

SVEUČILIŠTE U ZAGREBU  
**FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA**

SEMINAR

**Metode prepoznavanja tematike teksta na osnovu  
sadržaja**

Ana Beblek  
Barbara Carević

Voditelj: Mr. sc. Mile Šikić

2008.

## **Sadržaj**

1	Uvod.....	3
2	Klasifikacija teksta.....	4
2.1	Definicija klasifikacije teksta.....	4
2.2	Single label i multilabel klasifikacija teksta .....	4
2.3	Hard i soft klasifikacija teksta.....	5
2.4	Dokumentno orientirana klasifikacija teksta (DPC) i kategorijski orientirana klasifikacija teksta (CPC) .....	5
3	Metode odabira svojstava .....	6
3.1	Učestalost dokumenta .....	6
3.2	Informacijska dobit .....	6
3.3	Mjera uzajamne informacije .....	7
3.4	$\chi^2$ statistika.....	8
3.5	Povezanost riječi .....	8
4	Metoda k-najbližih susjeda .....	10
4.1	Algoritam k-najbližih susjeda .....	11
4.2	Modifikacija algoritma k–najbližih susjeda uvođenjem težinskih faktora .....	12
4.3	Karakteristike algoritma k – najbližih susjeda.....	12
5	Stabla odluke.....	13
5.1	Problemi prikladni za rješavanje pomoću stabla odluke.....	13
5.2	Predstavljanje stabla odluke.....	13
5.3	Osnovni algoritam učenja stabla odluke .....	15
5.4	Karakteristike algoritma ID3 .....	17
6	Naivni Bayesov klasifikator.....	18
6.1	Bayesov teorem.....	18
6.2	Naivni Bayesov klasifikator – teorija .....	19
6.3	Primjena Naivnog Bayesovog klasifikatora u klasifikaciji teksta .....	20
6.4	Karakteristike Naivnog Bayesovog klasifikatora .....	21
7	Metoda potpornih vektora - SVM.....	22
7.1	Klasifikator s maksimalnom marginom.....	23
7.2	Metoda potpornih vektora sa slabom marginom .....	26
7.3	Karakteristike metodu potpornih vektora (SVM).....	28
8	Umjetne neuronske mreže.....	29
8.1	Model umjetne neuronske mreže .....	29
8.2	Topologija neuronskih mreža .....	31
8.3	Učenje .....	31
9	Testiranje.....	33
10	Literatura.....	36

## **Kazalo slika**

Slika 1. Primjer klasifikacije knn algoritmom za k=3 i k=5 .....	11
Slika 2. Dijagram stabla odluke .....	14
Slika 3. Primjer stabla odluke .....	14
Slika 4. Rad stabla odluke .....	15
Slika 5. Primjer entropije .....	16
Slika 6. Preslikavanje pokaznih uzoraka iz ulaznog prostora (eng. <i>input space</i> ) u $N$ -dimenzionalni prostor $F$ (eng. <i>feature space</i> ) .....	22
Slika 7. Klasifikator s maksimalnom marginom.....	23
Slika 8. Slojevi umjetne neuronske mreže .....	29
Slika 9. Topologija neuronskih mreža .....	31

## **Kazalo tablica**

Tablica 1. Decizijska matrica.....	4
Tablica 2. Usporedni rezultati različitih klasifikatora ispitanih na pet različitih verzija baza novinskih članaka Reuters. Oznaka "F1" označava uporabu F1 mjere učinkovitosti (van Rijsbergen, 1972, 1979 [8]; Lewis, 1995 [9]), oznaka "M" označava makro usrednjavanje (eng. <i>macroaverage</i> ).....	34

## **1 Uvod**

Klasifikacija teksta prema sadržaju je problem koji je postao aktualan u posljednje vrijeme zbog velike količine dostupnih tekstova u elektroničkom obliku. Smatra se da je danas preko 80% informacija pohranjeno u tekstualnom obliku., zbog te velike i brzo rastuće količine podataka isključeno je korištenje ljudi na tom poslu pa se krenulo prema metodama za automatsku klasifikaciju teksta. Klasifikacija teksta je jedan od problema dubinske analize teksta (eng. *text mining*), koja je interdisciplinarno polje istraživanja dubinske analize podataka (eng. *data mining*), dohvata podataka (eng. *informational retrieval*), strojnog učenja (eng. *machine learning*), statistike i računalne lingvistike (eng. *computational linguistics*).

U ovom seminaru je dan pregled najvažnijih metoda za automatsku klasifikaciju teksta u predefinirane kategorije.

## 2 Klasifikacija teksta

### 2.1 Definicija klasifikacije teksta

Neka je  $C = \{c_1, c_2, \dots, c_m\}$  skup predefiniranih kategorija (klasa) i  $D = \{d_1, d_2, \dots, d_n\}$  skup dokumenata. Klasifikacija teksta je proces dodjeljivanja vrijednosti svakom paru  $\{d_j, c_i\} \in D \times C$ . Ta vrijednost može biti tipa Boolean, nula ako dokument ne pripada u tu kategoriju i jedan ako pripada ili u rasponu od 0 do 1, gdje vrijednost određuje prikladnost neke određene kategorije.

Pridruživanje se može predstaviti decizijskom matricom.

Tablica 1. Decizijska matrica

	$d_1$	...	$d_j$	...	$d_n$
$c_1$	$a_{11}$	...	$a_{1j}$	...	$a_{1n}$
...	...	...	...	...	...
$c_i$	$a_{i1}$	...	$a_{ij}$	...	$a_{in}$
...	...	...	...	...	...
$c_m$	$a_{m1}$	...	$a_{mj}$	...	$a_{mn}$

Formalno klasifikacija teksta je proces aproksimacije nepoznate ciljne funkcije, koja opisuje kako bi dokumenti trebali biti klasificirani, pomoću funkcije  $\Phi : D \times C \rightarrow \{T, F\}$  (klasifikator, pravilo, hipoteza, model)

Nazivi kategorija nisu bitni, to su samo simboličke labele koje ne utječu na klasifikaciju, sva klasifikacija se vrši samo iz podataka dobivenih iz samog dokumenta.

### 2.2 Single label i multilabel klasifikacija teksta

Kategorije se mogu i ne moraju preklapati, tj. jedan dokument može pripadati u više kategorija.

Razlikujemo dva slučaja. Single-label TC (eng. *single-label text categorization*) je slučaj kad svakom dokumentu može biti dodijeljena samo jedna kategorija, kategorije se ne preklapaju. Multilabel TC (eng. *multilabel text categorization*) je slučaj kad bilo koji broj kategorija može biti dodijeljen istom dokumentu, svaki dokument može imati nula, jednu ili više kategorija. Kategorije se preklapaju. Metode klasifikacije za single-label TC u

multilabel TC se ponešto razlikuju, pa je jako bitno dovoljno rano odrediti koja je prikladnija za određeni problem.

### **2.3 Hard i soft klasifikacija teksta**

Ukoliko se donosi binarna odluka pripada li dokument određenoj kategoriji, to se naziva čvrsta (eng. *hard*) kategorizacija teksta. Mekana (eng. *soft*) kategorizacija ocjenjuje prikladnost neke kategorije dokumente, pridružujući mu brojčanu vrijednost između 0 i 1.

### **2.4 Dokumentno orijentirana klasifikacija teksta (DPC) i kategoriski orijentirana klasifikacija teksta (CPC)**

Kod dokumentno orijentirane klasifikacije (eng. *category-pivoted categorization*) za odabrani dokument  $d_j \in D$ , pronalaze se sve kategorije  $c_i \in C$  gdje bi se on trebao svrstati, decizijska matrica se popunjava po redcima. Kod kategoriski orijentirane klasifikacije (eng. *document-pivoted categorization*) za odabranu  $c_i \in C$  kategoriju se pronalaze svi dokumenti  $d_j \in D$  koji joj pripadaju, decizijska matrica se popunjava po stupcima. Razlika je bitna jer skupovi  $D$  i  $C$  nisu uvek od početka dostupni. DPC je pogodniji kada dokumenti postaju dostupni jedan po jedan (e-mail), dok je CPC prikladniji pri dodavanju novih kategorija  $c$  u skup  $C$  postojećih kategorija, nakon što je dio dokumenata već klasificiran (klasificiranje web stranica). U praksi je CPC većinom bolja opcija.

