

Strojno učenje

4 (I dio)

Osnovni algoritmi

Tomislav Šmuc

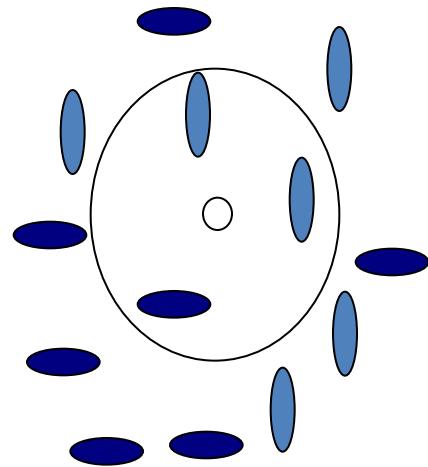
Osnovni algoritmi za učenje pod nadzorom

- Metoda najbližih susjeda – k-nn
- MAP hipoteza i princip Bayes-optimalne klasifikacije
- Naivni Bayesov klasifikator
- stabla odlučivanja

- “Memorijski” klasifikator – (ROTE-Learner)
 - U memoriji su svi primjeri dostupni u trenutku učenja
 $(\langle \mathbf{x}_i, y_i \rangle \in \mathcal{T})$
 - Klasifikacija novih instanci – traži isti takav primjer u memoriji
 $(\mathbf{x}_t = \mathbf{x}_i \mid \mathbf{x}_i \in \mathcal{T})$:
 - ukoliko ga nadje, novi primjer dobiva oznaku (y) kao njegova replika iz memorije (primjeri za učenje);
 - ukoliko ne nadje takav primjer – odustaje od klasifikacije !
 - Zapravo ne generalizira – i ne stvara nikakav model ?!

K-nn algoritam (k – najbližih susjeda)

- Malo poopćenje “memorijskog” klasifikatora
- Klasificira koristeći princip analogije:
“Reci mi tko su ti prijatelji” ili “Reci mi tko su ti susjedi”
- Novi primjer dobija vrijednost ciljnog atributa koja je najčešća u njegovom susjedstvu (k-najbližih susjeda)

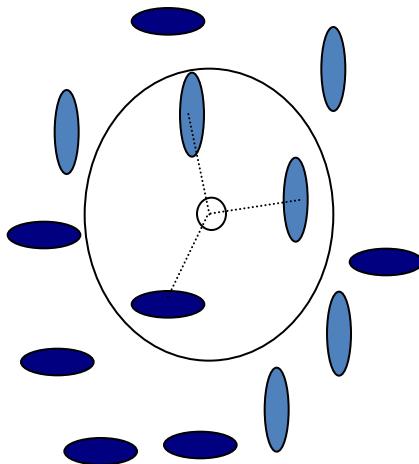


K-nn algoritam

- Izračuna udaljenost između novog primjera x_t i svih primjera iz skupa za učenje T
- Odredi k-najbližih susjeda x_t iz T
- Pridjeli x_t klasu koja je najčešća između k-najbližih susjeda

$$3\text{-nn}(\circ) = \begin{array}{c} \text{---} \\ | \\ | \end{array} \Rightarrow c(\circ) = \text{---}$$

K-nn algoritam (k – najbližih susjeda)



K-nn algoritam

- Udaljenost između primjera (n je broj dimenzija)

$$D(\mathbf{x}, \mathbf{x}_i) = \sqrt{\sum_{j=1}^n (x_j - x_{i,j})^2}$$

- Ako su $i=1,..k$ k -najbližih susjeda (točaka u prostoru):

$$\hat{f}(\mathbf{x}) \leftarrow \arg \max_{c=C} \left(\sum_{i=1}^k \delta(c, f(\mathbf{x}_i)) \right)$$

gdje je

$$\delta(x, y) = 1 \text{ za } x = y$$

$$\delta(x, y) = 0 \text{ za } x \neq y$$

K-nn algoritam (k – najbližih susjeda)

$$D(\mathbf{x}, \mathbf{x}_i) = \sqrt{\sum_{j=1}^n (x_j - x_{i,j})^2}$$

| X_1 | X_2 | X_3 | X_4 | X_5 | X_6 | X_7 | y |
|--------|-------|-------|-------------|------------|--------|--------------------|-------------------|
| Godine | Spol | Brak | Obrazovanje | Broj djece | Regija | Primanja (HRK/god) | Klasa G(1) / N(0) |
| 26 | m | Da | sš | 1 | I | 88000 | 0 |
| 34 | ž | Ne | vss | 2 | S | 65000 | 1 |
| 56 | ž | Da | ss | 4 | J | 135000 | 0 |
| 68 | m | Ne | vss | 1 | Z | 45000 | 1 |
| 19 | m | Ne | ss | 0 | C | 33000 | 1 |
| | | | | | | | |

Problem udaljenosti između primjera

| X_1 | X_2 | X_3 | X_4 | X_5 | X_6 | X_7 | y |
|--------|-------|-------|-------------|------------|--------|--------------------|--------------------|
| Godine | Spol | Brak | Obrazovanje | Broj djece | Regija | Primanja (HRK/god) | Klasa G(1) / NG(0) |
| 26 | m | Da | sš | 1 | I | 88000 | 0 |
| 34 | ž | Ne | vss | 2 | S | 65000 | 1 |
| 19 | m | Ne | ss | 0 | C | 33000 | 1 |
| | | | | | | | |

$$D(Pero, Matilda) = \sqrt{(x_1(Pero)-x_1(Matilda))^2 + (x_2(Pero)-x_2(Matilda))^2 + \dots}$$

$$D(Pero, Matilda) = \sqrt{((45-38)^2 + (m-\check{z})^2 + (Da-Ne)^2 + (S\check{S}-VSS)^2 + (2-1)^2} \dots$$

???

K-nn algoritam (k – najbližih susjeda)

K-nn – problem određivanja udaljenosti između primjera

- i. Za kontinuirane varijable / atributе

$$D_2(\mathbf{x}_1, \mathbf{x}_2) = \sqrt{\sum_{j=1}^n (x_{1,j} - x_{2,j})^2} \quad \text{Euklidska}$$

$$D_1(\mathbf{x}_1, \mathbf{x}_2) = \sum_{j=1}^n |x_{1,j} - x_{2,j}| \quad \text{Manhattan}$$

- ii. Za kategoričke varijable / atributе

$$D(\mathbf{x}_1, \mathbf{x}_2) = \sum_{j=1}^n (1 \mid x_{1,j} \neq x_{2,j}) \quad \text{Hamming udaljenost (isto što i tzv. edit distance)}$$

K-nn – udaljenost između primjera

- Atributi obično imaju vrlo različite intervale vrijednosti, stoga:
 - Normalizacija numeričkih atributa na interval (0,1):

$$a'_i = \frac{a_i - \min(a_i)}{\max(a_i) - \min(a_i)}$$

- Standardizacija numeričkih atributa

$$a^s_i = \frac{a_i - \bar{a}_i}{stdev(a_i)}$$

- Udaljenosti za kategoričke attribute:

($x'_j = x_{i,j} \Rightarrow x'_j - x_{i,j} = 0; \quad x'_j \neq x_{i,j} \Rightarrow x'_j - x_{i,j} = 1$); ponekad – matrice udaljenosti

- K-nn algoritam možemo isto tako koristiti i za regresijske probleme !
Kako izgleda $f(\mathbf{x})$ u tom slučaju ?

