

Mașinile cu vectori suport

Mașinile cu vectori suport (engl. “Support Vector Machines”, SVM) reprezintă o metodă de învățare de nouă generație (Shawe-Taylor & Cristianini, 2000), cu o fundamentare matematică riguroasă, bazată pe conceptul de maximizare a „marginii” care separă instanțele din două clase diferite, iar maximizarea este rezolvată analitic, nu empiric. Datorită acestei fundamentări, mașinile cu vectori suport au demonstrat performanțe foarte bune pentru probleme reale cum ar fi clasificarea textelor, recunoașterea caracterelor scrise de mână, clasificarea imaginilor etc. În general, SVM-urile sunt considerate unele dintre cele mai bune metode de clasificare cunoscute la ora actuală.

Mașinile cu suport vectorial sunt o clasă de algoritmi supervizați de învățare automată care utilizează concepte din teoria învățării computaționale. Suportul este o suprafață de separare optimă tipic neliniară în spațiul de intrare și liniară într-un spațiu cu mai multe dimensiuni.

Trei idei principale:

- Se definește ce este un hiperplan optimal (într-un mod care poate fi identificat printr-o cale eficientă computațional): maximizează marginea
- Extinde definiția de mai sus pentru probleme liniar neseperabile: are un termen de penalizare pentru clasificări eronate
- Proiectează datele într-un spațiu cu mai multe dimensiuni unde este mai simplă clasificarea cu suprafețe de decizie liniare: reformulează problema astfel încât datele sunt proiectate implicit în acest spațiu

Istoria SVM

- SVM sunt legate de teoria învățării statistice
- SVM au fost introduse în 1992
- SVM au devenit populare datorită succeselor în recunoașterea cifrelor scrise de mână
- SVM sunt privite azi ca un exemplu important de “metode kernel”, unul din domeniile cheie ale mașinilor instruibile

Hiperplane de separare. Marginea dintre clase

Să considerăm mai întâi o problemă de clasificare binară cu clase separabile liniar (Figura 1).




Figura 1. Problema de clasificare cu clase separabile linear.

Un clasificator poate împărți planul cu o dreaptă în două suprafețe și prin urmare poate rezolva corect această problemă.

Dreapta separatoare poate avea parametri diferiți, după cum se arată în Figura 2. Toate aceste drepte rezolvă problema de clasificare considerată.




Figura 2. Drepte de separare posibile.

Având mai multe opțiuni la dispoziție, se pune problema care dintre acestea este cea mai bună, criteriul luat în calcul fiind capacitatea de generalizare a modelului, adică posibilitatea acestuia de a clasifica în mod corect instanțe noi.

Odată găsită o dreaptă de separare între instanțele de antrenare, putem spune că este destul de probabil ca o nouă instanță (1, 2) să aparțină clasei pătratelor iar una (7, 7) să aparțină clasei cercurilor. Probleme vor apărea în zona de demarcație dintre cele două clase. Pentru o instanță (3, 4), folosind două modele diferite, vom avea rezultate diferite, după cum se poate vedea în figura 3: o dreaptă o clasifică drept cerc iar cealaltă dreaptă – drept pătrat.




Figure 3. Drepte de separare diferite pot determina rezultate diferite.

Una din ideile de bază ale mașinilor cu vectori suport este că modelul care generalizează cel mai bine este acela care desparte cel mai mult clasele, adică cel care asigură marginea cea mai mare de demarcație între clase. Marginea este distanța dintre dreptele paralele cu dreapta de separare care ating cel puțin una din instanțele fiecărei clase. Pentru cele două modele din figura 3, marginea dată de dreapta 1 este cea din figura 4a iar marginea dată de dreapta 2 este cea din figura 4b.

1.




Figura 4. Marginile generate de doua drepte de separare diferite.

Se vede că marginea determinată de primul model este mai mare, prin urmare acesta este mai bun decât celălalt.