### **3 Metode odabira svojstava**

Metode odabira svojstava za pojedine algoritme za klasifikaciju teksta igraju važnu ulogu pri klasifikaciji. Odabirom svojstava povećava se učinkovitost algoritama. Mnogi algoritmi imaju poteškoće pri klasifikaciji teksta s velikim prostorom svojstava (eng. *feature space*) koji se može smanjiti primjenom metoda. U nastavku slijedi opis najvažnijih metoda odabira svojstava.

#### **3.1 Učestalost dokumenta**

Učestalost dokumenta (eng. *document frequency - DF*) je broj dokumenata u kojima se pojavljuje određeni izraz (riječ ili fraza). Prilikom kategorizacije teksta, izbacuju se oni izrazi čiji je DF je manji od definiranog praga. Prepostavlja se da takvi izrazi ne utječu na kategorizaciju, a njihovim uklanjanjem se pridonosi smanjenju prostora svojstava, time i povećanju točnosti kategorizacije. Ova metoda odabira svojstava je najjednostavnija, ali predstavlja ad hoc pristup povećanju efikasnosti kategorizacije.

#### **3.2 Informacijska dobit**

Informacijska dobit (eng. *information gain - IG*) predstavlja rezultat statističkog testa koji se računa na osnovu prisutnosti određenog izraza u dokumentu. Često označava kriterij za dobrotu (eng. *goodness*) izraza u području strojnog učenja.

Neka  $\{c_i\}_{i=1}^m$  označava grupu kategorija u ciljnem prostoru. Informacijska dobit  $G$  izraza  $t$  jednaka je:

$$\begin{aligned} G(t) = & - \sum_{i=1}^m P_r(c_i) \log P_r(c_i) \\ & + P_r(t) \sum_{i=1}^m P_r(c_i | t) \log P_r(c_i | t) \\ & + P_r(t) \sum_{i=1}^m P_r(c_i | t) \log P_r(c_i | t) \end{aligned} \quad [1]$$

Informacijska dobit se izračunava za svaki pojedini izraz te se iz prostora svojstava se izbacuju oni izrazi koji imaju čija je informacijska dobit manja od predefinirane vrijednosti. Prilikom izračuna uzima se u obzir procjena uvjetnih vjerojatnosti kategorije određenog izraza, te vrijednost entropije. Vremensku složenost procjene vjerojatnosti iznosi  $O(N)$ , a prostorna složenost  $O(VN)$ , gdje  $N$  označava broj dokumenata u skupu za učenje, a  $V$  veličinu rječnika izraza. Vremensku složenost proračuna entropije je  $O(Vm)$

### 3.3 Mjera uzajamne informacije

Mjera uzajamne informacije (eng. *mutual information* -  $MI$ ) je metoda koja mjeri međusobnu ovisnost dviju varijabli.

Da bi objasnili metodu potrebno je definirati:

- $t$  – izraz
- $c$  – kategorija
- $A$  - broj pojavljivanja izraza  $t$  u kategoriji  $c$
- $B$  - broj pojavljivanja izraza  $t$  u drugim kategorijama
- $C$  – broj kategorija u kojima se ne pojavljuje izraz  $t$
- $N$  – ukupan broj dokumenata

Definicija mjera uzajamne informacije između  $t$  i  $c$  glasi:

$$I(t, c) = \log \frac{P_r(t \wedge c)}{P_r(t) \times P_r(c)} \quad [2]$$

a njena vrijednost se procjenjuje pomoću:

$$I(t, c) \approx \log \frac{A \times N}{(A + C) \times (A + B)} \quad [3]$$

Ako su  $t$  i  $c$  nezavisni, vrijednost  $I(t, c)$  je nula.

Dobrota izraza pri odabiru svojstava se računa tako da se uzme u obzir izračun mjere za pojedine kategorije na slijedeći način:

$$I_{\text{avg}}(t) = \sum_{i=1}^m P_r(c_i) I(t, c_i) \quad [4]$$

$$I_{\text{max}}(t) = \max_{i=1}^m \{I(t, c_i)\} \quad [5]$$

Vremenska složenost mjera uzajamne informacije je  $O(Vm)$ .

Nedostatak ove metode predstavlja veliki utjecaj rubne vjerojatnosti izraza na izračun mjere, kao što se može vidjeti iz slijedećeg izraza:

$$I(t, c) = \log P_r(t | c) - \log P_r(t) \quad [6]$$

Ako je uvjetnom vjerojatnost  $P_r(t | c)$  među izrazima jednaka, izrazi će rijetko imati veću mjeru od uobičajenih izraza. Stoga, ne možemo uspoređivati vrijednost mjere među izrazima koji imaju vrlo veliku razliku u učestalosti u kategorijama.

### 3.4 $\chi^2$ statistika

$\chi^2$  statistika (eng. *CHI*) mjeri nedostatak neovisnosti između izraza  $t$  i kategorije  $c$ .

Da bi objasnili metodu potrebno je definirati:

- $t$  – izraz
- $c$  – kategorija
- $A$  - broj pojavljivanja izraza  $t$  u kategoriji  $c$
- $B$  - broj pojavljivanja izraza  $t$  u drugim kategorijama
- $C$  – broj kategorija u kojima se ne pojavljuje izraz  $t$
- $D$  - broj izraza u kategoriji kada se ne pojavljuju niti  $t$  niti  $c$
- $N$  – ukupan broj dokumenata

Dobrota izraza je definirana izrazom:

$$\chi^2(t, c) = \frac{N \times (AD - CB)^2}{(A + C) \times (B + D) \times (A + B) \times (C + D)} \quad [7]$$

Ako su  $t$  i  $c$  nezavisni, vrijednost  $\chi^2$  statistike je nula.

Računanjem  $\chi^2$  statistike između svakog pojedinog izraza i određene kategorije dolazimo do izraza za računanje  $\chi^2$  statistike po kategorijama:

$$\chi^2_{\text{avg}}(t) = \sum_{i=1}^m P_r(c_i) \chi^2(t, c_i) \quad [8]$$

$$\chi^2_{\text{max}}(t) = \max_{i=1}^m \{\chi^2(t, c_i)\} \quad [9]$$

$\chi^2$  statistika ima kvadratnu prostornu složenost.

Velika razlika između  $\chi^2$  statistike i mjera uzajamne informacije je što se između različitih izraza  $t$  u istoj kategoriji  $c$ ,  $\chi^2$  vrijednosti mogu uspoređivati. Ali, to svojstvo ne vrijedi kod izraza koji imaju malu učestalost u kategorijama.

### 3.5 Povezanost riječi

Povezanost riječi (eng. *term strength - TS*) predstavlja vjerojatnost da će se izraz pojaviti u usko povezanim dokumentima. Dokumenti u skupu za učenje izdvajaju se u parove ako je njihova sličnost iznad određene vrijednosti. Povezanost riječi se računa pomoću procjene uvjetne vjerojatnosti da se izraz pojavljuje u drugom dijelu para povezanih dokumenata ako se pojavljuje u prvom.

Neka su  $x$  i  $y$  proizvoljan par različitih, ali povezanih dokumenata, a neka je  $t$  izraz. Onda je definicija snage izraza:

$$s(t) = P_r(t \in y \mid t \in x) \quad [10]$$

Ova mjera odabira svojstava je potpuno različita od gore navedenih mjer. Zasniva se na grupiranju dokumenata uz pretpostavku da su dokumenti koji sadrže mnoge slične riječi i sami slični, a te riječi sadrže velik dio informacije. Ova metoda ne uzima u obzir povezanost između izraza i kategorije. Po tome je slična metodi učestalosti dokumenata, a znatno se razlikuje od, na primjer, informacijske dobiti ili mjere uzajamne informacije.

