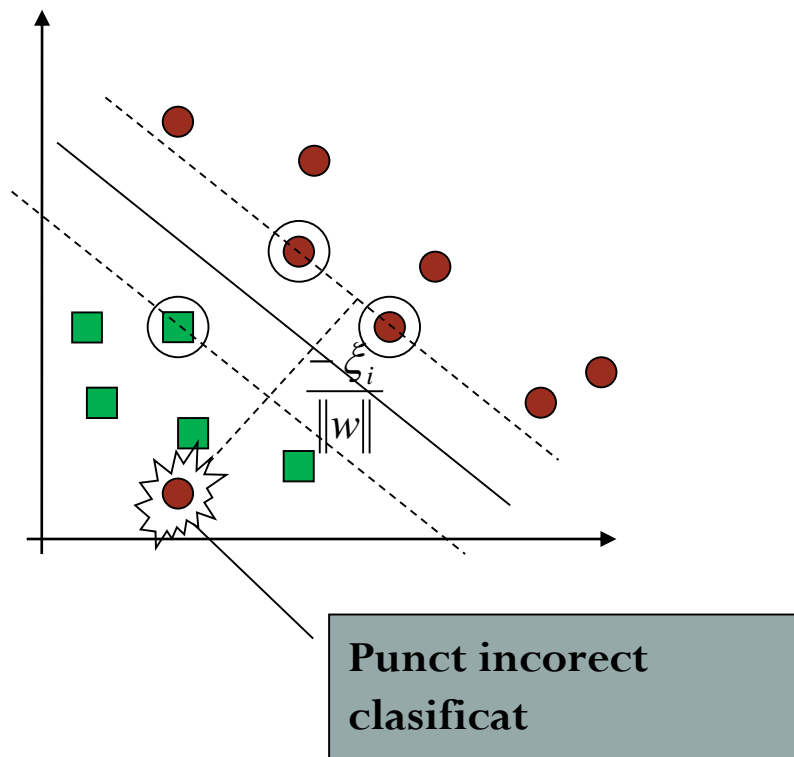
$$\xi_i \geq 0 \quad i = 1, 2, \dots, m$$

- Suma clasificarilor gresite trebuie minimizata impreuna cu maximizarea marginii de separatie:

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^m \xi_i$$

$C > 0$

SVM liniare pentru date neseparabile



● reda +1

■ reda -1

SVM neliniare


- Un spatiu de n dimensiuni poate fi transformat intr-un spatiu nou al trasaturilor unde

Se pot generaliza conceptele pentru a construi un hiperplan care sa nu fie o functie liniara?

- transformat

- dimensiune

SVM neliniare



Transformare neliniara

x - exemplu din spatiul de intrare

$\Phi : \mathcal{R}^n \rightarrow H$ - transformarea

Ar putea fi posibila existenta unei functii kernel $K...$

$$K(x, y) = \Phi(x) \cdot \Phi(y)$$

- Se transforma problema de optimizare in formulare duala.
Cum va fi perceputa transformarea la nivelul problemei de optimizare?
- In expresia duala, datele apar numai ca parte a unor produse scalare.
- In expresia determinarii hiperplanului optim in H , datele vor aparea, de asemenea, ca parte a unor produse scalare.

Transformarea neliniara

- Kernel – functie care exprima un produs scalar intr-un spatiu al trasaturilor.
- Convergenta masinilor cu suport vectorial catre o solutie impune ca o astfel de functie sa fie pozitiv (semi-)definita.
- Un astfel de kernel este unul care satisface teorema lui Mercer.
- Face imposibila detectarea de suprafete eficiente dar care nu o respecta.

Kernel

- Kernel – functie care exprima un produs scalar intr-un spatiu al trasaturilor.
- Exista kernele clasice pentru care s-a demonstrat respectarea conditiei lui Mercer:

- Kernelul polinomial: $K(x, y) = (x \cdot y)^p$

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

Rezolvarea problemei de optimizare

- Se bazeaza pe notiuni de convexitate.
- Se construiesc Lagrangianul si se aplica conditiile Karush-Kuhn-Tucker-Lagrange (KKTL).
- Se construiesc duala problemei de optimizare.
- Se egaleaza gradientul noii functii obiectiv cu 0 si se rezolva sistemul rezultat.
- w si b rezulta din conditiile KKTL, daca se pot calcula;
 - daca nu, masina cu suport vectorial va determina direct clasa pentru vectorii de test.
- Semnul lui $f_{w,b}$ da clasa finala – pozitiva sau negativa.