K-nn - poboljšanja

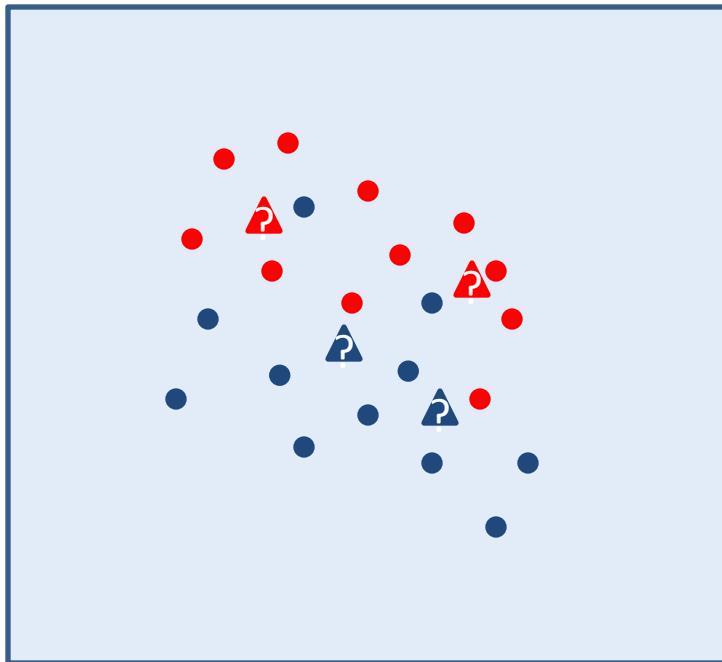
- Težinsko određivanje - uzima u obzir udaljenost k-susjeda prema novom primjeru

$$\hat{f}(\mathbf{x}) \leftarrow \arg \max_{c=C} \left(\sum_{i=1}^k w_i \delta(c, f(\mathbf{x}_i)) \right)$$

gdje je

$$w_i \equiv \frac{1}{d(\mathbf{x}, \mathbf{x}_i)}$$

K-nn – overfitting

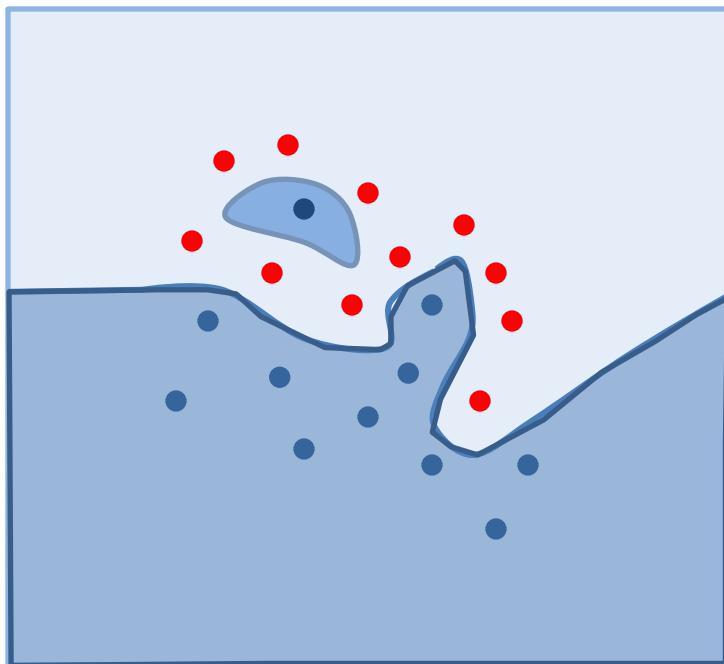


● Training set

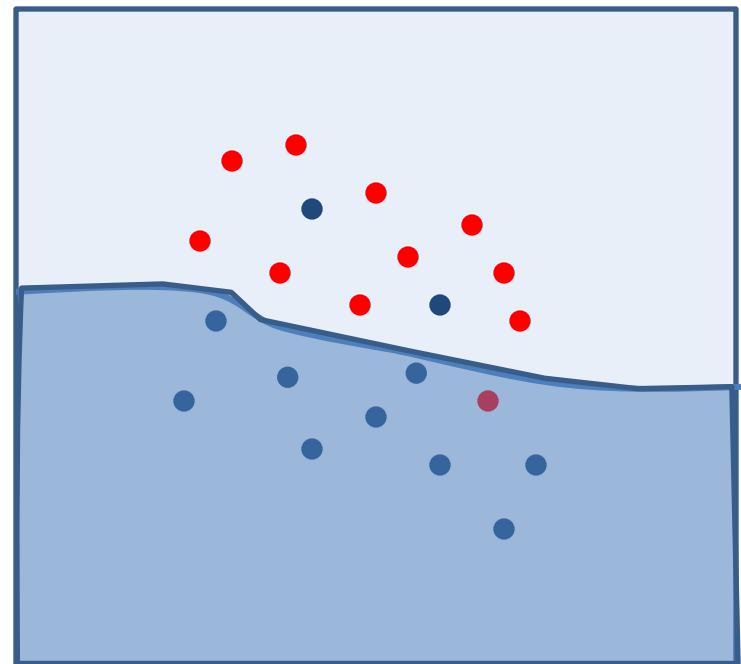
? Novi primjeri

K-nn algoritam (k – najbližih susjeda)

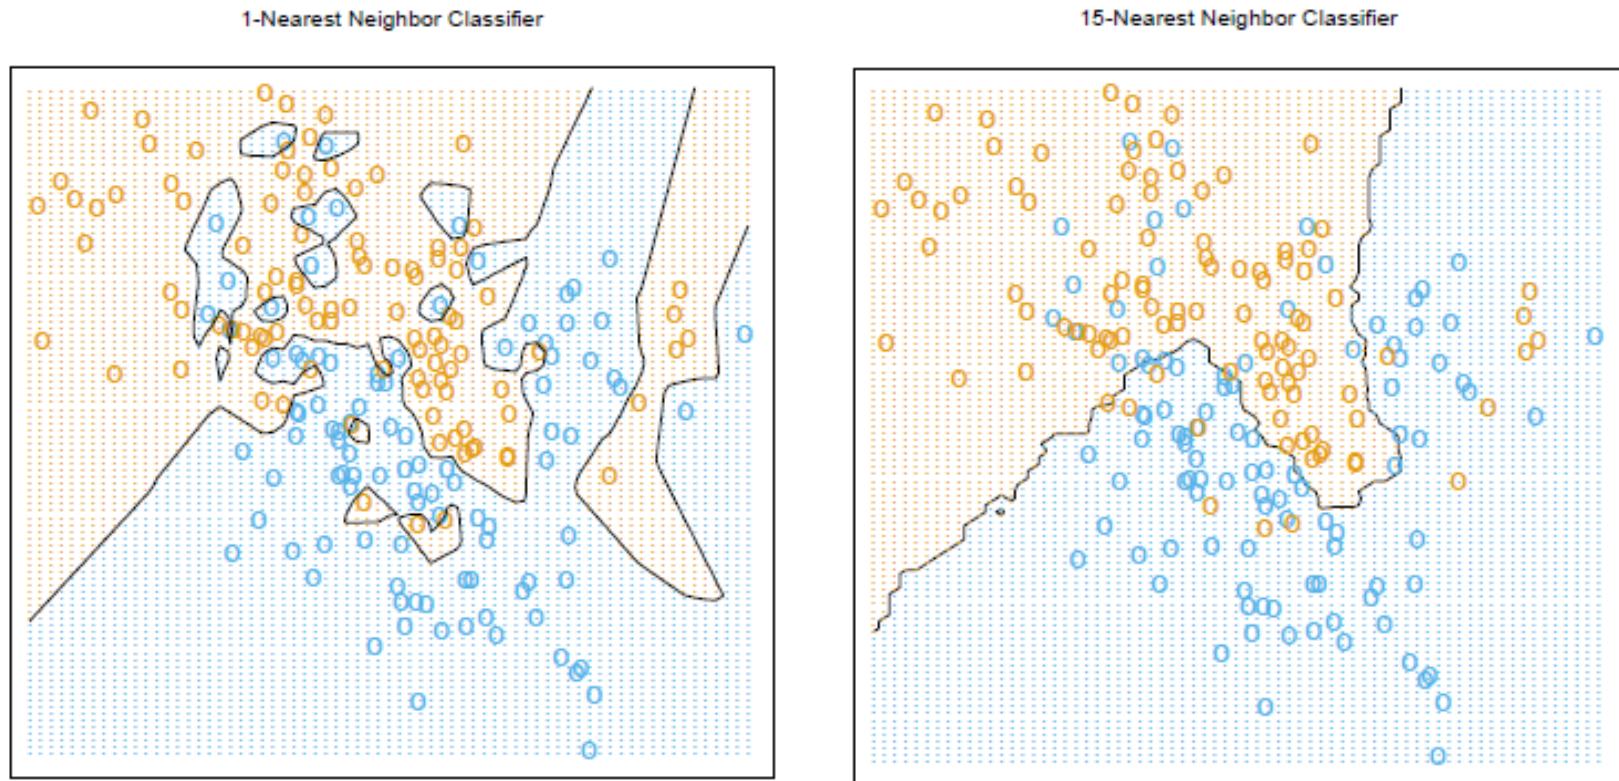
1-nn (približne granične linije)