## 4 Metoda k-najbližih susjeda

Metoda k-najbližih susjeda potpada pod metode učenja na temelju primjera. Primjeri su pohranjeni, a postupak generalizacije je odgođen do trenutka potrebe za klasifikacijom novog uzorka. Tada se određuje vrijednost ciljne funkcije ispitivanjem odnosa novog uzorka prema pohranjenom primjeru. Takve metode kod kojih se odluka o klasifikaciji odgađa do predočavanja novog primjera nazivaju se lijene metode (eng. *lazy methods*).

U algoritmu k-najbližih susjeda primjeri su točke u n-dimenzionalnom prostoru  $R_n$ . Udaljenost između primjera se računa Euklidskom metrikom, a ciljna funkcija može imati diskretne ili realne vrijednosti.

Primjer  $x$  je opisan vektorom značajki

$$\langle a_1(x), a_2(x), \dots, a_n(x) \rangle$$

gdje je  $a(x)$  označava k-ti atribut primjera  $x$ .

Euklidska udaljenost između dva vektora  $x_i$  i  $x_j$  je:

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (a_r(x_i) - a_r(x_j))^2} \quad [11]$$

Za ciljnu funkciju s diskretnim vrijednostima vrijedi:

$$f : R_n \rightarrow V$$

gdje je  $V = \{v_1, v_2, \dots, v_s\}$ .

Za ciljnu funkciju s realnim vrijednostima  $f : R_n \rightarrow R$  se umjesto najčešće pojavljivanje vrijednosti ciljne funkcije uzima srednja vrijednost ciljnih funkcija  $k$  najbližih susjeda.

$$f(x_q) \leftarrow \frac{\sum_{i=1}^k f(x_i)}{k} \quad [12]$$

Decizijska funkcija vraća pripadnost grupi primjera kojoj pripada najviše od  $k$  susjeda testnog primjera, ako je  $k=1$ , testni primjer se klasificira kao i njegov najbliži susjed. U praksi je  $k$  često neparan broj da bi se izbjegli slučajevi da jednak broj susjeda pripada u više grupe.

## 4.1 Algoritam $k$ -najbližih susjeda

### Algoritam za učenje:

- Za svaki primjer za učenje  $(x, f(x))$  dodaj primjer na listu primjeri\_za\_učenje

### Algoritam klasifikacije:


- Za dani primjer  $x_q$  s nepoznatom klasifikacijom
  - Neka  $x_1, x_2, \dots, x_k$  označavaju  $k$  primjera koji su najbliži  $x_q$
  - Vrati

$$f(x_q) \leftarrow \arg \max_{v \in V} \sum_{i=1}^k \delta(v, f(x_i)) \quad [13]$$

$f(x_q)$  je najčešća vrijednost ciljne funkcije koja se pojavljuje među  $k$  primjera za učenje koji su najbliži primjeru  $x_q$ .

### Primjer rada algoritma

Testni primjer se u zavisnosti od odabranog  $k$  različito klasificira. Zajedno s trokutima za  $k=3$  i s kvadratima za  $k=5$ .



Slika 1. Primjer klasifikacije knn algoritmom za  $k=3$  i  $k=5$

## 4.2 Modifikacija algoritma $k$ -najbližih susjeda uvođenjem težinskih faktora

Budući da je algoritam radi na intuitivnoj pretpostavci da su objekti s najmanjom udaljenosti potencijalno slični, poboljšanje algoritma koje se samo nameće je uvođenje težinskih faktora. Za svaki od  $k$  susjeda, uvodi se težinski faktor  $w_i$  koji ovisi o njegovoj udaljenosti od upita  $x_q$ .

Vrijednost decizijске funkcije određuje se formulom:

$$f(x_q) \leftarrow \arg \max_{v \in V} \sum_{i=1}^k w_i \delta(v, f(x_i)) \quad [14]$$

gdje je

$$w_i \equiv \frac{1}{d(x_q, x_i)^2} \quad [15]$$

Ako se testni primjer poklapa s primjerom za učenje, tj udaljenost između njih je jednaka nuli, testni primjer se klasificira jednakom kao taj primjer za učenje. Ukoliko je više primjera koji se preklapaju, uzima se klasifikacija većine primjera.

Modifikacija za slučaj kontinuirane ciljne funkcije:

$$f(x_q) \leftarrow \frac{\sum_{i=1}^k w_i f(x_i)}{\sum_{i=1}^k w_i} \quad [16]$$

gdje je težinski faktor  $w_i$  definiran kao i za prethodni slučaj.

Zbog uvođenja težinskih algoritama udaljeni primjeri će imati vrlo malo utjecaja na klasifikaciju. Metode kod kojih se svi primjeri uzimaju u obzir kod klasifikacije, nazivaju se globalnim. Ako se uzima ograničeni broj primjera, onda je to lokalna metoda. Ovakva globalna metoda naziva se Shepardova metoda.

## 4.3 Karakteristike algoritma $k$ – najbližih susjeda

Prednosti algoritma su robusnost na šum u primjerima za učenje i efikasnost ako je skup primjera za učenje dovoljno velik. Glavni nedostatak je induktivna pristranost, prepostavlja se da je klasifikacija upita slična klasifikaciji primjera u blizini. Udaljenost se računa na temelju svih atributa, što dovodi do kletve dimenzionalnosti (eng. *curse of dimensionality*), tj. osjetljivosti algoritma na sve attribute, bez obzira na njihov broj i značaj za ciljnu funkciju. Rješenje je množenje atributa s faktorima da bi se smanjio utjecaj nevažnih atributa. Drastičniji pristup je potpuno uklanjanje nevažnih atributa. Također je problem velika složenost izvođenja, zbog toga je potrebno ostvariti efikasno indeksiranje memorije.

## **5 Stabla odluke**

Stabla odluke su metoda za aproksimiranje funkcije diskretnih vrijednosti. Robusna su na šum i mogu učiti i disjunktne izraze. Jedna su od najčešćih i najpraktičnijih metoda induktivnog zaključivanja. Induktivna pristranost stabla odluka je u preferiranju malih stabala u odnosu na velika. Stabla odluke pretražuju potpun prostor hipoteza.

### **5.1 Problemi prikladni za rješavanje pomoću stabla odluke**

Stabla odluke su najbolja za rješavanje problema sa sljedećim karakteristikama:

- Primjeri su predstavljeni parovima atribut-vrijednost, pogotovo ako je skup vrijednosti koje može poprimit atribut malen, moguće je prilagoditi algoritam da radi i sa kontinuiranim vrijednostima atributa.
- Ciljna funkcija poprima diskrete vrijednosti, moguće je prilagoditi algoritam da radi i s realnim vrijednostima.
- Rješenje problema zahtjeva disjunktni izraz. Stabla odluke prirodno predstavljaju disjunktni izraz.
- Primjeri za učenje sadržavaju pogreške. Stabla odluke su robusna i na pogreške u klasifikaciji primjera za učenje i na pogreške u vrijednostima atributa primjera za učenje.
- Primjerima za učenje nedostaju neke vrijednosti atributa. Stabla odluke se mogu koristiti ako postoje nepoznate vrijednosti atributa.

Naučene funkcije su predstavljene kao stabla odluke ili kao skup ako-onda pravila radi čitljivosti i preglednosti.


### **5.2 Predstavljanje stabla odluke**

Stablo odluke predstavlja disjunkciju konjunkcije uvjeta na vrijednosti atributa.. Svaki put od korijena stabla do lista korespondira s konjunkcijom vrijednosti atributa, a stablo je disjunkcija ovih konjunkcija.

Klasifikacija primjera se vrši odozgo, od korijena prema listovima. Svaki čvor na stablu predstavlja testiranje određenog atributa primjera, a svaka grana koja izlazi iz tog čvora predstavlja jednu od vrijednosti za taj atribut.


