

Opcé napomene

Ø-1

1. Nezávisnost, uvjetna nezávisnost - ~~produkt~~ produkt i "brisanje" argumenta:

(A) Bezuvjetna nezávisnost slučajnih varijabli X i Y :
produkt: $P(X, Y) = P(X) \cdot P(Y)$

brisanje drugog argumenta (jedan uvjet):

$$P(X|Y) = P(X)$$

$$P(Y|X) = P(Y)$$

(B) Uvjetna nezávisnost sl. varijabli X, Y , za dani Z
produkt (u prvom argumentu):

$$P(X, Y|Z) = P(X|Z) \cdot P(Y|Z)$$

brisanje drugog argumenta - prema uvjetnoj nezav.

$$P(X|Y, Z) = P(X|Z) \quad Y \text{ se briše}$$

$$P(Y|X, Z) = P(Y|Z) \quad X \text{ se briše}$$

Sve ostalo se prvo mora svesti na nešto od ovoj, a to ide po Bayesovom pravilu ("okreće" argumente!).

2. Bayesova mreža smije imati nišak grafa, sve dok graf ostaje usmjeren i aciklički.

Nišak grafa se kasnije može eliminirati i to računanjem odgovarajućih distribucija i provjerom (uvjetne) nezávisnosti (v. gore). To NE IDE topološkim ili grafovskim algoritmom - poput d-separacije!

Uočiti - ako čvorove numeriramo "topološki", tj. tako da roditelji dolaze prije djece, onda laučano pravilo

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | X_{1,-}, X_{i-1})$$

koje uvijek vrijedi, odgovara Bayesovoj mreži koja je potpuni usmjereni aciklički graf!

$$\text{parents}(X_i) = \{X_{1,-}, X_{i-1}\}$$

Prinyeua na Zad.1 (a)

(ii) Ova mreža je potpun graf

$$X_1 = \text{Omot}, X_2 = \text{Oblik}, X_3 = \text{Okus}$$

i sigurno je korektna, tj. što god pisalo u tablicama uvjetnih vjerojatnosti (CPT) u dvorovima, dobivamo korektnu združenu distribuciju.

Problem = mreža je neprirodna, ima previše grana i iz zadanog teksta treba ozbiljno računati da se nađu sve 3 CPT.

(iii) je očito korektna - prema tekstu i ima jednu granu mauje - koja odražava uvjetnu nezavisnost Omot i Oblik za dati Okus, a CPT se trujaluo napisu.

(i) nije korektna, jer graf (prema topološkoj semantici) tvrdi da su Omot i Oblik nezavisne, tj

$$\begin{aligned} \text{ili} \quad & P(\text{Omot} | \text{Oblik}) = P(\text{Omot}) \\ \text{ili} \quad & P(\text{Oblik} | \text{Omot}) = P(\text{Oblik}) \\ \text{ili} \quad & P(\text{Omot}, \text{Oblik}) = P(\text{Omot}, \text{Oblik}) \end{aligned}$$

No, ako iz teksta ili mreže (iii) izračunamo distribucije na lijevoj i desnoj strani, izlazi da ove jednakosti NE vrijede.

Sintaksa Bayesove mreže za n slučajnih varijabli X_1, \dots, X_n

- skup od n čvorova, svaki čvor odgovara jednoj slučajnoj varijabli X_i (varijabla = ime čvora)
- usmjereni grana između dva čvora opisuje izravni utjecaj polaznog čvora = roditelja, na dolazni čvor = dijete.

Cijeli graf mora biti usmjereni aciklički graf.

- u svakom čvoru X_i zadana je ujetna distribucija vjerojatnosti

$$P(X_i | \text{Parents}(X_i))$$

koja zadaje vjerojatnosti čvora X_i za dane (poznate) sve njegove roditelje $\text{Parents}(X_i)$.

- Globalna ili numerička semantika mreže:

potpuna združena distribucija vjerojatnosti (konjunkcija) svih varijabli X_1, \dots, X_n je produkt (prema Bayesovom laičanom pravilu) lokalnih ujetnih distribucija vjerojatnosti

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{parents}(X_i))$$

gdje su x_1, \dots, x_n konkretne vrijednosti varijabli, a $\text{parents}(X_i)$ su konkretne vrijednosti roditelja od X_i .

Na razinu distribucija

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | \text{Parents}(X_i))$$


(produkt = produkt po jezicima)

- Lokalna ili topološka semantika iz strukture grafa:

svaki čvor X_i je ujetno nezavisan od svih svojih nesljedbenika (nepotomaka), ako su dani (kao ujet/dolaz) njegovi roditelji $\text{Parents}(X_i)$.

"Bombarni iznenadjenja" - pomotene mreže:

1-2



(a) Iz teksta zadatka je očit da Okus ne ovisi ni o čemu (tj. nema roditelja), dok Omot i Oblik izravno ovisi o Okusu.

Dakle, Omot i Oblik su međusobno zavisne - porast vjerojatnosti jedne povlači porast vjerojatnosti druge varijable - preko Okus.

(i) NE VALJA - jer nema veze između Omot i Oblik. Po lokalnoj semantici, to bi značilo da su Omot i Oblik nezavisne - v. odgovor na (c).