5-nn (približne granične linije)

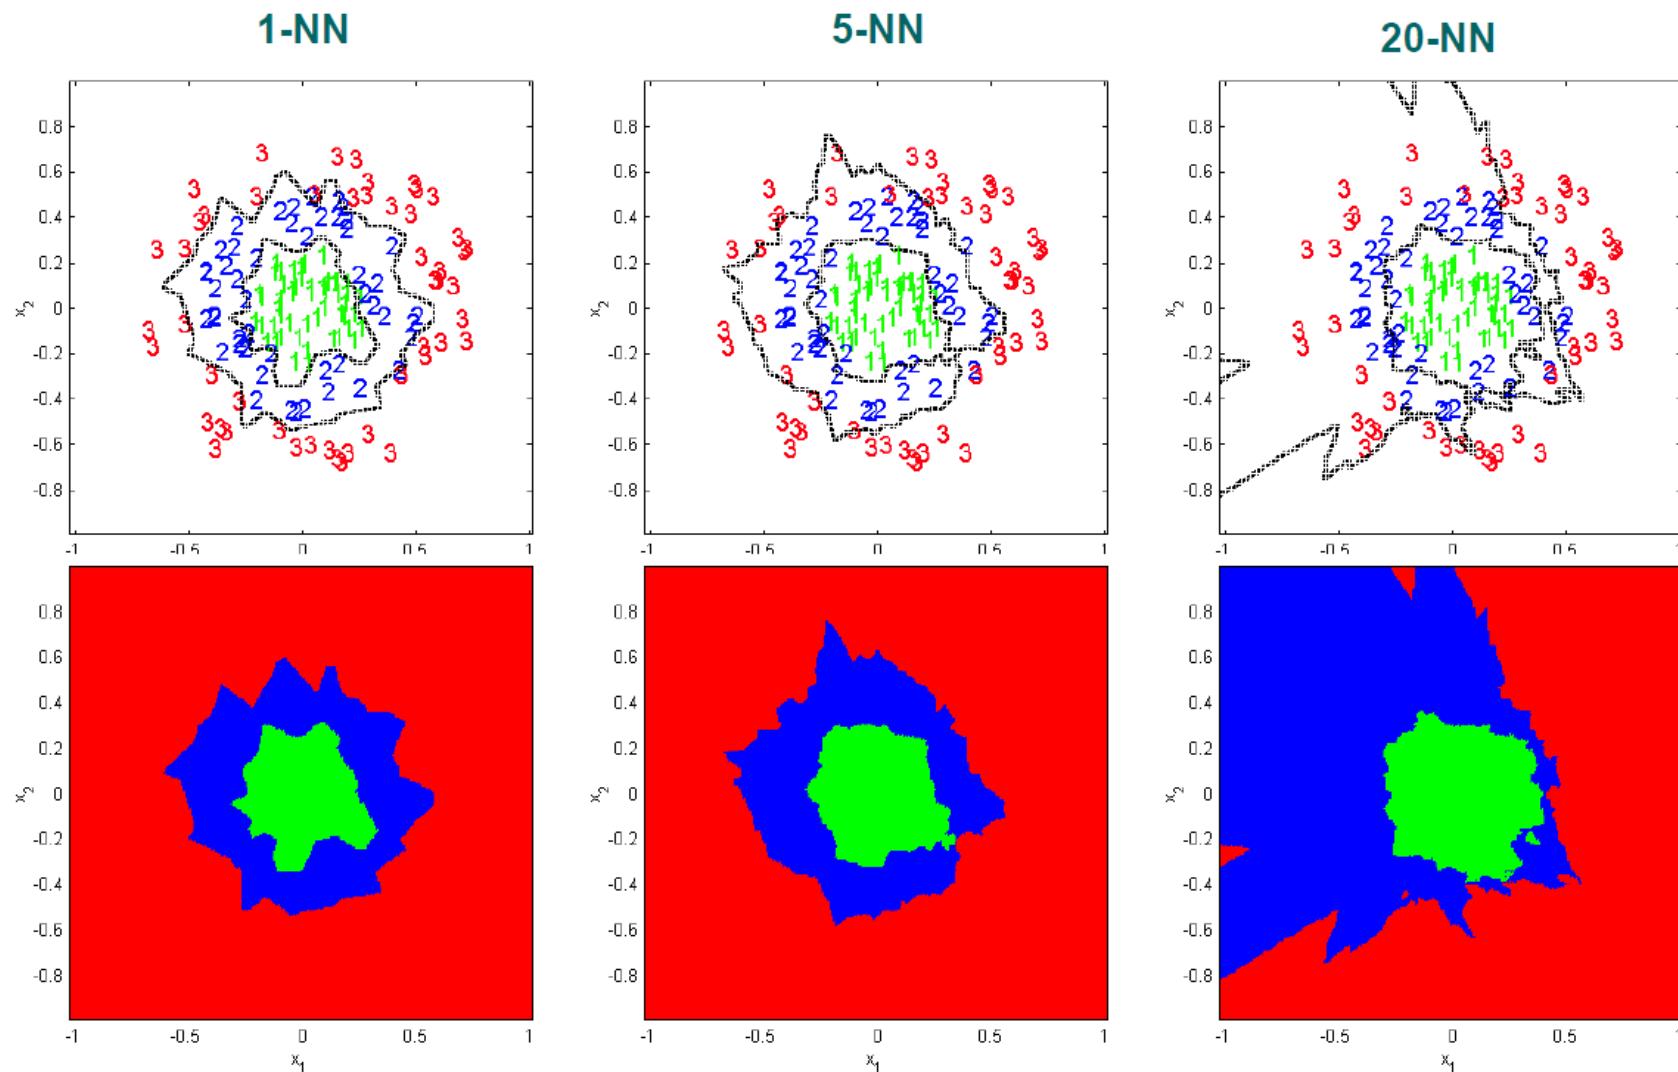


K-nn algoritam (k – najbližih susjeda)