## Dijagram

- Svaki čvor koji nije list je povezan sa testom koji skup mogućih vrijednosti atributa dijeli na podskup koji odgovara različitim rezultatima testa.
- Svaka grana prenosi rezultate određenog testa na sljedeći čvor
- Svaki čvor je povezan sa skupom mogućih rezultata testa
- Za m atributa stablo odluke smije imati visinu manju ili jednaku m.



Slika 2. Dijagram stabla odluke


**Primjer :** Da li je vrijeme pogodno za golf?



Slika 3. Primjer stabla odluke

### 5.3 Osnovni algoritam učenja stabla odluke

Stablo odluke se konstruira promatrajući pravilnosti u podacima :



Slika 4. Rad stabla odluke

Temeljni algoritam učenja stabla odluke je ID3 (eng. *Induction of Decision Trees*), proširenje tog algoritma je C4.5.

#### ID3:

- Testira se svaki atribut da se ocjeni kako dobro klasificira primjere
- Najbolji se odabire kao čvor, a njegove vrijednosti su silazne grane
- Primjeri za učenje se sortiraju prema odgovarajućem silaznom čvoru (niz onu granu koja odgovara vrijednosti tog atributa)
- Cijeli postupak se ponavlja koristeći primjere koji su dodijeljeni silaznom čvoru

ID3 spada u pohlepne algoritme (eng. *greedy algorithm*), jer se nikad ne vraća zbog ponovnog razmatranja prethodnih čvorova.

Potrebno je odabrati koji atribut će se testirati u pojedinom čvoru stabla.

Informacijska dobit (eng. *information gain*) je mjera kako dobro pojedini atribut dodjeljuje primjere za učenje u skladu s ciljnom klasifikacijom. Informacijsku dobit računamo pomoću entropiju, koja mjeri homogenost primjera.

Ako je:

$n_b$  - broj primjera u grani b

$n_{bc}$  - broj primjera u grani b klase c, naravno  $n_{bc}$  je jednaki ili manji od  $n_b$

$n_t$  - ukupni broj primjera u svim granama

Vjerojatnost:

$P_b$  - vjerojatnost da je primjer u grani b pozitivan

$$P_b = \frac{\text{broj pozitivnih primjera na grani}}{\text{ukupni broj primjera na grani}} = \frac{n_{bc}}{n_b}$$


- Ako su svi primjeri na grani pozitivni, onda je  $P_b = 1$  (homogeno pozitivan)
- Ako su svi primjeri na grani negativni, onda je  $P_b = 0$  (homogeno negativan)

Entropija:

$$\text{Entropija} = \sum_c -\left(\frac{n_{bc}}{n_b}\right) \log_2 \left(\frac{n_{bc}}{n_b}\right) \quad [17]$$

- Entropija varira između 0 i 1
- $\text{Entropija} = 0$  ako je skup potpuno homogen
- $\text{Entropija} = 1$  ako je skup potpuno nehomogen

Primjer entropije za skup od 6 primjera koji mogu pripadati u dvije klase:



Slika 5. Primjer entropije

Srednja entropija:

$$Srednja\_entropija = \sum_b \left( \frac{n_b}{n_t} \right) \times \left[ \sum_c - \left( \frac{n_{bc}}{n_b} \right) \log_2 \left( \frac{n_{bc}}{n_b} \right) \right] \quad [18]$$

Informacijska dobit primjera A u odnosu na skup primjera S:

$$Informacijska\_dabit(S, A) = Entropija(S) - \sum_{v \in Vrijednost(A)} \frac{|S_v|}{|S|} Entropija(S_v) \quad [19]$$

*Vrijednost(A)* – skup svih mogućih vrijednosti skupa A

*S<sub>v</sub>* – podskup od S za koji atribut A ima vrijednost v, tj.  $S_v = \{s \in S | A(s) = v\}$

Za čvor u stablu biramo atribut s najvećom informacijskom dobiti i nastavljamo dalje s algoritmom.

#### 5.4 Karakteristike algoritma ID3

Algoritam ID3 je induktivno pristran na dva načina, izabire kraće stablo prije nego dulje stablo i atribut s većom informacijskom dobiti stavlja bliže korijenu stabla.

Može doći do prenaučenosti (eng. *overfit*) stabla odluke.

##### Definicija prenaučenosti:

Neka je dan prostor hipoteza  $H$ . Hipoteza  $h \in H$  je prenaučena ako postoji hipoteza  $h' \in H$  takva da:

$h$  ima manju pogrešku nego  $h'$  na primjerima na učenje, ali  $h'$  ima manju pogrešku nego  $h$  na cijelom prostoru primjera.

Prenaučenost se rješava zaustavljanjem rasta stabla prije savršene klasifikacije i naknadnim podrezivanjem stabla, što je i bolji pristup.

## 6 Naivni Bayesov klasifikator

Probabilistički pristup indukciji znanja temelji se na indukciji znanja Bayesovim učenjem. Osnovna ideja je da se vrijednosti promatranih atributa instanci ravnaju po određenim razdiobama vjerojatnosti, te da se optimalno zaključivanje o novoj instanci može izvesti iz tih vjerojatnosti primijenjenih na njene attribute.

### 6.1 Bayesov teorem

Bayesov teorem se temelji na odabiru najvjerojatnije hipoteze iz skupa hipoteza  $H$  na osnovu skupa za učenje  $D$ , a uz utjecaj predodređenih vjerojatnosti svake od ponuđenih hipoteza u skupu  $H$ .

Da bi objasnili teorem potrebno je definirati vjerojatnosti:

- $P(h)$  - a priori vjerojatnost hipoteze . Apriorna vjerojatnost hipoteze može biti "objektivna" kada se temelji na stvarnom eksperimentu ili "subjektivna" kada se temelji na pretpostavci. Ukoliko vrijednost vjerojatnosti nije poznata može se svim hipotezama pridijeliti jednaka početna vjerojatnost.
- $P(D)$  - vjerojatnost pojavljivanja instance  $D$ .
- $P(D|h)$  - uvjetna vjerojatnost pojavljivanja instance i ako je hipoteza  $h$  točna.
- $P(h|D)$  - posteriorna vjerojatnost točnosti hipoteze  $h$  nakon pojavljivanja instance  $D$ .  $P(h|D)$  omogućava procjenu točnosti hipoteza nakon promatranja pojave novih instanci  $D$ , za razliku od a priori vjerojatnosti  $p(h)$ , koja je neovisna o pojavi podatka  $D$ .

Formula Bayesovog teorema glasi:

$$P(h | D) = \frac{P(D | h)P(h)}{P(D)} \quad [20]$$

Najčešće je potrebno izračunati maksimalnu aposteriornu hipotezu (MAP)  $h \in H$ , hipotezu s najvećom vjerojatnošću  $h_{MAP}$  nakon što se dogodio određeni događaj  $D$ :

$$\begin{aligned} h_{MAP} &= \arg \max_{h \in H} P(h | D) \\ &= \arg \max_{h \in H} \frac{P(D | h)P(h)}{P(D)} \\ &= \operatorname{argmax}_{h \in H} P(D | h)P(h) \end{aligned} \quad [21]$$

U posljednjem retku je izbačen  $P(D)$  iz nazivnika jer on ne ovisi o hipotezi  $h$ .

U slučajevima kada a priori vjerojatnosti hipoteza  $h$  jednake, možemo zanemariti utjecaj parametra  $P(h)$  i procjenjujemo samo na osnovu  $P(D|h)$ . Veličina  $h_{MAP}$  se pojednostavljuje na slijedeći način:

$$h_{MAP} = \arg \max_{h \in H} P(D | h) \quad [22]$$

Premda ovakav klasifikator dokazano polučuje najbolju klasifikaciju, problematičan je i neprimjenjiv u velikom broju slučajeva zbog vrlo velikog broja trening instanci potrebnih kako bi se izračunale uvjetne vjerojatnosti kojima se barata. Stoga se u praktičnoj primjeni koristi pojednostavljeni oblik Bayesovog klasifikatora nazvan Naivni Bayesov klasifikator.