(ii) MOŽE reprezentirati bilo koju distribuciju jer je mreža potpuna (između svaka dva čvora ima veza u jednom smjeru).

Naravno, to nije prirodna mreža (po smjeru veza) i zato ima previše veza.

(iii) MOŽE, i to je prirodna mreža za ovaj problem, s najmanjim brojem veza (veze su kauzalne).

(b) Mreža (iii) je najbolja - ima najmanje veza i veze imaju prirodan = kauzalan smjer. Dodatno, v. odgovor na (d).

(c) U mreži (i) nema veze od Omot prema Oblik. Po lokalnoj (topološkoj) semantici, čvor Omot je ujedno nezavisan od svih svojih usljedbenika za dane njegove roditelje.

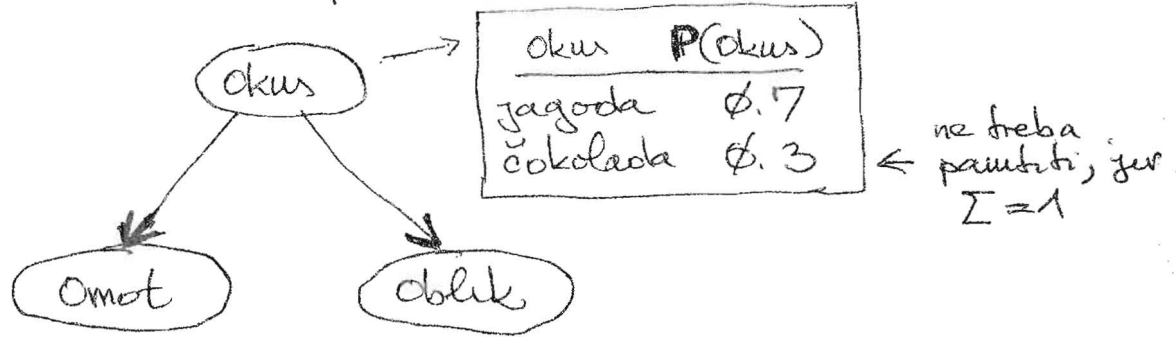
No, Omot nema roditelja \Rightarrow ujedna nezavisnost prelazi u bezuvjetnu, a Oblik nije sljedbenik od Omot (nema te veze). Dakle, Omot i Oblik su nezavisne, tj. vrijedi $P(\text{Omot}|\text{Oblik}) = P(\text{Omot})$.
Odgovor je DA - i baš zato mreža (i) NE VALJA.

(d) Iz lokalne (topološke) semantike u (iii) sledi:

- Za varijablu Okus \rightarrow ništa, jer su joj preostale druge varijable sledbenici.
- Za Omot i Oblik \rightarrow njih druge su uvjetno nezavisne za danu Okus (roditelj za obje).

Tožno ova nezavisnost izlazi iz teksta zadatka: kad znamo Okus, odgovarajući bomboni se nezavisno oblikuju i pakiraju (prema opisanju pravilima).
Zato mreža (iii) korektno/najbolje prikazuje problem.

(e) U najboljoj mreži (iii), pripadne tablice uvjetnih distribucija vjerojatnosti (CPT) izlaze izravno iz mjednosti u opisu problema:



Okus	Omot	P(Omot Okus)	Okus	Oblik	P(Oblik Okus)
jagoda	crveni	0.8	jagoda	krugli	0.8
jagoda	smeti	0.2	jagoda	kockasti	0.2
čokolada	crveni	0.1	čokolada	krugli	0.1
čokolada	smeti	0.9	čokolada	kockasti	0.9

Dovoljno je pamtititi po željan red od prva i od zadnja dva reda, jer je $\sum(p_{mi}, d_{ugi}) = \sum(t_{reei}, č_{etvrhi}) = 1$

Napomena: Za mrežu (iii), za uvažavanje odgovarajućih CPT imamo što za računati - hrpa posla, jer je mreža neprirodna!

(f) Traži se vjerojatnost $P(\text{Omot} = \text{crveni})$.

To ovisi samo o Okusu (ne o Obliku - možemo ga eliminirati kao varijablu).

Po Bayesovom pravilu - za distribucije vjerojatnosti

$$P(\text{Omot}) = P(\text{Omot} | \text{Okus}) \cdot P(\text{Okus})$$

pa uvrstimo $\text{Omot} = \text{crveni}$ i marginaliziramo = ~~z~~ zbrojimo po svim vrijednostima Okusa:

Okus=...

$$P(\text{Omot} = \text{crveni}) = P(\text{Omot} = \text{crveni} | \text{Okus} = \text{jagoda}) \cdot P(\text{jagoda}) \\ + P(\text{Omot} = \text{crveni} | \text{Okus} = \text{čokolada}) \cdot P(\text{čokolada})$$

$$= 0.8 \cdot 0.7 + 0.1 \cdot 0.3 = 0.56 + 0.03$$

$$= \underline{0.59}$$

Usput, to znači da je $P(\text{Omot} = \text{smeđi}) = 0.41$.