Elements of Statistical Learning (2nd Ed.) ©Hastie, Tibshirani & Friedman 2009 Chap 2

K-nn algoritam (k – najbližih susjeda)



Karakteristike k-nn klasifikatora

Prednosti

- Jednostavan za implementaciju
- Gotovo optimalan za ($N \rightarrow \infty$)
 $Er_{\text{OBayes}} < Er_{1-\text{nn}} < 2 * Er_{\text{OBayes}}$
- Koristi lokalnu informaciju – vrlo adaptivan
- Pogodan za paralelnu implementaciju

Mane

- Memorija
- Trajanje u procesu klasifikacije
- tzv. “curse of dimensionality” problem

Karakteristike k-nn klasifikatora

1-nn vs k-nn

- korištenje većih vrijednosti k:
 - “glađe” granice između klase (manja vjerojatnost overfitting-a)
 - pruža dodatnu “probabilističku” informaciju
- opasnosti prevelikog k:
 - može potpuno poništiti prednosti lokalne estimacije (“prisiljen” koristiti sve udaljenije primjere)
 - povećava se zahtjev na računalne resurse kod klasifikacije

K-nn – problemi

1. Koji k je optimalan ? => Zahtijeva eksperimentiranje sa različitim k
2. Velik broj atributa – puno nevažnih – u određivanju udaljenosti svi imaju istu težinu !?
 - Rješenja: Težinski faktori za svaki atribut/varijablu
 - Svaki atribut dobija vlastitu težinu – kako je odrediti ?
3. Velik broj primjera u skupu za učenje
 - Za svaki novi primjer koji želimo klasificirati moramo odrediti udaljenost prema svim primjerima u memoriji i odabrati najbliže susjede !
 - Rješenja:
 - Indeksiranje primjera (**kd-trees** metoda)
 - Selektivno spremanje primjera za učenje

MAP (Maximum a posteriori) klasifikacija

Bayes-optimalna klasifikacija

(NB) - Naivni Bayes klasifikator

- U strojnom učenju u principu želimo naći najuspješniju hipotezu/model koja opisuje podatke koji su nam dostupni za učenje (T)

Probabilistički pristup

Najbolja hipoteza \approx **najvjerojatnija hipoteza**

- Mnogi algoritmi strojnog učenja baziraju se upravo na traženju najvjerojatnije hipoteze/modela (generativni algoritmi)

Vjerojatnost hipoteze ovisi od njene prethodne vjerojatnosti,
vjerojatnosti dobivanja upravo onakvih podataka kakve smo skupili
- uz danu hipotezu, te o samim podacima (generativni algoritmi!)

MAP hipoteza

Pojam h_{MAP} - **MAP – maximum a posteriori** hipoteze

h_{MAP} = Maksimalno vjerojatna hipoteza(e) uz dostupne podatke

$$h_{MAP} = \arg \max_{h \in H} \frac{P[T|h] \cdot P[h]}{P[T]} = P[T|h] \cdot P[h]$$

No, ustvari naš konačni cilj je dobiti najbolji rezultat ! Što znači (u slučaju klasifikacije):

- koja je **najvjerojatnija klasifikacija novog primjera** uz podatke (primjere u skupu za učenje) koje imamo ?

- Da li je odgovor uz ovakav cilj - **predikcija dobivena od h_{MAP}** ?

$$c(x_i) = \arg \max_{c_j \in C} P[c_j | h_{MAP}, x_i]$$

Bayes-optimalna klasifikacija

Iako je h_{MAP} najvjerojatnija hipoteza iz H uz dane podatke T , najvjerojatniju klasifikaciju novog primjera dobit ćemo kombiniranjem predikcija svih hipoteza iz H , i to s težinama koje odgovaraju (posteriori) vjerovatnosti hipoteza

$$c(x_i) = \arg \max_{c_j \in C} \sum_{h_k \in H} P[c_j | h_k] \cdot P[h_k | T]$$

Ovo je princip tzv. Bayesove optimalne klasifikacije

Za bilo koji sustav koji klasificira nove instance po ovom principu – možemo reći da je optimalan u Bayes-ovom smislu.

Osnovni problem s takvim klasifikatorima:

- resursi (sve hipoteze sudjeluju u klasifikaciji !)

Bayesov klasifikator

Za potrebe klasifikacije:

recimo da nemamo hipoteze/modele – nego samo podatke (skup primjera za učenje):

$$P[c_j|x] = \frac{P[x|c_j] \cdot P[c_j]}{\sum_{k=1}^{|C|} P[x|c_k] \cdot P[c_k]} = \frac{P[x|c_j] \cdot P[c_j]}{P[x]}$$

$c_j \in C - \text{klaša}$

x - vrijednost atributa

(prepostavimo da se radi o kategoričkoj varijabli)

Učenje:

- ❑ Odrediti $P(x|c_j)$, $P(c_j)$ iz podataka T

Klasifikacija:

- ❑ Korištenjem Bayesovog pravila odrediti:

$$c_{MAP} = \arg \max_{c_j \in C} P[\mathbf{x}^{novi} | c_j] \cdot P[c_j]$$

$c_j \in C - \text{klasa}$

\mathbf{x} - vektor vrijednosti atributa \mathbf{x}
 $= \{x_1, x_2, \dots, x_n\}$

(pretpostavka da se radi o
kategoričkim varijablama)

Bayesov klasifikator

$$c_{MAP} = \arg \max_{c_j \in C} P(c_j | x_1, x_2, \dots, x_n)$$

uz Bayesov teorem

$$\begin{aligned} c_{MAP} &= \arg \max_{c_j \in C} \frac{P(x_1, x_2, \dots, x_n | c_j) \cdot P(c_j)}{P(x_1, x_2, \dots, x_n)} \\ &= \arg \max_{c_j \in C} P(x_1, x_2, \dots, x_n | c_j) \cdot P(c_j) \end{aligned}$$

Odrediti

$P(c_j)$ - je lako

$P(x_1, x_2, \dots, x_n | c_j)$ – gotovo nemoguće !

**Potrebno je imati vrlo,
vrlo velik skup primjera !**

Osnovna pretpostavka

$$P(x_1, x_2, \dots, x_n | c_j) \approx \prod_{i=1}^n P(x_i | c_j)$$

x_i uvjetno nezavisno o x_j $\forall i \neq j !$

$$\forall (i, j, k) P(c = c_j | x_1 = x_{1,j}, x_2 = x_{2,k}) = P(c = c_j | x_1 = x_{1,j})$$

c je uvjetno nezavisno od x_2 uz zadan x_1 ako je distribucija vjerojatnosti nad c neovisna o vrijednosti x_2 , uz zadane vrijednosti x_1 .

Što nam to donosi ?