SVM pentru mai multe clase

- In utilizarea standard, SVM este o masina instruibila pentru probleme binare (cu doua clase).
- In extinderea la mai multe clase (k), exista doua tehnici clasice:
 - One-against-all (Unul impotriva tuturor)
 - One-against-one (Unu la unu)

One-against-all (1aa)

- Se construiesc k clasificatori SVM.
 - Pentru al i -lea SVM, clasa i este pozitiva si celelalte impreuna reprezinta clasa negativa.
- Fiecare al i -lea SVM determina hiperplanul optim de coeficienti w^i si b^i .
- Eticheta pentru un exemplu nou este data de clasa care are valoarea maxima pentru functia invatata f_{w^i, b^i} .

One-against-one (1a1)

- Se construiesc $k(k-1)/2$ clasificatoare SVM pentru fiecare doua clase pe rand.
 - Clasa i este clasa pozitiva, iar j cea negativa
- Se determina hiperplanul de decizie intre fiecare doua clase i si j cu coeficientii w^{ij} si b^{ij} .
- Eticheta pentru un exemplu nou se determina prin vot.
 - Pentru fiecare SVM se calculeaza clasa exemplului, care primeste un vot.
 - Castiga clasa cu cele mai multe voturi obtinute.

SVM pentru regresie

- In acest caz, datele sunt constranse sa se afle pe un hiperplan care
 - Permite o anumita eroare ϵ fata de iesirile reale
 - Are abilitate mare de generalizare
- Pentru cazul liniar:

$$\begin{cases} y_i - w \cdot x_i + b \leq \epsilon \\ w \cdot x_i - b - y_i \leq \epsilon \end{cases} \quad i = 1, 2, \dots, m$$

- si minimizeaza $\|w\|^2$

Problema de optimizare - regresie

- Pentru cazul general al datelor neseparabile:

$$\begin{cases} y_i - w \cdot x_i + b \leq \varepsilon + \xi_i \\ w \cdot x_i - b - y_i \leq \varepsilon + \xi_i^* \end{cases} \quad \xi_i, \xi_i^* \geq 0$$

- si minimizeaza $\|w\|^2 + C \sum_{i=1}^m (\xi_i + \xi_i^*) \quad C > 0$
- Aplicarea de kernele este similara cu cea in cazul clasificarii.
- Functia $f_{w,b}$ rezultata da iesirea prognozata pentru un nou exemplu.

SVM in R. Clasificare (1/4)

```
library(e1071) # pentru SVM
library(mlbench) # pentru baza de date cu diabet
data(PimaIndiansDiabetes)
dat <- PimaIndiansDiabetes

# De 30 de ori vom partitiona aleator baza in antrenament si test
# pentru validare incrucisata (cross-validation)
repeats <- 30
classColumn <- 9
accuracies <- vector(mode="numeric",length=10) # cele 30 de
acurateti obtinute
```

SVM in R. Clasificare (2/4)

```
index <- 1:nrow(dat)
for(i in 1:repeats) {
  testindex <- sample(index, trunc(length(index)/4)) # 25%
  date in test/75% in antrenament
  testset <- dat[testindex, ]
  trainset <- dat[-testindex, ]

  svm.model <- svm(diabetes ~ ., data = trainset, kernel =
"linear", cost = 1)
  svm.pred <- predict(svm.model, testset[, -classColumn])
  contab <- table(pred = svm.pred, true = testset[,
classColumn])
  accuracies[i] <- classAgreement(contab)$diag
}
```

SVM in R. Clasificare (3/4)

```
print(accuracies)
```

```
print(mean(accuracies)) # media acuratetilor
```

```
print(sqrt(var(accuracies))) # deviatia standard
```

```
print(summary(accuracies))
```

```
print("Un exemplu de matrice de confuzie")
```

```
print(contab) # cate date din fiecare clasa au fost prognozate in  
clasa respectiva, respectiv duse in clasa opusa
```