## 6.2 Naivni Bayesov klasifikator – teorija

Naivni Bayesov klasifikator se primjenjuje u slučajevima gdje se primjer podatka za učenje može prikazati kao konjunkcija atributa koji mogu poprimiti određeni (konačan) skup vrijednosti ( $a_1, a_2, \dots, a_n$ ). Uvodimo pojam najvjerojatnije klasifikacije  $v_{MAP}$  koji predstavlja najvjerojatniji element konačnog skupa  $V$  svih mogućih klasifikacija ulazne instance i može se računati po izrazu:

$$v_{MAP} = \arg \max_{v_j \in V} P(v_j | a_1, a_2 \dots a_n) \quad [23]$$

Prethodni izraz možemo raspisati po Bayesovom teoremu:

$$v_{MAP} = \arg \max_{v_j \in V} \frac{P(a_1, a_2 \dots a_n | v_j) P(v_j)}{P(a_1, a_2 \dots a_n)} \quad [24]$$

$$v_{MAP} = \arg \max_{v_j \in V} P(a_1, a_2 \dots a_n | v_j) P(v_j) \quad [25]$$

Vjerojatnost  $P(v_j)$  nije problem izračunati jednostavnim pobrojavanjem pojavljivanja tražene rezultantne klasifikacije. Problem dolaze s izračunom izraza  $P(a_1, a_2 \dots a_n | v_j)$  zbog međusobne zavisnosti vrijednosti atributa  $a_1, a_2 \dots a_n$  tako da je broj mogućih  $P(a_1, a_2 \dots a_n | v_j)$  izraza jednak broju svih mogućih različitih n-torki pomnoženih sa brojem svih mogućih klasifikacija. Da bi se odredile  $P(a_1, a_2 \dots a_n | v_j)$  za sve moguće kombinacije vrijednosti atributa potrebna je ogromna količina podataka u setu za učenje. Stoga se uvodi daljnje pojednostavljenje koje se bazira na tzv. "naivnoj pretpostavci" da su pojave vrijednosti različitih atributa međusobno nezavisne:

$$P(a_1, a_2 \dots a_n | v_j) = \prod_i P(a_i | v_j) \quad [26]$$

Primjenom Bayesovog teorem dobivamo formulu:

$$v_{NB} = \arg \max_{v_j \in V} P(v_j) \prod_i P(a_i | v_j) \quad [27]$$

Broj različitih vjerojatnosti  $P(a_i | v_j)$  koje treba izračunati iz podataka sada je mnogo manji broj nego broj potreban kako bi se dobila  $P(a_1, a_2 \dots a_n | v_j)$ .

### **6.3 Primjena Naivnog Bayesovog klasifikatora u klasifikaciji teksta**

U praktičnoj upotrebi Naivni Bayesov klasifikator je pokazao korisnost zbog jednostavnosti implementacije i polučenih zadovoljavajućih rezultata. Jedan od najčešćih primjena je klasifikacija odnosno filtriranje e-mail poruka (anti-spam softver).

#### **Primjer klasifikacije dokumenata na osnovu sadržaja**

Pregledavanjem sadržaja poruka izdvajamo atribute  $w_i$  (u našem slučaju riječi) gdje se vjerojatnost da će se riječ  $w_i$  određenog dokumenta svrstati u klasifikaciju  $v_j$  može se napisati kao  $P(a_i | v_j)$ . Pretpostavljanjem međusobne nezavisnosti atributa dolazimo do izraza vjerojatnosti dokumenta  $D$ :

$$P(D | v_j) = \prod_i P(w_i | v_j) \quad [28]$$

Prema teoriji vjerojatnosti gornji izraz možemo napisati kao:

$$P(D | v_j) = \frac{P(D \cap v_j)}{P(v_j)} \quad [29]$$

ili

$$P(v_j | D) = \frac{P(D \cap v_j)}{P(D)} \quad [30]$$

Primjenom Bayesovog teorema na gornji izraz dobivamo:

$$P(v_j | D) = \frac{P(v_j)}{P(D)} P(D | v_j) \quad [31]$$

Ako klasifikaciju  $v_j$  svedemo samo na dvije vrijednosti S i  $\neg S$  (spam e-mail poruka i legitimna e-mail poruka) dolazimo do izraza:

$$P(D | S) = \prod_i P(w_i | S) \quad [32]$$

odnosno

$$P(D | \neg S) = \prod_i P(w_i | \neg S) \quad [33]$$

Koristeći prethodno izvedene izraze možemo napisati:

$$P(S | D) = \frac{P(S)}{P(D)} \prod_i P(w_i | S) \quad [34]$$

i

$$P(\neg S | D) = \frac{P(\neg S)}{P(D)} \prod_i P(w_i | \neg S) \quad [35]$$

Dijeljenjem dobivamo:

$$\frac{P(S | D)}{P(\neg S | D)} = \frac{P(S)}{P(\neg S)} \frac{\prod_i P(w_i | S)}{\prod_i P(w_i | \neg S)} = \frac{P(S)}{P(\neg S)} \prod_i \frac{P(w_i | S)}{P(w_i | \neg S)} \quad [36]$$

Budući vrijedi da je  $p(S | D) + p(\neg S | D) = 1$ , možemo izračunati vjerojatnost  $P(S|D)$  na slijedeći način:

$$\ln \frac{P(S | D)}{P(\neg S | D)} = \ln \frac{P(S)}{P(\neg S)} + \sum_i \ln \frac{P(w_i | S)}{P(w_i | \neg S)} \quad [37]$$

Dakle, poruka se klasificira kao spam e-mail poruka za  $\ln \frac{P(S | D)}{P(\neg S | D)} > 0$


#### 6.4 Karakteristike Naivnog Bayesovog klasifikatora

Dобра strana ove metode je brzina, čak i za velike skupove podataka. U teoriji Bayesov klasifikator u odnosu na druge klasifikatore ima minimalnu pogrešku, međutim u praksi to često nije tako. Najveći nedostatak ove metode je u temeljnoj *naivnoj* prepostavci da je djelovanje nekog atributa na pripadnost uzorka pojedinom razredu neovisno o djelovanju drugih atributa, odnosno da su atributi međusobno neovisni, što u praksi nije uvek istina.

## 7 Metoda potpornih vektora - SVM

Metoda potpornih vektora, odnosno algoritam *SVM* (eng. *Support Vector Machines*) spada u grupu jezgrenih metoda klasifikacije. Temelji se na principu strukturne minimizacije rizika koji pronalazi hipotezu  $h$  za koju se može garantirati najmanja vjerojatnost pogreške na skupu za učenje.

Metoda potpornih vektora vrši klasifikaciju preslikavanjem skupa pokaznih uzoraka iz ulaznog prostora uzoraka  $\Re_N$  (eng. *input space*) u  $N$ -dimenzionalni prostor  $F$  (eng. *feature space*) koji optimalno razdvaja uzorce u dvije kategorije. Nakon što se vektor uzorka  $x$  preslika u prostor  $F$  funkcijom  $\Phi$ , u novom prostoru se određuje kojoj kategoriji novi vektor  $\Phi(x)$  pripada. Kategorije razdvaja hiperravnina razdvajanja. Optimalna hiperravnina je ona s maksimalnom granicom razdvajanja između uzoraka dvaju razreda.



**Slika 6.** Preslikavanje pokaznih uzoraka iz ulaznog prostora (eng. *input space*) u  $N$ -dimenzionalni prostor  $F$  (eng. *feature space*)

Zadan je skup pokaznih uzoraka  $\{x_1, \dots, x_l\}$ , koji ima  $l$  elemenata. Kategorija kojemu pripada  $i$ -ti uzorak označen je s  $y_i$  i može biti  $\pm 1$ . Skup uzoraka se preslikava nelinearnim mapiranjem u  $N$ -dimenzionalni prostor  $F$ :

$$\Phi: \Re_N \rightarrow F$$

Novi uzorci, čija kategorija nije poznata, razvrstavaju se u prostor  $F$  funkcijom odlučivanja  $f$  koja glasi:

$$f(\mathbf{x}) = \text{sign}((\mathbf{w}\mathbf{x}) + b) = \pm 1, \quad [38]$$

gdje je  $(\mathbf{w}\mathbf{x}) + b = 0$ ,  $\mathbf{w} \in \Re_N$ ,  $b \in R$  kategorija hiperravnina.