Umjesto svih permutacija $P(x_1, x_2, \dots, x_n | c_j)$

$$N_{BC}(P) \approx |C| * |x_1| * |x_2| * \dots * |x_n|$$

Trebaju nam samo $P(x_1 | c_j), P(x_2 | c_j), \dots, P(x_n | c_j)$

$$N_{NBC}(P) \approx |C| * [|x_1| + |x_2| + |x_n|]$$

NB – algoritam (kategoričke varijable)

Učenje:

- Za svaku vrijednost klasu c_j odredi :

$$\hat{\phi}_k = P(c = c_k) = \frac{\#T\{c = c_k\}}{|T|}$$

- Za svaku vrijednost $x_{i,j}$ za svaki atribut x_i :
odredi:

$$\hat{\kappa}_{ijk} = P(x_i = x_{i,j} | c = c_k) = \frac{\#T\{x_i = x_{i,j} \wedge c = c_k\}}{\#T\{c = c_k\}}$$

NB - algoritam

Klasifikacija:

- Za novi primjer \mathbf{x}^{novi}

$$c(\mathbf{x}^{novi}) \leftarrow \arg \max_{c_j} \hat{\phi}_j \prod \hat{\kappa}_{ijk}$$

Primjer

| Spol | Brak | Klasa G(1) / N(0) |
|------|------|----------------------|
| m | Da | 1 |
| m | Ne | 1 |
| ž | Da | 1 |
| ž | Da | 1 |
| ž | Ne | 0 |
| m | Ne | 0 |
| ž | Da | 0 |

učenje

$$P(c=1)=4/7; P(c=0)=3/7 \quad \hat{\phi}_k = P(c=c_k) = \frac{\#T\{c=c_k\}}{|T|}$$

$$\hat{K}_{ijk} = P(x_i = x_{i,j} | c = c_k) = \frac{\#T\{x_i = x_{i,j} \wedge c = c_k\}}{\#T\{c = c_k\}}$$



$$P(\text{Spol}=m | \text{Klasa}=1) = 1/2$$

$$P(\text{Spol}=m | \text{Klasa}=0) = 1/3$$

$$P(\text{Brak}=Da | \text{Klasa}=1) = 3/4$$

$$P(\text{Brak}=Da | \text{Klasa}=0) = 1/3$$

klasifikacija

Novi primjer: $\mathbf{x}^n = \{\text{Spol}=m; \text{Brak}=Da\}, c(\mathbf{x}^n) = ?$

$$\left. \begin{aligned} P(c(\mathbf{x}^n)=1) &= 4/7 * 1/2 * 3/4 = 12/56 = 3/14 \\ P(c(\mathbf{x}^n)=0) &= 3/7 * 1/3 * 1/3 = 3/63 = 1/21 \end{aligned} \right\} \quad c(\mathbf{x}^n) = 1$$

problemi

Kada je stvarna vjerojatnost

$$P(x_i = x_{i,j} \mid c = c_k) \ll 1$$

a imamo relativno mali broj primjera za učenje $|T|$

=> Vrlo je vjerojatno da ćemo dobiti procjenu

$P(x_i = x_{i,j} \mid c = c_k) \approx \kappa_{ijk} = 0$ => ovaj će faktor dominirati pri izračunu $c(\mathbf{x}^{novi})$

Rješenje:

m-estimate (drugi naziv - Laplacian smoothing)

$$\hat{\kappa}_{ijk} = P(x_i = x_{i,j} \mid c = c_k) = \frac{\#T\{x_i = x_{i,j} \wedge c = c_k\} + m \cdot p}{\#T\{c = c_k\} + m}$$

p - naša procjena vjerojatnosti; ($\sim p=1/\text{br.kategorija varijable}$)
 m – veličina “virtualnog” uzorka
(en. equivalent sample size).

Ako su atributi/variabile kontinuirane ?

Rješenje:

- diskretizacija – više različitih pristupa
- pretpostavka da se x_j ponaša prema normalnoj distribuciji $N(\mu, \sigma)$
 - učenje: za svaku varijablu j i klasu c_k odredimo zasebno $N(\mu, \sigma)_{j,k}$
 - klasifikacija: odredimo $P(x_j^{novi} | c=c_k)$ prema:

$$P(x_j^{novi} | c = c_k) = \frac{1}{\sigma_{jk} \sqrt{2\pi}} \exp\left(\frac{-(x_j^{novi} - \mu_{jk})^2}{2\sigma_{jk}^2} \right)$$

NB – algoritam u praksi

- jednostavan: nema učenja hipoteza/modela !
- pretpostavka o uvjetnoj nezavisnosti - iako u većini situacija nije opravdana => rezultati općenito vrlo dobri !
- robustan na šum u podacima

Stabla odlučivanja

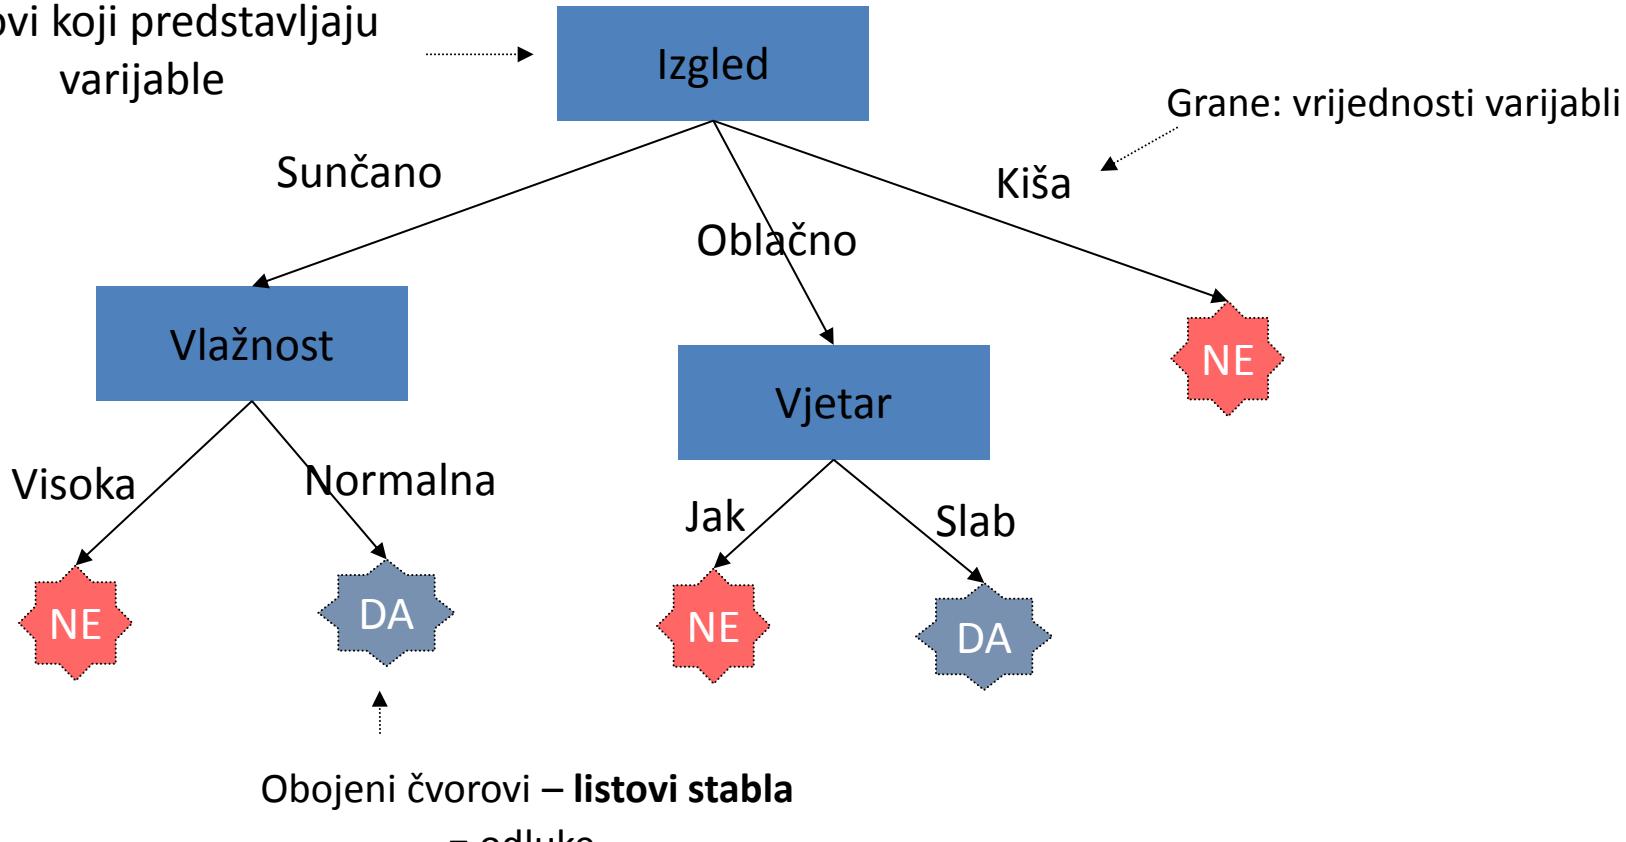
Primjer: Igrati ili ne igrati !