În cazul de față, problema de clasificare are 2 atribute și suprafața de separare este o dreaptă care împarte planul în 2 semiplane. Dacă problema ar fi avut 3 atribute, suprafața de separare ar fi fost un plan care împarte în două spațiul tridimensional. În general, hiperspațiul nD corespunzător unei probleme cu n atribute este împărțit în două de către un hiperplan $(n - 1)D$.

Reprezentarea matematica

Pentru a formaliza această descriere, să considerăm că o suprafață de separare este descrisă de următoarea ecuație:

$$(\mathbf{w} \cdot \mathbf{x}) + b = 0,$$

Unde w și x sunt vectori iar b este un scalar.

$(\mathbf{w} \cdot \mathbf{x})$ este produsul scalar al celor doi vectori, adică:

$$(\mathbf{w} \cdot \mathbf{x}) = w_1x_1 + \dots + w_nx_n,$$

unde n este dimensiunea lor.

Exemplu:




Figure 5. Drepte cu diferite ecuatii.

În figura 5, ecuația primei drepte este:

$$x_2 = 1 - x_1 \Rightarrow x_1 + x_2 - 1 = 0.$$

Considerăm aici că numele axelor sunt x_1, x_2 etc., întrucât y are o semnificație deosebită, indicând clasa unei instanțe și nu un atribut (corespunzător unei axe de coordonate).

Analog, ecuațiile următoarelor două drepte sunt:

$$x_1 + x_2 - 2 = 0,$$

respectiv:

$$x_1 + x_2 - 3 = 0.$$

În aceste cazuri, $w = (1, 1)$ iar b diferă. Dreptele cu aceeași orientare w sunt paralele iar translația este dată de termenul b .

A patra dreaptă nu este paralelă cu celelalte trei; aici $w = (2, 5)$ iar $b = -20$. w este un vector perpendicular pe dreapta corespunzătoare sau, în general, pe suprafața de separare considerată.

Reprezentarea problemei pentru SVM presupune ca ecuațiile suprafețelor de separare să fie normalizate, astfel încât în limitele care trec prin vectorii suport ai celor două clase să fie

$$(\mathbf{w} \cdot \mathbf{x}) + b = -1$$

respectiv

$$(\mathbf{w} \cdot \mathbf{x}) + b = 1$$

(figura 6).

Instanțele de pe aceste două suprafețe se numesc vectori suport, care dau și numele metodei.

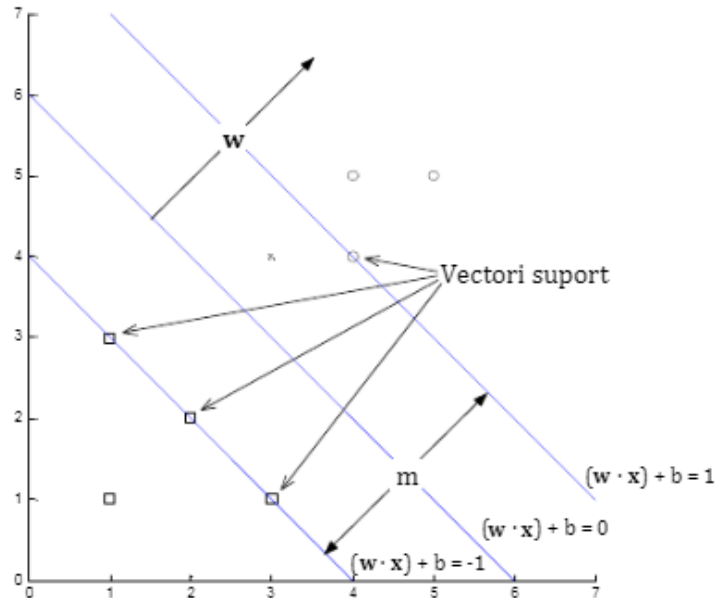


Figura 6. Vectorii suport și ilustrarea botiunilor caracteristice problemei.