(g) Zadani su "dokazi" $\text{Omot} = \text{crveni}$ i $\text{Oblik} = \text{okrugli}$, a traži se vjerojatnost

$$P(\text{Okus} = \text{jagoda} | \text{Omot} = \text{crveni}, \text{Oblik} = \text{okrugli}).$$

Možemo izračunati potpunu združenu distribuciju i onda ~~je~~ očitati pripadni redak.

Međutim, lakše je stvar "okrenuti" po Bayesovom pravilu i onda izravno koristiti poznate podatke iz mreže

$$P(\text{Okus} | \text{Omot} = \text{crveni}, \text{Oblik} = \text{okrugli}) = \{ \text{okret po Bayesu} \}$$

$$= \alpha \cdot P(\text{Omot} = \text{crveni}, \text{Oblik} = \text{okrugli} | \text{Okus}) \cdot P(\text{Okus})$$

$$= \{ \text{uvjetna nezavisnost Omot i Oblik za dati Okus} \}$$

$$= \alpha \cdot P(\text{Omot} = \text{crveni} | \text{Okus}) \cdot P(\text{Oblik} = \text{okrugli} | \text{Okus}) \cdot P(\text{Okus})$$

Računamo distribuciju za oba okusa, tako da na kraju možemo naći normalizacijsku konstantu α da suma bude jednaka 1.

Potrebni verjetni duljine 2 (za oba okusa), s tim da je poredak prvo jagoda, pa onda čokolada:

$$P(\text{Omot} = \text{crveni} \mid \text{Okus}) = \langle \phi.8, \phi.1 \rangle \quad \text{iz CPT u Omot}$$

$$P(\text{Oblik} = \text{okrugli} \mid \text{Okus}) = \langle \phi.8, \phi.1 \rangle \quad \text{iz CPT u Oblik}$$

$$P(\text{Okus}) = \langle \phi.7, \phi.3 \rangle \quad \text{iz CPT u Okus}$$

Traženi produkt po točkama je

$$\begin{aligned} P(\text{Okus} \mid \text{Omot} = \text{crveni}, \text{Oblik} = \text{okrugli}) \\ = \alpha \cdot \langle \phi.8 \cdot \phi.8 \cdot \phi.7, \phi.1 \cdot \phi.1 \cdot \phi.3 \rangle \\ = \alpha \cdot \langle \phi.448, \phi.\phi\phi3 \rangle \end{aligned}$$

$$\Rightarrow \alpha = \frac{1}{\phi.451} = 2.21729\ 49\phi\phi2 \dots$$

$$\begin{aligned} P(\text{Okus} \mid \text{Omot} = \text{crveni}, \text{Oblik} = \text{okrugli}) &= \left\langle \frac{448}{451}, \frac{3}{451} \right\rangle \\ &= \langle \phi.99334\ 81153\dots, \phi.\phi\phi665\ 18847\dots \rangle \end{aligned}$$

Dakle, odgovor za okus jagode je


$$P(\text{jagoda} \mid \text{crveni}, \text{okrugli}) = \phi.99334\ 81153\dots$$

2. zad. - rješenje

2-1

Bayesova mreža za "model" geologija sladoleda

V_1	$P(V_1)$
k	0.4
s	0.6



V_1	V_2	$P(V_2 V_1)$	
k	k	0.5	} $\Sigma = 1$
k	s	0.5	
s	k	0.3	} $\Sigma = 1$
s	s	0.7	

V_i	S_i	$P(S_i V_i)$	
k	d	0.2	} $\Sigma = 1$
k	n	0.8	
s	d	0.9	} $\Sigma = 1$
s	n	0.1	

(a) Traži se empirijska vjerojatnost $\hat{P}(V_2=k)$ na bazi uzorka

(k,n,k,n) (k,n,k,n) (s,n,s,d) (s,d,s,d) (s,d,k,n)
 (k,n,k,d) (s,d,s,d) (s,d,s,d) (s,d,k,n) (k,n,s,d)

(poredak varijabli u uzorku je (V_1, S_1, V_2, S_2)).

$$\hat{P}(V_2=k) = \frac{\text{broj uzoraka s } V_2=k}{\text{broj svih uzoraka}} = \frac{5 \text{ (uzorci 1, 2, 5, 6, 9)}}{10}$$

tj. $\boxed{\hat{P}(V_2=k) = 0.5}$

Napomena: pripadna "stvarna" vjerojatnost iz mreže je

$$\begin{aligned} P(V_2=k) &= P(V_2=k|V_1=k) \cdot P(V_1=k) + P(V_2=k|V_1=s) \cdot P(V_1=s) \\ &= 0.5 \cdot 0.4 + 0.3 \cdot 0.6 = 0.20 + 0.18 \\ &= 0.38 \end{aligned}$$

(b) Kad su zadani dokazi $E=e$ u mreži, odbacuju se uzoraka preskače = odbacuje sve uzorke koji se ne slažu s dokazima, tj. u reduciranom uzorku ostaju samo oni koji se slažu s dokazima.

Zatim se zaključuje "empirijski" = broj povoljnih/svih na temelju reduciranog uzorka.