- Želimo naučiti prepoznavati:
“kada je dobar dan za igranje tenisa” – igrati ili ne ?
- Mjerenja:
 - Varijable i njihove vrijednosti + oznake

| Izgled | Temperatura | Vlažnost | Vjetar | Igrati DA/NE |
|----------------|---------------|----------------|-----------------|-----------------|
| <i>Sunčano</i> | <i>Hladno</i> | <i>Visoka</i> | <i>Slab</i> | <i>Da</i> |
| <i>Kišno</i> | <i>Vruće</i> | <i>Srednja</i> | <i>Osrednji</i> | <i>Ne</i> |
| <i>Oblačno</i> | <i>Toplo</i> | <i>Visoka</i> | <i>Jak</i> | <i>Ne</i> |

Stabla odlučivanja (decision trees)

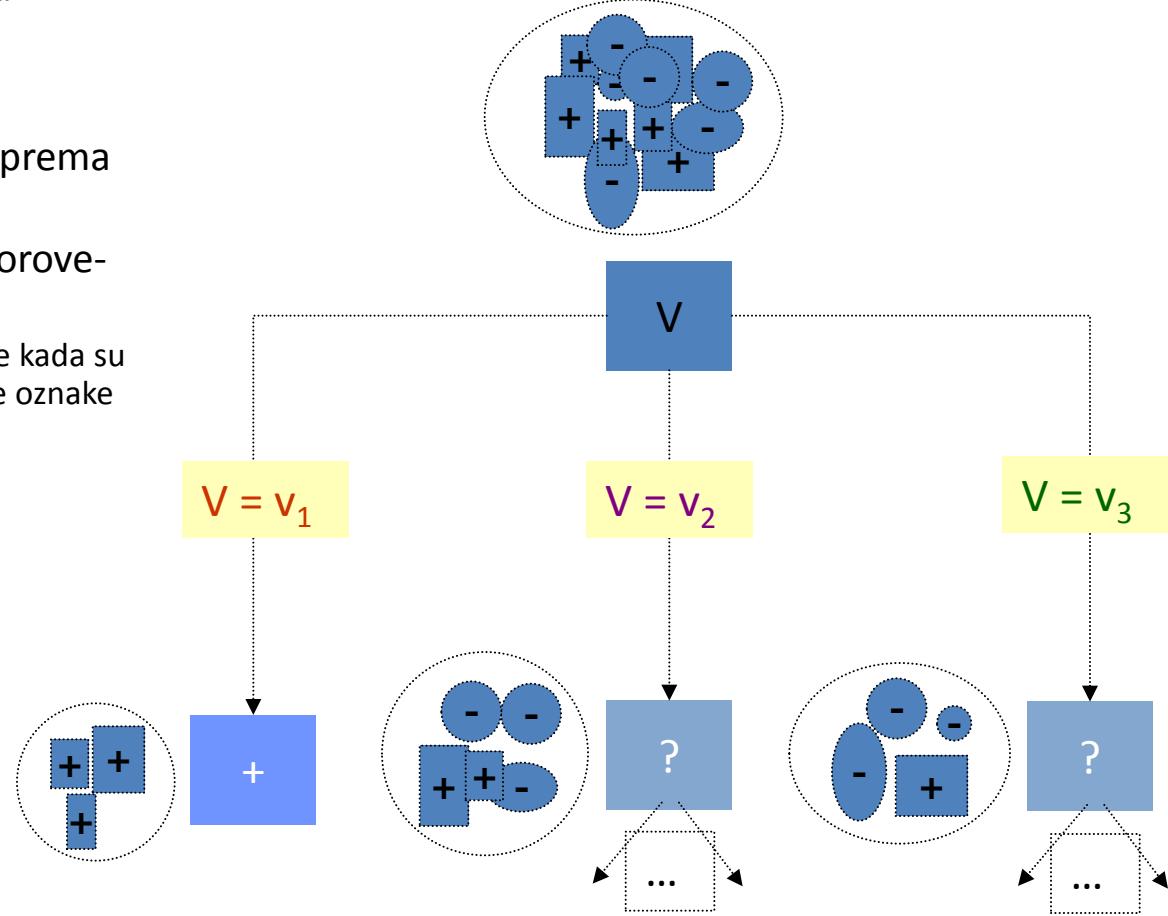
Čvorovi koji predstavljaju varijable



$$(Izgled = \text{Sunčano} \wedge Vlažnost = \text{Normalna}) \rightarrow \text{Igrati tenis} = \text{DA}$$

Stvaranje stabla odlučivanja

- Uz dani skup primjera za učenje – T :
 - Izaberi varijablu V
 - Podijeli (split) primjere prema vrijednosti varijable V
 - Stvori (pod)stabla za čvorove-djelu rekursivno;
 - Zaustavi proces podjele kada su svi primjeri u čvoru iste oznake



Algoritam stabla odlučivanja (ID3) (top-down induction of decision trees)

- **ID3 (Primjeri, Ciljna varijabla, Varijable)**
 - Kreiraj osnovni čvor stabla
 - Ako su svi *Primjeri* iste klase (+) => stablo je osnovni čvor sa oznakom (+)
 - Ako su svi *Primjeri* iste klase (-) => stablo je osnovni čvor sa oznakom (-)
 - Ako su sve *Varijable* iskorištene => vrati osnovni čvor sa oznakom najbrojnije klase u skupu *Primjeri*
 - Inače
 - Dok *Varijable* > 0
 - $V_i \leftarrow$ odredi varijablu koja najbolje dijeli/klasificira skup *Primjeri*
 - Za svaku vrijednost v_j od V_i
 - Dodaj novu granu ispod čvora, koja korespondira sa testom $V_i=v_j$
 - Neka su $Primjeri_{(V_i=v_j)}$ onaj podskup *Primjeri* – koji zadovoljava $V_i=v_j$
 - Ako $Primjeri_{(V_i=v_j)}=0$
 - Tada dodaj oznaku $c = \text{najčešće klase u skupu Primjeri}$
 - Inače na novu granu dodaj novo pod-stablo
 $\text{ID3}(Primjeri_{(V_i=v_j)}, \text{Ciljna varijabla}, \text{Varijable} - \{V_i\})$