Vektor  $w$  jednak je  $w = \sum_i v_i x_i$ , gdje vektori  $x_i$  predstavljaju primjere koji su najbliže hiperravnini, a nazivaju se potporni vektori.

Budući potporni vektori nose informacije o problemu razvrstavanja, funkcija odlučivanja  $f$  glasi:

$$f(x) = \operatorname{sign}\left(\sum_i v_i (x x_i) + b\right) = \pm 1 \quad [39]$$

Sada se u prostoru  $F$  računaju se skalarni produkti  $k(x, x_i) = \Phi(x) \Phi(x_i)$ , gdje je  $k$  funkcija jezgre, a težine  $v_i$  se određuju rješavanjem kvadratnih jednadžbi.

Kategorija uzorka se određuje s:


$$f(x) = \operatorname{sign}\left(\sum_i v_i k(x x_i) + b\right) = \pm 1 \quad [40]$$

## 7.1 Klasifikator s maksimalnom marginom

Prepostavimo da je skup pokaznih uzoraka, odnosno skup za učenje linearno razdvojiv, tj. da postoji hiperravnina  $(w, b)$  tako da za sve primjere skupa vrijedi:

$$y_i (\langle w | x_i \rangle + b) > 0 \quad [41]$$

Tada postoji više hiperravnina koje razdvajaju skup za učenje bez pogreške.



Slika 7. Klasifikator s maksimalnom marginom

Na slici 5.2 je prikazana hiperravnina gdje  $\gamma$  predstavlja maksimalnu marginu, a primjeri  $x_i$  potporne vektore. Skaliranjem hiperravnine  $(w, b)$  pomoću skala  $\alpha \in R^+$  u  $(\lambda w, \lambda b)$ , ne mijenja se funkcija vezana uz hiperravninu. Stoga možemo skalirati parametre hiperravnine tako da funkcija margini iznosi 1. Dakle slijedi:

$$\begin{aligned}\langle w | x_2 \rangle + b &= +1 \\ \langle w | x_1 \rangle + b &= -1\end{aligned}\quad [42]$$

$$\langle w | x_2 - x_1 \rangle = 2 \quad [43]$$

$$\begin{aligned}\gamma &= \frac{1}{2} \left\langle \frac{w}{\|w\|} | x_2 - x_1 \right\rangle \\ \gamma &= \frac{1}{\|w\|}\end{aligned}\quad [44]$$

Margina  $\gamma$  je obrnuto proporcionalna s udaljenosti između bilo koja dva primjera različitih kategorija., stoga je za maksimalnu marginu potrebno pronaći:

$$\min \left[ \frac{1}{2} \|w^2\| \right] \quad [45]$$

uz zadovoljene uvjete:

$$y_i (\langle w | x_i \rangle + b) \geq 1, \quad i = 1 \dots l \quad [46]$$

Budući je zadano ograničenje funkcije, odnosno uvjet [46], izraz [45] nije lako numerički rješiti. Problem se rješava uporabom Lagrangeovih multiplikatora. Neka je  $f(x,y)$  funkcija čije je ekstreme potrebno naći, a neka je  $g(x,y) = c$  uvjet.. U točkama ekstrema gradijenti funkcija  $f$  i  $g$  su paralelni vektori normalni, te je zadovoljen slijedeći izraz:

$$\nabla f(x,y) = \alpha \nabla g(x,y) \quad [47]$$

gdje je  $\alpha$  Lagrangeov multiplikator<sup>1</sup>, pomoću kojeg izjednačavamo funkcije  $f$  i  $g$  po duljini. Pomoći izraza [47] i uvjeta  $g(x,y) = c$  dolazimo do Lagrangianove formule:

$$L(x,y,\alpha) = f(x,y) + \alpha(g(x,y) + c) \quad [48]$$

a točke ekstrema dobivamo pomoću:

$$\nabla L(x,y,\alpha) = 0 \quad [49]$$

U slučaju kada imamo više uvjeta  $g_i(x,y)$ , problem pronašlaska ekstrema se rješava na slijedeći način:

---

<sup>1</sup> Optimizacijski postupci, a među njima i teorija Lagrangiana opisani su u (Cristianini, 2000) [4]

$$\nabla f(x, y) = \sum_i \alpha_i \nabla g_i(x, y) \quad [50]$$

odnosno

$$L(x, y, \alpha) = f(x, y) - \sum_i \alpha(g(x, y) + c) \quad [51]$$

Uvrštavanjem izraza [45] i [46] u prethodnu funkciju dobivamo dualnu formu:

$$L(w, b, \alpha) = \frac{1}{2} \langle w | w \rangle - \sum_{i=1}^l \alpha_i [y_i (\langle w | x_i \rangle + b) - 1] \quad [52]$$

Derivacije od  $L$  po primalnim varijablama u sedlu moraju nestati, pa slijedi:

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^l y_i \alpha_i x_i = 0 \quad [53]$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^l y_i \alpha_i = 0 \quad [54]$$

Transformacijama ovih izraza dobivamo:

$$w = \sum_{i=1}^l y_i \alpha_i x_i \quad [55]$$

$$0 = \sum_{i=1}^l y_i \alpha_i \quad [56]$$

Uvrštavanjem u Lagrangian dobivamo dualnu formu koju je potrebno maksimizirati.

$$\begin{aligned} L(w, b, \alpha) &= \frac{1}{2} \langle w | w \rangle - \sum_{i=1}^l \alpha_i [y_i (\langle w | x_i \rangle + b) - 1] \\ &= \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i | x_j \rangle - \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i | x_j \rangle + \sum_{i=1}^l \alpha_i \\ &= \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i | x_j \rangle \end{aligned} \quad [57]$$

$$\begin{aligned} \max & \left[ W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i | x_j \rangle \right] \\ & \sum_{i=1}^l y_i \alpha_i = 0 \\ & \alpha_i \geq 0, \quad i = 1 \dots l \end{aligned} \quad [58]$$

Neka je  $\alpha^*$  rješenje dualne forme, tada težinski vektor  $w^*$  daje hiperravninu s maksimalnom marginom:

$$w^* = \sum_{i=1}^l y_i \alpha_i^* x_i \quad [59]$$

$$\gamma = \frac{1}{\|w^*\|} \quad [60]$$

Odmak b je potrebno izračunati iz primalnih varijabli:

$$b^* = -\frac{\max_{y_i=-1} (\langle w^* | x_i \rangle) + \min_{y_i=+1} (\langle w^* | x_i \rangle)}{2} \quad [61]$$

Prema Kuhn-Tuckerovom teoremu postoji i dopunski uvjet

$$y_i (\langle x_i | w \rangle + b) - 1 = 0, \quad i = 1 \dots l \quad [62]$$

pomoću kojeg zaključujemo kako su jedino za one primjere  $x_i$ , za koje funkcija margini iznosi 1, te leže točno na geometrijskoj margini odgovarajući  $\alpha_i^*$  različiti od nule. Ostali primjeri su nevažni.

## 7.2 Metoda potpornih vektora sa slabom marginom

Prethodno opisana metoda potpornih vektora s maksimalnom marginom prepostavlja da su primjeri za učenje linearno razdvojivi. Međutim, ukoliko skup za učenje sadrži šum, primjeri neće biti linearno razdvojivi, pa je potrebno uvesti metodu potpornih vektora sa slabom marginom.