Za dane dołaze $S_1=d$ i $S_2=n$, nakon odbacivanja u reduciranom uzorku ostaju samo 5. i 9. uzorak

$$(s, d, k, n) \quad (s, d, k, n)$$

tj. imamo samo 2 uzorka.

U oba je $V_2=k$, tj. nema uzorka s $V_2=s$. Onda je

$$\hat{P}(V_2 | S_1=d, S_2=n) = \left\langle \frac{2}{2}, \frac{0}{2} \right\rangle = \langle 1, 0 \rangle$$

$k \quad s$

$$\hat{P}(V_2=k | S_1=d, S_2=n) = 1$$

(c) Metoda težinske izglednosti (vjerođostojnosti) uzorkuje samo nedokazne varijable (uključivo i varijablu uputa) a dołazi se smatraju fiksima.

Ako su Z sve nedołazne varijable, onda je uzorak vjerođatnost za naku moguću vjedoost $Z=z$, uz fiksne dołaze $E=e$, jednaka (po pravilu za Bayesove mreže)

$$S_{WS}(z, e) = \prod_{i=1}^e P(z_i | \text{parents}(z_i))$$

gdje su z_1, \dots, z_e sve nedołazne varijable.

- Iz globalne semantike Bayesove mreže, odgovarajuća vjerođatnost za "združeni" događaj (z, e) (koji pokriva sve varijable u problemu je

$$P(z, e) = \prod_{i=1}^n P(x_i | \text{parents}(x_i))$$

gdje je $\{x_1, \dots, x_n\} = \{z_1, \dots, z_e\} \cup \{e_1, \dots, e_m\}$, a e_1, \dots, e_m su dokazne varijable.

Da bismo iz $S_{WS}(z, e)$ dobili konzistentnu progenu s pravom distribucijom, svaki uzorak (z, e) mora dołati faktor = težinu

$$w(z, e) = \prod_{k=1}^m P(e_k | \text{parents}(e_k))$$

prema odgovarajućim dołazima u mreži.

Onda je

$$S_{ws}(z, e) \cdot w(z, e) = P(z, e).$$

Umjesto "broj porođnih" i "broj svih", za prozjenu vjerojatnosti koristimo zbroj odgovarajućih težina

Ako je X upitna varijabla, a x_p neka od njezinih vrijednosti onda je prozjena vjerojatnosti $P(X=x_p|e)$ dana ovako:

$$P(X=x_p|e) = \frac{\text{zbroj težina uzoraka u kojima je } X=x_p}{\text{zbroj težina svih uzoraka}}$$

(d) Fiksne vrijednosti dokaznih varijabli S_1, S_2 su
 $S_1 = d, S_2 = n$.

(Svih 6 uzoraka ima te fiksne vrijednosti, variraju samo vrijednosti za V_1, V_2).

Prvo treba odrediti težine svih 6 uzoraka. Težina w pojediniog uzorka

$$(V_1 = v_1, \underbrace{S_1 = d}_{\text{draz}}, V_2 = v_2, \underbrace{S_2 = n}_{\text{draz}})$$

računa se iz konkretnih vrijednosti v_1 i v_2

$$w = P(S_1 = d | V_1 = v_1) \cdot P(S_2 = n | V_2 = v_2)$$

Tablica težina za zadanih 6 uzoraka je

(v_1, d, v_2, n)	$P(d v_1)$	$P(n, v_2)$	$w = P(d v_1) \cdot P(n v_2)$
(s, d, k, n)	0.9	0.8	0.72
(k, d, k, n)	0.2	0.8	0.16
(s, d, k, n)	0.9	0.8	0.72
(s, d, s, n)	0.9	0.1	0.09
(s, d, s, n)	0.9	0.1	0.09
(k, d, s, n)	0.2	0.1	0.02

U svih 6 uzoraka, prva tri imaju $V_2 = k$ (tzv. porođni) pa je prozjena vjerojatnost:

$$\hat{P}(V_2 = k | S_1 = d, S_2 = n) = \frac{0.72 + 0.16 + 0.72}{0.72 + 0.16 + 0.72 + 0.09 + 0.09 + 0.02} = \frac{1.60}{1.80} = \frac{8}{9} = 0.88889$$

3. zad. - rješenje

(a) Entropija slučajne varijable X s diskretnim vrijednostima x_i koje imaju vjerojatnosti $p_i = P(X=x_i)$ je

$$H(X) = - \sum_n p_n \log_2 p_n$$

(broj bitova potreban za kodiranje "odgovora").

U zadatku primjeru "ciljna" varijabla je klasa s dužje moguće vrijednosti $+$ i $-$.

Cilj kod konstrukcije stabla odlučivanja je što brže smanjiti učajnu entropiju, na osnovu odgovarajućeg uzorka u danom čvoru, koji još nije potpuno "klasificiran".

Skup (preostalih) podataka D u danom čvoru ima polaznu entropiju $H(D)$ - koju računamo empirijski, na temelju tog skupa podataka.

Za sve (preostale) atribute, koji još nisu iskonstruirani treba izračunati pripadnu učajnu entropiju, kao srednju vrijednost (očekivanje na bazi uzorka), po svim mogućim vrijednostima tog atributa.