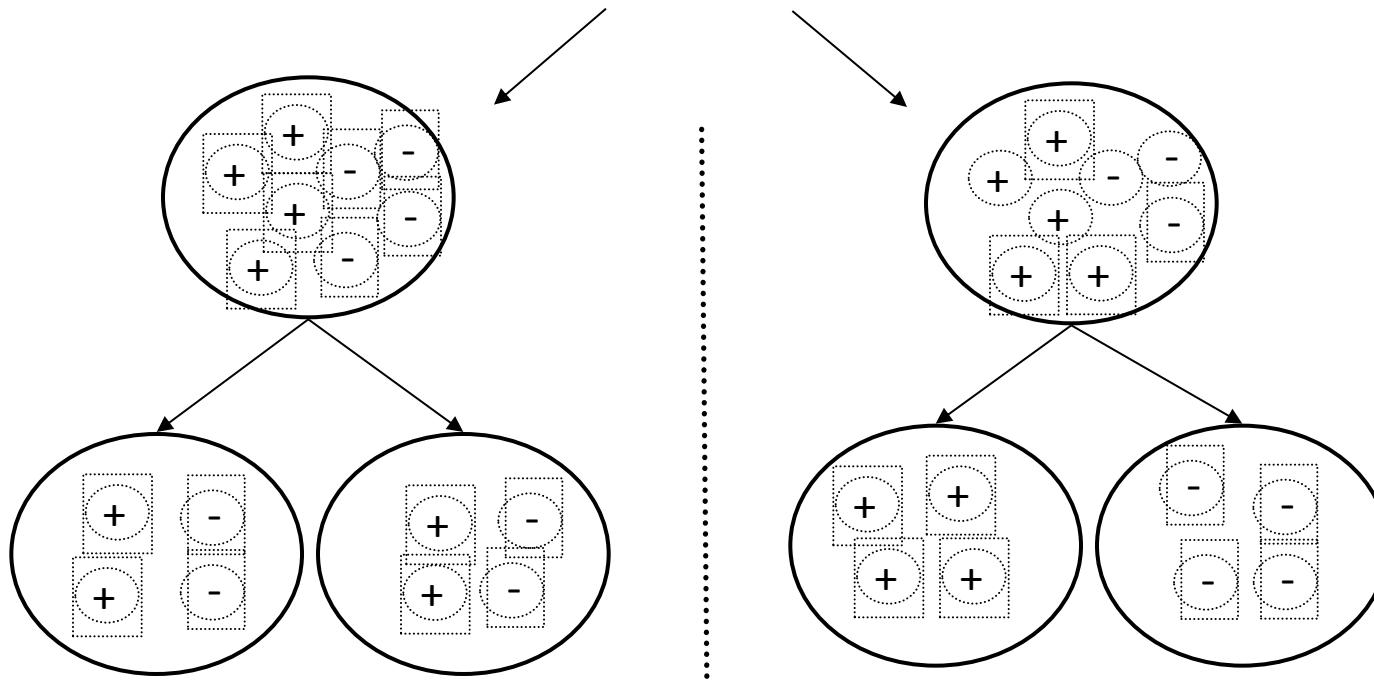
Kraj

ID3 (Quinlan)

- ID3 – algoritam za generiranje Stabla Odlučivanja
- Koristi (en. *information gain*) porast informacije u procesu izbora varijable u čvoru za podjelu primjera (split)
- Kasnije verzije C4.5 (=J48 – WEKA), C5

Porast informacije (stvaranje homogenijih grana)

Velika nesigurnost



Velika nesigurnost

**Niska nesigurnost
Dobra podjela !**

Entropija

- Entropija u skupu T primjera za binarni (1/0) klasifikacijski problem :

$$E(T) = -p_1 \log_2(p_1) - p_0 \log_2(p_0)$$

- p_1 udio primjera klase 1 u skupu T
- p_0 udio primjera klase 0 u skupu T

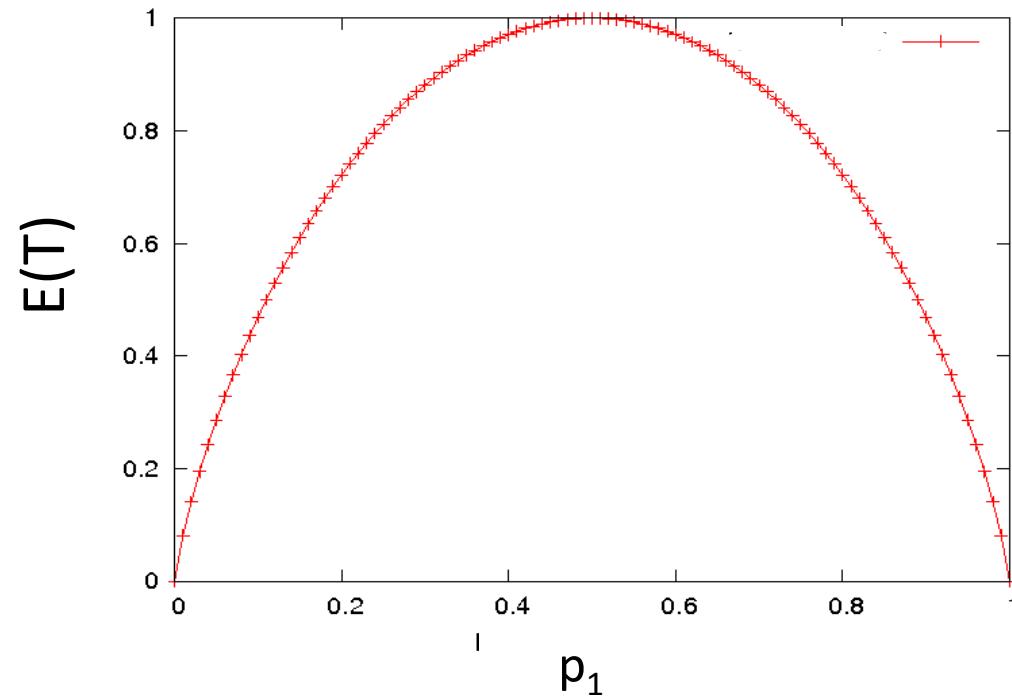
Za $p_1 / p_0 = 1$, $E(T)=0$, za $p_1 / p_0 = 0.5$ $E(T)=1$.

- Za probleme s više klasa :
$$E(T) = -\sum_i p_i \log_2(p_i)$$

Teorija informacija:

$E(X)$ - očekivani broj bitova potreban da se kodira slučajno odabrana vrijednost iz skupa X

Entropija



$$E(T) = -p_1 \log_2(p_1) - p_0 \log_2(p_0)$$

Porast informacije (en. information gain)

$$\text{InfoGain}(V) = \text{Porin}(V) = E(p_1, p_0) - \sum_{i=1}^{N_V} \frac{n_i}{N} \cdot E(p_{1,i}, p_{0,i})$$

- p_1, p_0 : broj (1,0) primjera u čvoru
 - $E(p_1, p_0)$: entropija uz dane p and n
 - N_V : broj mogućih vrijednosti (v_i) varijable V
 - n_i : broj primjera u grani i induciranoj split-om $V=v_i$
 - N : broj primjera u čvoru na koje radimo split
-
- ID3 bira varijablu s najvećim porastom informacije za podjelu !