SVM in R. Clasificare (4/4)

```
> print(accuracies)
[1] 0.7708333 0.7864583 0.7031250 0.8177083 0.7708333
[6] 0.7812500 0.7812500 0.7239583 0.7760417 0.7500000
[11] 0.7812500 0.8125000 0.8020833 0.7500000 0.7031250
[16] 0.7604167 0.7864583 0.8385417 0.7552083 0.8072917
[21] 0.7968750 0.7864583 0.7083333 0.8020833 0.7656250
[26] 0.7395833 0.7604167 0.7760417 0.7916667 0.7812500
> print(mean(accuracies))
[1] 0.7722222
> print(sqrt(var(accuracies)))
[1] 0.0330519
> print(summary(accuracies))
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.7031 0.7565 0.7786 0.7722 0.7904 0.8385
>
> print("Un exemplu de matrice de confuzie")
[1] "Un exemplu de matrice de confuzie"
> print(contab)
      true
pred  neg pos
neg 117  29
pos  13  33
```

- Rezultatul programului:
 - Acuratetile in cele 30 de rulari.
 - Acuratetea in medie.
 - Deviatia standard.
 - Sumarul privind acuratetea in cele 30 de rulari.
 - Matricea de confuzie:
 - Pe linie – predictia
 - Pe coloana - realitatea

SVM in R. Regresie (1/4)

```
library(e1071)
```

```
library(mlbench)
```

```
data(BostonHousing)
```

```
classColumn <- 14
```

```
# o singurara rulare cu multimile de antrenament si test alese aleator
```

```
random <- sample(1:506, replace = FALSE)
```

```
randomTrain <- random[1:380]
```

```
randomTest <- random[381:506]
```

```
train <- BostonHousing[randomTrain,]
```

```
test <- BostonHousing[randomTest,]
```

SVM in R. Regresie (2/4)

```
svm.model <- svm(medv ~ ., data = train, kernel = "radial",  
epsilon = 0)
```

```
svm.pred <- predict(svm.model, test[, -classColumn])
```

```
summary(svm.pred)
```

Eroarea RMS (root mean square error - RMSE) pentru n date
cu valorile prognozate P_i si cele reale R_i .

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - R_i)^2}$$

```
RMSE <- sqrt(mean((svm.pred - test[, classColumn])^2))
```

```
print(RMSE)
```


SVM in R. Regresie (3/4)

#calculeaza corelatia dintre prognozat si real

Coeficientul de corelatie al lui Pearson masoara gradul de potrivire intre iesirile modelului si cele reale.

#Coeficientul de corelatie bazat pe rang al lui Spearman este calculat drept cel al lui Pearson pentru variabilele ierarhizate.

```
cor.test(svm.pred, test[, classColumn], method = "spearman")
```

```
cor.test(svm.pred, test[, classColumn], method = "pearson")
```

SVM in R. Regresie (4/4)

```
> summary(svm.pred)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 8.552 17.270  21.730  23.120  27.840  47.730
>
> RMSE <- sqrt(mean((svm.pred - test[, classColumn])^2))
> print(RMSE)
[1] 4.565229
>
> #calculeaza corelatia dintre prognozat si real
>
> cor.test(svm.pred, test[, classColumn], method = "spearman")

spearman's rank correlation rho

data:  svm.pred and test[, classColumn]
S = 19023.73, p-value < 2.2e-16
alternative hypothesis: true rho is not equal to 0
sample estimates:
      rho
0.942936

Warning message:
In cor.test.default(svm.pred, test[, classColumn], method = "spearman") :
  Cannot compute exact p-values with ties
> cor.test(svm.pred, test[, classColumn], method = "pearson")

Pearson's product-moment correlation

data:  svm.pred and test[, classColumn]
t = 21.9085, df = 124, p-value < 2.2e-16
alternative hypothesis: true correlation is not equal to 0
95 percent confidence interval:
 0.8489145 0.9225224
sample estimates:
      cor
0.891457
```

- Rezultatul programului:
 - Eroare RMS mica.
 - Testele Pearson si Spearman indica potrivire aproape perfecta (aproape de 1) intre valorile reale si cele prognozate de model cu valoarea p de ordinul e-16.

Exercitii

- Implementati in R un model de clasificator SVM pentru problema diagnozei cancerului de san (Wisconsin breast cancer diagnosis) [1] din pachetul R mlbench [2].
- Implementati in R un model SVM de regresie pentru problema bacsisului din cursul anterior.

[1] [https://archive.ics.uci.edu/ml/datasets/Breast+Cancer+Wisconsin+\(Original\)](https://archive.ics.uci.edu/ml/datasets/Breast+Cancer+Wisconsin+(Original))

[2] <http://cran.r-project.org/web/packages/mlbench/mlbench.pdf>