Konkretno, dati atribut A_i s k vrijednosti a_{i1}, \dots, a_{ik} particionira sve primjere D u k disjunktih podskupova

$$D_1, \dots, D_k$$

$D_j = \{n \text{ primjeri u kojima je } A_i = a_{ij}, j=1, \dots, k$

Entropija ciljne varijable X na skupu D_j je

$$\underbrace{H(X | A_i = a_{ij})}_{\text{entropija } (D_j)} = - \sum_n P(X=x_n | A_i=a_{ij}) \log_2 P(X=x_n | A_i=a_{ij})$$

a pripadno očekivanje je

$$\underbrace{H(X | A_i)}_{\text{entropija } A_i(D)} = \sum_{j=1}^k P(A_i = a_{ij}) \cdot H(X | A_i = a_{ij})$$

(ako su vrijednosti jednako vjerojatne)

$$= \sum_{j=1}^k \frac{|D_j|}{|D|} \cdot \underbrace{H(X | A_i = a_{ij})}_{\text{entropija } (D_j)}$$

Dobitak informacije odabirou atributa A_i za grananje u tom čvoru stabla je

$$\begin{aligned}
I(D, A_i) &= \text{dobitak}(D, A_i) = \cancel{H(D)} \\
&= H(X) - H(X|A_i) \\
&= \text{entropija}(D) - \text{entropija}_{A_i}(D)
\end{aligned}$$

Za grananje biramo onaj atribut A_i (među preostalima) koji daje maksimalni dobitak informacije, tj. onaj koji ima najmanju entropiju ($\text{entropija}_{A_i}(D)$).

- U našem skupu primjera, sve vrijednosti atributa su jednako vjerojatne

1. Na početku skup D sadrži sih 6 primjera. Imamo 3 primjera klase + i 3 primjera klase -, pa za ciljni varijablu klasa vrijedi

$$P_+ = P_- = \frac{1}{2}$$

Entropija polaznog skupa D je:

$ \begin{aligned} \text{entropija}(D) &= H(\text{klasa}) = - (P_+ \log_2 P_+ + P_- \log_2 P_-) = 1 \\ &\quad \quad \quad \frac{1}{2} \quad -1 \quad \quad \frac{1}{2} \quad -1 \end{aligned} $
--

tj. nema informacije = maksimalni nered.

2. Tražimo najbolji atribut za konjenje (pri čvor) stabla.

2a. Izbor $A_i = \text{Boja}$. Imamo 3 vrijednosti: crvena, plava, zelena

$D_1 = (\text{Boja} = \text{crvena})$ - ima 3 primjera {1, 3, 5}

$D_2 = (\text{Boja} = \text{plava})$ - ima 1 primjer {2}

$D_3 = (\text{Boja} = \text{zelena})$ - ima 2 primjera {4, 6}

Treba naći entropije svakog od ovih skupova prema klasi.

$$\begin{aligned}
\text{entropija}(D_1) &= \{2+, 1-\} = - \left(\frac{2}{3} \log_2 \frac{2}{3} + \frac{1}{3} \log_2 \frac{1}{3} \right) \\
&= - \left(\frac{2}{3} \log_2 2 - \frac{2}{3} \log_2 3 + \frac{1}{3} \log_2 1 - \frac{1}{3} \log_2 3 \right) \\
&= \log_2 3 - \frac{2}{3} = 0.91829 \ 58341
\end{aligned}$$

$$\text{entropija } (D_2) = \{1+\} = -1 \cdot \log_2 1 = 0$$

$$\text{entropija } (D_3) = \{2-\} = -0 \cdot \log_2 0 - 1 \cdot \log_2 1 = 0$$

Pripadna srednja vrijednost

$$\begin{aligned} \text{entropija Boga } (D) &= \frac{3}{6} \cdot \text{entropija } (D_1) + \frac{1}{6} \cdot \text{entropija } (D_2) \\ &\quad + \frac{2}{6} \cdot \text{entropija } (D_3) \\ &= \frac{1}{2} \cdot (\log_2 3 - \frac{2}{3}) \\ &= \underline{\underline{0.4591479176}} \end{aligned}$$

2b. Izbor $A_i = \text{Oblik}$. Imamo 2 vrijednosti: kvadrat¹, kmg²

$$D_1 = (\text{Oblik} = \text{kvadrat}) - \text{ima 4 primjera } \{1, 2, 4, 6\}$$

pripadna entropija

$$\text{entropija } (D_1) = \{2+, 2-\} = -\frac{2}{4} \log_2 \frac{2}{4} - \frac{2}{4} \log_2 \frac{2}{4} = 1$$

$$D_2 = (\text{Oblik} = \text{kmg}) - \text{ima 2 primjera } \{3, 5\}$$

$$\text{entropija } (D_2) = \{1+, 1-\} = 1$$

Pripadna srednja vrijednost

$$\begin{aligned} \text{entropija objekat } (D) &= \frac{4}{6} \cdot \text{entropija } (D_1) + \frac{2}{6} \cdot \text{entropija } (D_2) \\ &= \underline{\underline{1}} \end{aligned}$$