Pimjer odabira atributa za split

Skup primjera u čvoru

| x1 | x2 | x3 | y |
|-------|-------|----------|---|
| velik | težak | Plosnat | 1 |
| mali | težak | Plosnat | 1 |
| mali | težak | zaobljen | 0 |
| velik | lagan | Plosnat | 0 |

$$\text{InfoGain}(V) = \text{Porin}(V) = E(p_1, p_0) - \sum_{i=1}^{N_v} \frac{n_i}{N} \cdot E(p_{1,i}, p_{0,i})$$

$$\text{Porin (X1)} = 1 - (0.5 \cdot 1 + 0.5 \cdot 1) = 0$$

$$\text{Porin (X2)} = 1 - (0.75 \cdot 0.918 + 0.25 \cdot 0) = \underline{\underline{0.311}}$$

$$\text{Porin (X3)} = 1 - (0.75 \cdot 0.918 + 0.25 \cdot 0) = \underline{\underline{0.311}}$$

Varijable s numeričkim vrijednostima

- Domena V je numerička:

$$\text{Domena}_V = \{10 - 250\}$$

- Kako je podijeliti ?

- Mogućnost: **diskretizacija**:

$$\text{Domena}_V = \{10 - 40, 40 - 120, 120 - 250\}$$

Problemi:

- Koja diskretizacija je najbolja?
- Kako razlikovati primjere u istom intervalu
 - Ako V predstavlja ocjene-bodove, nema razlike između čaka unutar intervala 40-120 !

Varijable s numeričkim vrijednostima

- Rješenje: dinamička podjela

Poredaj primjere prema vrijednosti V – sortiranje

a. Za svaki $x_i \in \text{Domene}(V)$

- Probaj podijeliti u 2 dijela: $(x \in d_1) \leq x_i$ i $(x \in d_2) > x_i$
- Izmjeri *InfoGain/Porin* podjele

b. Samo između vrijednosti kod kojih dolazi do promjene klase

| | | | | | | | | | | |
|--------|---|----|----|----|----|----|----|----|----|-----|
| X_i | : | 40 | 45 | 50 | 71 | 78 | 85 | 88 | 90 | 100 |
| class: | | 0 | 0 | 1 | 1 | 1 | 0 | 0 | 0 | 1 |

Overfitting u stablima odlučivanja

- Naučiti stablo koje perfektno klasificira primjere iz skupa za učenje u principu vodi na lošije rezultate na novim primjerima !

2 razloga:

- Šum u podacima – koji onda nastojimo “naučiti”
- Algoritam prilikom generiranja stabla radi split-ove na malo podataka – što znači da su te odluke (statistički) nepouzdane

Prevencija overfittinga u stablima odlučivanja

2 osnovna pristupa

❑ Ograničavanje rasta (en. Prepruning):

- Zaustavljanje rasta stabla u toku konstrukcije kada je broj podataka premali za dobivanje pouzdane odluke

❑ Rezanje po završetku stabla (en. Postpruning):

- Konstruiramo kompletno stablo, a nakon toga režemo pod-stabla koja ne poboljšavaju točnost ukupnog stabla – pritom označujemo listove koji rezultiraju rezanjem sa oznakom klase koja prevladava
- Metode koje koristimo za to koja pod-stabla ćemo “odrezati”:
 - Unakrsna validacija
 - Izdvojimo unaprijed dio podataka za validaciju
 - Statistički testovi

Problemi

- ❑ Porast informacije preferira atributе sa mnogo vrijednosti
 - ❑ Moguće rješenje

$$GainRatio(T, V) = \text{Porin_norm}(T, V) = \frac{\text{Porin}(T, V)}{\text{SplitI}(T, V)}$$

$$\text{SplitI}(T, V) = -\sum_{i=1}^c \frac{|T_i|}{|T|} \cdot \log_2 \frac{|T_i|}{|T|}$$



- ❑ Gdje su T_i podskupovi T koji nastaju splitom na V (primjeri s vrijednostи v_i)

Problemi

- Nedostajuće vrijednosti u primjerima ($x_i = \{13, 54, M, ?, Da, 345, \dots\}$)

Mogući pristupi

- Ako čvor n "testira" varijablu V , za primjer koji ima nedostajuću vrijednost za V :
 - a) pridijeli najčešću vrijednost za primjere u koji su u čvoru n
 - b) pridijeli najčešću vrijednost za V koju imaju primjeri iste klase koji su u čvoru n
 - c) Dodijeli vjerojatnost p_i svakoj mogućoj vrijednosti v_i varijable V , te proslijedi udio p_i svakoj grani i koja ide iz čvora
- Kada se klasificiraju novi primjeri – koristi se ista shema kao i kod učenja !

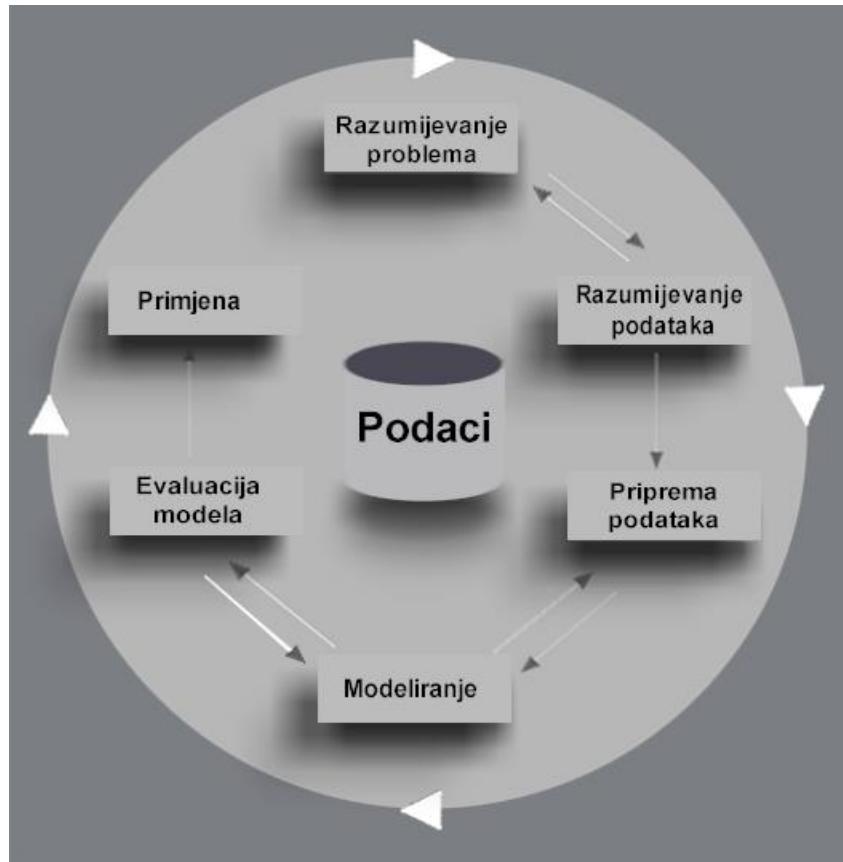
Različite varijante algoritma

- ❑ Stabla odlučivanja za regresijske probleme - ciljne varijable s realnim vrijednostima (en. regression trees)
- ❑ Kombiniranje i testiranje više atributa u čvoru
- ❑ Različiti uvjeti za split

Osnovni algoritmi

- K-nn, Nbayes i Stabla Odlučivanja
 - vrlo često se koriste u dubinskoj analizi podataka

DM – kao standardni proces (CRISP-DM)



| | Važnost | Trajanje |
|---------------------------------------------|---------|----------|
| Razumijevanje problema i podataka | 80 % | 20% |
| Priprema podataka, modeliranje i evaluacija | 20 % | 80% |

Literatura:

Machine learning,

T. Mitchel (djelovi ch. 3,6,8)

The Elements of Statistical Learning

Hastie, Tibshirani, Friedman (ch. 2)