Clasificarea propriu-zisă presupune determinarea parametrilor w (en. weights) și b (en. bias) care maximizează marginea de separare dintre clase. Apoi, o instanță nouă z va fi clasificată în una din cele două clase (-1 sau 1) cu ajutorul funcției discriminant:

$$f_d(\mathbf{z}) = \text{sgn}((\mathbf{w} \cdot \mathbf{z}) + b),$$

unde

$$\text{sgn}(a) = \begin{cases} -1, & \text{dacă } a < 0 \\ 1, & \text{dacă } a \geq 0 \end{cases}$$

Fie y_i clasa instanței i . Odată determinați parametrii w și b , următoarele relații trebuie respectate:

$$(\mathbf{w} \cdot \mathbf{x}_i) + b \leq -1 \text{ dacă } y_i = -1,$$

$$(\mathbf{w} \cdot \mathbf{x}_i) + b \geq 1 \text{ dacă } y_i = 1.$$

De exemplu, pentru clasa 1, instanțele de pe dreapta-graniță a marginii vor avea cantitatea

$$(\mathbf{w} \cdot \mathbf{x}_i) + b$$

egală strict cu 1, fiind vectori suport, iar celelalte instanțe din aceeași clasă, mai depărtate de margine, vor avea cantitatea respectivă mai mare strict decât 1.

Mai compact, constrângerile din ecuațiile de mai sus pot fi scrise astfel:

$$y_i ((\mathbf{w} \cdot \mathbf{x}_i) + b) \geq 1.$$

Din figura 7, putem observa că marginea m este de fapt proiecția distanței dintre oricare doi vectori suport \mathbf{x}_1 și \mathbf{x}_2 pe direcția vectorului \mathbf{w} .




Figura 7. Ilustrarea modalității de calcul a marginii.

Prin urmare, valoarea lui m se poate obține de exemplu scăzând ecuațiile vectorilor \mathbf{x}_1 și \mathbf{x}_2 :

$$\begin{aligned} (\mathbf{w} \cdot \mathbf{x}_1) + b &= -1 \\ (\mathbf{w} \cdot \mathbf{x}_2) + b &= 1 \\ \Rightarrow (\mathbf{w} \cdot (\mathbf{x}_2 - \mathbf{x}_1)) &= 2 \\ \Rightarrow m &= \frac{\mathbf{w}}{\|\mathbf{w}\|} \cdot (\mathbf{x}_2 - \mathbf{x}_1) = \frac{2}{\|\mathbf{w}\|}, \end{aligned}$$

unde $\|\cdot\|$ este norma euclidiană, adică lungimea vectorului considerat:

$$\|\mathbf{w}\| = \sqrt{w_1^2 + \dots + w_n^2}.$$

Exemplu:

În situația din figura 7, marginea m este în mod evident distanța dintre punctele $(1, 1)$ și $(3, 3)$:

$$m = \sqrt{(3-1)^2 + (3-1)^2} = 2\sqrt{2} = 2,83.$$

Însă aceeași valoare se obține proiectând distanța dintre $x_1(3,-1)$ și $x_2(1,5)$ pe direcția $w(1,1)$.

De fapt, distanța dintre oricare 2 puncte situate pe cele 2 drepte paralele proiectată pe direcția lui w poate fi utilizată pentru a ajunge la același rezultat.

Exemplu de aplicare a algoritmului SVM pe un set de date

```
from sklearn.svm import SVC
model=SVC(kernel='linear',gamma=1)
url = "https://raw.githubusercontent.com/jbrownlee/Datasets/master/pima-indians-diabetes.data.csv"
names = ['preg', 'plas', 'pres', 'skin', 'test', 'mass', 'pedi', 'age', 'class']
import pandas
dataframe = pandas.read_csv(url, names=names)
array = dataframe.values
X = array[:,0:8]
Y = array[:,8]
test_size = 0.33
seed = 7
from sklearn import model_selection
X_train, X_test, Y_train, Y_test = model_selection.train_test_split(X,
Y, test_size=test_size, random_state=seed)
model.fit(X_train, Y_train)
model.score(X_test, Y_test)
```