2c. Izbor $A_i = \text{Veličina}$. Imamo 2 vrijednosti: velika¹, mala²

$$D_1 = (\text{Veličina} = \text{velika}) - \text{ima 4 primjera } \{1, 2, 5, 6\}$$

$$\begin{aligned} \text{entropija } (D_1) &= \{3+, 1-\} = -\frac{3}{4} \log_2 \frac{3}{4} - \frac{1}{4} \log_2 \frac{1}{4} \\ &= -\frac{3}{4} \log_2 3 + \log_2 4 = 2 - \frac{3}{4} \log_2 3 \\ &= 0.8112781245 \end{aligned}$$

$$D_2 = (\text{Veličina} = \text{mala}) - \text{ima 2 primjera } \{3, 4\}$$

$$\text{entropija } (D_2) = \{\text{~~0+~~ } 0+, 2-\} = 0$$

Srednja vrijednost

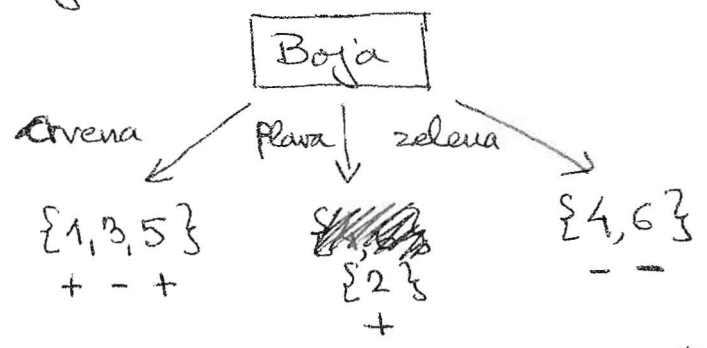
$$\begin{aligned} \text{entropija Veličina } (D) &= \frac{4}{6} \cdot \text{entropija } (D_1) + \frac{2}{6} \cdot \text{entropija } (D_2) = \frac{4}{3} - \frac{1}{2} \log_2 3 \\ &= \underline{\underline{0.5408526836}} \end{aligned}$$

Tablica entropija i dobitaka informacija

Atribut A_i	entropija $A_i(D)$	dobitak (D, A_i)
Boja	$\phi.459147917\phi$	$\phi.54\phi852\phi83\phi$
Oblik	1	0
Velicina	$\phi.54\phi852\phi83\phi$	$\phi.459147917\phi$

Najmanju entropiju / najveći dobitak informacija daje Boja, pa nju treba uzeti kao korijen stabla.

Particijom svih primjera prema vrijednosti boje dobivamo sljedeće stablo



Čvorovi "djece" za plavu i zelenu sadrže samo primjere iste klase \Rightarrow postaju listovi završnog stabla odlučivanja s klasama +, odn. -.

3. U čvoru za crvenu boju imamo 3 primjera, $D = \{1, 3, 5\}$ od čega su 2 klase + (1, 5) i 1 klase - (3).

U tom čvoru nastavljamu konstrukciju (rekurzivno), sa skupom

$$D = \{1, 3, 5\}$$

na kojemu je $P_+ = \frac{2}{3}, P_- = \frac{1}{3}$

pa je njegov "polazna" entropija

$$\begin{aligned} \text{entropija}(D) &= -\frac{2}{3} \log_2 \frac{2}{3} - \frac{1}{3} \log_2 \frac{1}{3} \quad (\text{v. ravije } D_1) \\ &= \log_2 3 - \frac{2}{3} = \phi.9182958341 \end{aligned}$$

Preostali atributi za grananje su Oblik i Velicina.

4. Traži se bolji od ta dva atributa - kao novi izvor grananja u stablu.

4a. Izbor $A_1 = \text{Oblik}$ - imamo 2 vrijednosti: kvadrat₁, kug₂.

$D_1 = (\text{Oblik} = \text{kvadrat})$ - ima 1 primjer {1}

entropija (D_1) = $\{1+, \emptyset-\} = \emptyset$

$D_2 = (\text{Oblik} = \text{kug})$ - ima 2 primjera {3, 5}

entropija (D_2) = $\{1+, 1-\} = 1$

Srednja vrijednost

$$\begin{aligned} \text{entropija}_{\text{oblik}}(D) &= \frac{1}{3} \cdot \text{entropija}(D_1) + \frac{2}{3} \cdot \text{entropija}(D_2) \\ &= \frac{2}{3} = \underline{\underline{0.66666666667}} \end{aligned}$$

4b. Izbor $A_2 = \text{Velicina}$ - imamo 2 vrijednosti: velika₁, mala₂

$D_1 = (\text{Velicina} = \text{velika})$ - ima 2 primjera {1, 5}

entropija (D_1) = $\{2+, \emptyset-\} = \emptyset$

$D_2 = (\text{Velicina} = \text{mala})$ - ima 1 primjer {3}

entropija (D_2) = $\{1-, \emptyset+\} = \emptyset$

Srednja vrijednost

$$\begin{aligned} \text{entropija}_{\text{velicina}}(D) &= \frac{2}{3} \cdot \text{entropija}(D_1) + \frac{1}{3} \cdot \text{entropija}(D_2) \\ &= \underline{\underline{\emptyset}} \end{aligned}$$