Uvodimo varijable  $\xi_i$  koje dopuštaju primjerima da stoje izvan granica margine te da budu krivo klasificirani.

$$\begin{aligned} y_i (\langle w | x_i \rangle + b) &\geq 1 - \xi_i, \quad i = 1 \dots l \\ \xi_i &\geq 0, \quad i = 1 \dots l \end{aligned} \quad [63]$$

Da bi se pogreške što više smanjile, koristimo slijedeće metode: slaba margina u L2 normi

$$\begin{aligned} & \min \left[ \frac{1}{2} \|w^2\| + \frac{1}{2} C \sum_{i=1}^l \xi_i^2 \right] \\ & y_i (\langle w | x_i \rangle + b) \geq 1 - \xi_i, \quad i = 1 \dots l \end{aligned} \quad [64]$$

te slaba margina u L1 normi.

$$\begin{aligned} & \min \left[ \frac{1}{2} \|w^2\| + \frac{1}{2} C \sum_{i=1}^l \xi_i \right] \\ & y_i (\langle w | x_i \rangle + b) \geq 1 - \xi_i, \quad i = 1 \dots l \\ & \xi_i \geq 0, \quad i = 1 \dots l \end{aligned} \quad [65]$$

Optimalna vrijednost parametra C je apriori nepoznata te se određuje krosvalidacijom na skupu za učenje.

Nakon nekoliko koraka ekvivalentnih onima za klasifikaciju s maksimalnom marginom dobivamo dualne definicije problema:

$$\begin{aligned} & \max \left[ W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \left( \langle x_i | x_j \rangle + \frac{1}{C} \delta_{ij} \right) \right] \\ & \sum_{i=1}^l y_i \alpha_i = 0, \\ & \alpha_i \geq 0, \quad i = 1 \dots l \end{aligned} \quad [66]$$

$$\begin{aligned} & \max \left[ W(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l y_i y_j \alpha_i \alpha_j \langle x_i | x_j \rangle \right] \\ & \sum_{i=1}^l y_i \alpha_i = 0 \\ & C \geq \alpha_i \geq 0, \quad i = 1 \dots l \end{aligned} \quad [67]$$

### **7.3 Karakteristike metodu potpornih vektora (SVM)**

Metoda potpornih vektora nalazi primjenu u kategorizaciji teksta, prepoznavanju rukopisa, klasifikaciji slika, itd. Prilagođena je za baratanje velikim količinama podataka – štoviše, mnoštvo mjerena povećava mogućnost razlučivanja pouzdano opaženih i bitnih uzoraka u podacima, od onih nepouzdanih, ili nebitnih. Popularna je zbog maksimalne generalizacije. Prilično je otporna na šum u podacima, neizbjegnu posljedicu bilo kojeg eksperimentalnog mjerena. Međutim točnost metode potpornih vektora je ograničena i poprilično ovisi o izboru nekih parametrima kao što su  $C$ ,  $\gamma$ , itd. Također, metoda je predviđena za klasifikaciju u samo dvije kategorije, ali razvijeni su i različiti pristupi koji omogućuju klasifikaciju više od dvije kategorije.


## 8 Umjetne neuronske mreže

Umjetna neuronska mreža je matematički ili računalni model temeljen na biološkoj neuronskoj mreži. Sastoji se od više međusobno povezanih umjetnih neurona i procesnih informacija koji služe distribuiranoj paralelnoj obradi podataka. Umjetne neuronske mreže uče pomoću primjera.

Dobro rješavaju probleme klasifikacije i predviđanja. Mogu raditi sa složenim i nepotpunim podacima. Neke od ostalih prednosti neuronskih mreža su prilagodljivost okolini, samoorganizacija i vršenje operacija u realnom vremenu.

### 8.1 Model umjetne neuronske mreže

Umjetni neuron se sastoji od više ulaza i jednog izlaza. Svaki ulaz  $x_i$  ima pridruženu težinu  $w_i$ , izlaz  $o$  je kompozicija ulaza pomnoženih sa odgovarajućim težinama.



Slika 8. Slojevi umjetne neuronske mreže

Vrijedi:

$$net = \sum_{i=1}^n w_i x_i + \theta \quad [68]$$

$$\theta = -w_0$$

$$x_0 = 1$$

$$net = \sum_{i=0}^n w_i x_i \quad [69]$$


$$o = f\left(\sum_{i=0}^n w_i x_i\right) = f(\text{net})$$

Prihvatljiva razina izlaza je obično između 0 i 1, ili između -1 i 1.

Prijenosna funkcija  $f$  je predefinirana, obično se koriste funkcije:


- ADALINE

$$f(\text{net}) = \text{net}$$




- TLU

$$f(\text{net}) = \begin{cases} 0 & \text{za } \text{net} < 0 \\ 1 & \text{inač} \end{cases}$$



- Sigmoidalna funkcija


$$f(\text{net}) = \frac{1}{1 + e^{-o * \text{net}}}$$



## 8.2 Topologija neuronskih mreža

Projektiranje neuronske mreže se vrši određivanjem broja neurona i njihovim povezivanjem, tj definiranjem njene topologije. Razlikujemo dvije vrste neuronskih mreža prema njihovoj topologiji. To su feed-forward neuronske mreže u kojima nema povratne veze, signal se prostire samo u jednom smjeru, ne vraća se u niže slojeve mreže i neuronske mreže s povratnom vezom. Neuronske mreže s povratnom vezom su složenije i imaju veće sposobnosti dinamičkog procesiranja od feed-forward mreža.

Neuronsku mrežu možemo podijeliti u više neuronskih slojeva. Svaki sloj prima podatke iz prethodnog sloja i šalje sljedećem sloju. Obično se razlikuju tri sloja, ulaz, izlaz i skriveni sloj (eng *hidden layer*). Na ulazu se šalju ulazni podaci, u skrivenom sloju se obrađuju, a na izlazu se dobivaju rezultati te obrade. Mreža se ponaša kao crna kutija, poznati su sami ulaz i izlaz, dok je obrada skrivena.



Slika 9. Topologija neuronskih mreža

## 8.3 Učenje

Neuron ima dva načina ili faze rada, faza učenja i faza obrade podataka. U fazi učenja potrebno je prvo definirati težine pojedinih ulaza, nakon toga se težine pojedinih ulaza korigiraju prema testnim primjerima.

Razlikuju se dva načina učenja:

- Učenje s učiteljem (eng *supervised learning*) – Učenje se odvija uz skup primjera.
- Učenje bez učitelja (eng *unsupervised learning*) – Ne postoji skup primjera, mogući izlazi nisu odmah poznati.

Učenje se odvija dok mreža dovoljno točno ne obradi podatke.

Najčešći algoritam za učenje neuronske mreže je back-propagation algoritam. Algoritam uspoređuje izlaz neuronske mreže s željenim izlazom i računa greške za svaki čvor u mreži. Težine veza se podešavaju prema vrijednosti greške za svaki čvor dok se ne dobiju minimalne prosječne kvadratne greške. Greške se smanjuju prolaskom kroz mrežu od izlaza prema ulazu.

## 9 Testiranje

U radu *Text Categorization with Support Vector Machines: Learning with Many Relevant Features* Thorstena Joachima [1] dana je usporedba rezultata rada pet različitih metoda strojnog učenja, metoda potpornih vektora - SVM, Bayesov algoritam, Rocchio algoritam, metoda k-najbližih susjeda s težinskim faktorima i algoritam C4.5 stabla za učenje. Ispitivanje je vršeno na dva testna skupa, prva je „ModApte“ koja je dio Reuters 21578 testnog skupa. Drugi testni skup je preuzet iz Ohsumed<sup>2</sup> kolekcije koju je sastavio William Hersh. Eksperimentalni rezultati su pokazali da se najlošije ponaša Bayes, slijede ga Rocchio algoritam i algoritma C4.5 stabla za učenje. Najbolje rezultate su imali algoritam k-najbližih susjeda i SVM, od ta dva SVM se pokazao kao bolji.