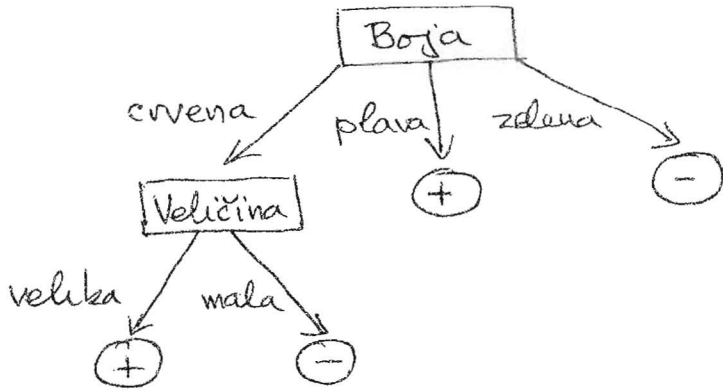
Tablica entropija i dobivene informacije (nepotrebna, sve je očit)

Atribut A_i	entropija $A_i(D)$	dobitak (D, A_i)
oblik	0.66666666667	0.2516291674
Velicina	\emptyset	0.9182958341

⇒ Treba uzeti Velicinu kao "dijete" za crvenu boju
 Oba dobivena djeteta imaju samo primjere iste klase,
 pa postaju listovi završnog stabla, a pripadne
 klase su + za "velika", - za "mala"

Svi primjeri su klasificirani ⇒ GOTOVO.

Pripadno stablo rima oblik



Uzati da oblik nema utjecaj na klasifikaciju

Klasifikacija novih primjera

1. (crvena, kvadrat, mala)
2. (plava, knjig, mala)



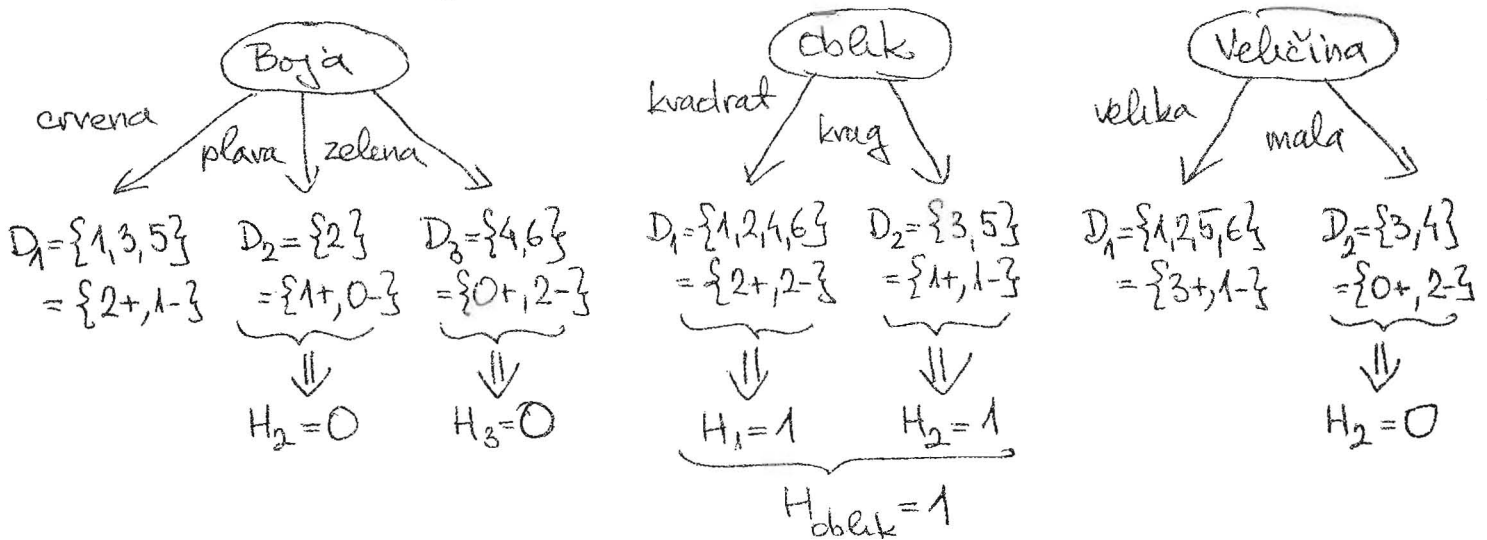
⇒ Klasa = (-)

⇒ Klasa = (+)

Grafička ilustracija konstrukcije stabla odlučivanja u pojedinim čvorovima:


1. korak: čvor = korijenu, pripadni skup primjera $D = \{1, \dots, 6\} = \{3+, 3-\}$