U radu *Machine Learning in Automated Text Categorization* Fabrizia Sebastianija (2002) [2] dan je tablični prikaz uspješnosti različitih vrsta klasifikatora na pet varijanti Reuters testnog skupa dokumenata: Reuters-22173 „ModLewis“ (stupac #1), Reuters-22173 „ModApt'e“ (stupac #2), Reuters-22173 „ModWiener“ (stupac #3), Reuters-21578 „ModApt'e“ (stupac #4), i Reuters-21578<sup>3</sup> „ModApt'e“ (stupac #5). Način na koji je autor vršio uspoređivanje je objašnjen u nastavku. Da bi se korektno moglo uspoređivati različite klasifikatore trebalo bi primijeniti jednu od dvije metode za uspoređivanje klasifikatora:

- Izravna usporedba: klasifikatori  $\Phi'$  i  $\Phi''$  mogu se uspoređivati samo ako su testirani na istom testnom skupu  $\Omega$ , obično od strane istih istraživača i u istim uvjetima. Ovo je pouzdanija metoda.
- Neizravna usporedba: klasifikatori  $\Phi'$  i  $\Phi''$  mogu se uspoređivati ako:
  1. testirani su na istim testnim skupovima  $\Omega'$  i  $\Omega''$  respektivno, obično od strane različitih istraživača i prema tome u različitim uvjetima
  2. jedan ili više standardnih klasifikatora  $\overline{\Phi_1}, \dots, \overline{\Phi_m}$  su testirani izravnom usporedbom na  $\Omega'$  i  $\Omega''$

Ova metoda je manje pouzdana.

Test 2 indicira relativnu „težinu“ testnih skupova  $\Omega'$  i  $\Omega''$ , koristeći to i rezultate testa 1 može se procijeniti relativna efikasnost klasifikatora  $\Phi'$  i  $\Phi''$ .

---

<sup>2</sup> Ohsumed kolekcija je dostupna na adresi <ftp://medir.ohsu.edu/pub/ohsumed>

<sup>3</sup> Reuters-21578 kolekcija dostupna je na adresi <http://www.research.att.com/~lewis/reuters21578.html>.

Tablica 2. Usporedni rezultati različitih klasifikatora ispitanih na pet različitih verzija baza novinskih članaka Reuters. Oznaka "F1" označava uporabu F1 mjere učinkovitosti (van Rijsbergen, 1972, 1979 [8]; Lewis, 1995 [9]), oznaka "M" označava makro usrednjavanje (eng. *macroaverage*)

			#1	#2	#3	#4	#5
		broj dokumenata broj dok. u skupu za učenje broj dok. za testiranje broj kategorija	21,450 14,704 6,746 135	14,347 10,667 3,680 93	13,27 9,610 3,662 92	12,902 9,603 3,299 90	12,902 9,603 3,299 10
Metoda	Vrsta						
WORD		[Yang 1999]	.150	.310	.290		
PropBayes Bim Nb	probabilistička probabilistička probabilistička probabilistička probabilistička probabilistička probabilistička	[Dumais et al. 1998] [Joachims 1998] [Lam et al. 1997] [Lewis 1992a] [Li and Yamanishi 1999] [Li and Yamanishi 1999] [Yang and Liu 1999]	.443 (MF1) .650			.752 .720	.815
C4.5 Ind	stabla odluke stabla odluke stabla odluke	[Dumais et al. 1998] [Joachims 1998] Lewis and Ringuette 1994]	.670			.794	.884
Swap-1 Ripper SleepingeExperts DI-Esc Charade Charade	skupni linearni skupni linearni skupni linearni skupni linearni skupni linearni skupni linearni	[Apt'e et al. 1994] [Cohen and Singer 1999] [Cohen and Singer 1999] [Li and Yamanishi 1999] Moulinier and Ganascia 1996 [Moulinier et al. 1996]	.683 .753	.805 .811 .759		.820 .827 .820	
LLSF LLSF	regresijski regresijski	[Yang 1999] [Yang and Liu 1999]		.855	.810		.849
BalancedWinnow Widrow-Hoff	on-line linearni on-line linearni	[Dagan et al. 1997] [Lam and Ho 1998]	.747 (M)	.833 (M)			.822
Rocchio Findsim Rocchio Rocchio Rocchio	grupirani linearni grupirani linearni grupirani linearni grupirani linearni grupirani linearni	[Cohen and Singer 1999] [Dumais et al. 1998] [Joachims 1998] [Lam and Ho 1998] [Li and Yamanishi 1999]	.660	.748		.776 .617 .799 .781 .625	.646
Classi NNET	neur. mreže neur. mreže neur. mreže	[Ng et al. 1997] Yang and Liu 1999 [Wiener et al. 1995]		.802		.838	
GIS-W k-NN k-NN k-NN k-NN	metode učenja na temelju primjera	[Lam and Ho 1998] [Joachims 1998] [Lam and Ho 1998] [Yang 1999] [Yang and Liu 1999]	.690	.852	.820	.860 .823 .820 .856	
SVM Light SVM Light SVM Light	SVM SVM SVM SVM	[Dumais et al. 1998] [Joachims 1998] [Li Yamanishi 1999] [Yang and Liu 1999]				.870 .864 .841 .859	.920
AdaBoost.MH	kolekcija kolekcija	[Schapire and Singer 2000] [Weiss et al. 1999]		.860		.878	
	Bayes-ove mreže	[Dumais et al. 1998] [Lam et al. 1997]	.542 (MF1)			.800	.850

Pomoću neizravne usporedbe došlo se do sljedećih zaključaka:

- Kolekcije klasifikatora, metoda potpornih vektora – SVM, metode koje se temelje na primjerima i metode s regresijom donose vrhunske rezultate. Nema dovoljno dokaza da se doneše konačan sud koja od tih metoda je najbolja.
- Neuronske mreže i on-line linearni klasifikatori rade jako dobro, iako malo lošije od prije spomenutih metoda.
- Rocchio algoritam i naivni Bayesov algoritam daju najlošije rezultate od algoritama koje se temelje na strojnem učenju.
- Podaci u tablici nisu dovoljni da bi se zaključilo nešto o stablima odluke. Međutim, u radu Dumaisa (1998) [5] klasifikator pomoću stabla odluke se pokazao tek nešto lošiji od SVM klasifikatora.

Važno je napomenuti da zaključci izneseni gore ne mogu biti absolutni. Za drugi kontekst mogu doći do izražaja druge značajke od onih koje su došle do izražaja za Reuters, a različiti klasifikatori mogu drugačije reagirati na te značajke.

## 10 Literatura

- [1] T. Joachims: *Text Categorization with Support Vector Machines: Learning with Many Relevant Features*, Universitaet Dortmund, 1997.
- [2] F. Sebastiani: *Machine Learning in Automated Text Categorization*, Consiglio Nazionale delle Ricerche, 2002.
- [3] Y. Yang: *A Comparative Study on Feature Selection in Text Categorization*, Carnegie Melon University, 1997.
- [4] N. Cristianini, J. Shawe-Taylor: *An Introduction to Support Vector Machines (and other kernel based learning methods)*, Cambridge University Press, Cambridge. 2000.
- [5] S. T. Dumais, H. Chen: *Hierarchical classification of Web content*, 2000.
- [6] *Machine Learning*, URL:  
<http://www.statsoft.com/textbook/stathome.html?stmachlearn.html&1> (1.4.2008)
- [7] M. E. Ruiz, P.Srinivasan: *Automatic Text Categorization Using Neural Networks*, URL:  
<http://informatics.buffalo.edu/faculty/ruiiz/publications/sigcr97/sigcrfinal2.html>, (2.4.2008)
- [8] C. J. van Rijsbergen: *Information Retrieval*, 1979  
URL: <http://www.dcs.gla.ac.uk/Keith>.
- [9] D. D. Lewis: *Evaluating and optmizing autonomous text classification systems*, 1995
- [10] R.Aheel: *Postupak klasifikacije teksta temeljen na k-nn metodi i naivnom Bayesovom klasifikatoru*, diplomski rad br. 1410, Zagreb, 2003.
- [11] M.Malenica: *Primjena jezgrenih metoda u kategorizaciji teksta*, diplomski rad br. 1505, Zagreb, 2004.
- [12] A.Cvitaš: *Automatsko indeksiranje dokumenata u modelu vektorskog prostora*, diplomski rad br. 1543, Zagreb, 2005.