Klasifikacija prema vrijednostima preostalih atributa (a to su sva tri) daje

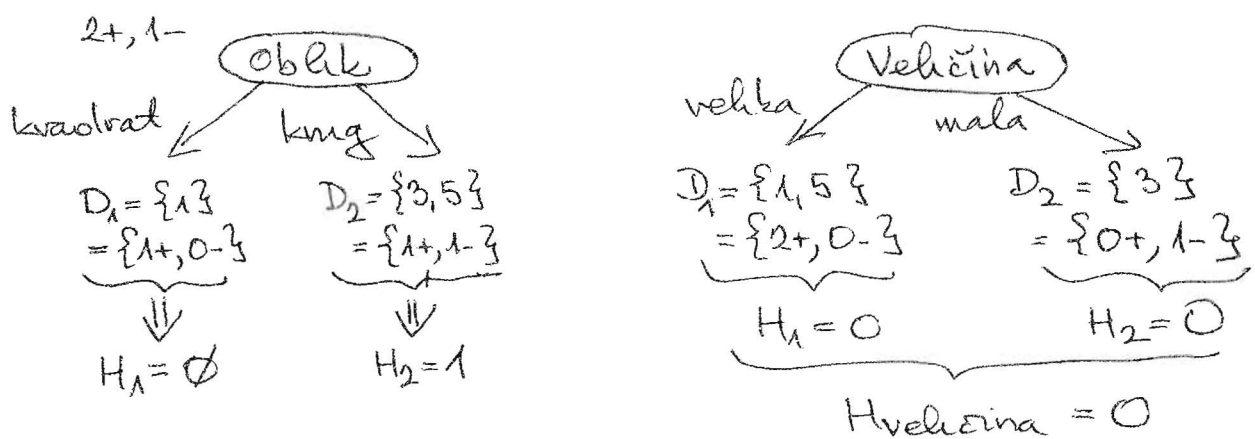


Dakle, Oblik ne daje nikakvu informaciju.

2. korak - već imamo:



u čvoru "crvena" imamo $D = \{1, 3, 5\} = \{2+, 1-\}$. Klasifikacija po preostalim atributima (Oblik, Veličina) daje



(b) Zadani je skup ili niz T od N primjera za učenje

$$x^{(i)}, i=1, \dots, N.$$

Svaki primjer $x^{(i)}$ je "vektor" koji se sastoji od n vrijednosti tzv. atributa $x_{i,j}$, za $j=1, \dots, n$ i od jedne dodatne vrijednosti $c^{(i)}$ - tzv. klase

$$x^{(i)} = (x_{i,1}, x_{i,2}, \dots, x_{i,n}, c^{(i)}).$$

Svaki pojedini atribut $x_{i,j}$ možemo interpretirati kao vrijednost odgovarajuće slučajne varijable A_j (za taj atribut na j -tom mjestu). Klasu $c^{(i)}$, također, možemo interpretirati kao vrijednost odgovarajuće slučajne varijable C , s tim da pretpostavljamo da klasa C ovisi o atributima A_1, \dots, A_n .

Bilo koji zadani "novi" primjer x ima poznate samo vrijednosti atributa, a pripadnu vrijednost klase $c = c(x)$ treba odrediti na temelju skupa podataka za učenje T ,

$$x = (x_1, \dots, x_n), \quad c = c(x) = ?$$

Za svaki novi primjer x , metoda k najbližih susjeda (k -NN) se sastoji iz 2 dijela:

(1) Pronaći indekse i_1, \dots, i_k za k najbližih susjeda novom primjeru x , među svim primjerima iz T , pri čemu se udaljenost $d(x, x^{(i)})$, $x^{(i)} \in T$ mjeri na sljedeći način

$$d(x, x^{(i)}) = \sqrt{\sum_{j=1}^n d_j^2(x_j, x_{i,j})}$$

- Euklidska udaljenost na kartezijevom produktu metričkih prostora

gdje je d_j udaljenost na prostoru atributa za varijablu A_j . U našem slučaju, svi atributi su "kategoričnog" tipa, pa koristimo trivijalnu diskretnu 0-1 metriku

$$d_j(x_j, x_{i,j}) = \begin{cases} 0, & \text{za } x_j = x_{i,j} \\ 1, & \text{za } x_j \neq x_{i,j} \end{cases}, \quad j=1, \dots, n$$

(2) Na osnovu k najbližih susjeda iz T , odredujemo klasu novog primjera, prema klasama najbližih susjeda. Kod težišnog određivanja klase, koristimo i težine za klasu svakog susjeda:

$$c(x) = \arg \max_c \sqrt{\sum_{i=1}^k w_{i,c} \cdot \delta(c, c^{(i)})}$$

Govori maksimum ide po svim mogućim vrijednostima klase $C=c$.

Funkcija δ je karakteristična funkcija na prostoru vrijednosti za klase

$$\delta(c_p, c_g) = \begin{cases} 1, & \text{za } c_p = c_g \\ 0, & \text{za } c_p \neq c_g \end{cases}$$

(odavno od diskretne 0-1 metrike).

Prema zahtjevu iz zadatka, pripadne težine $w_{i,c}$ su obrnuto proporcionalne kvadratima udaljenosti između novog i susjednog primjera iz T

$$w_{i,c} = \frac{1}{(d(x, x^{(i)}))^2}$$

Zato se kod nalaženja najbližih susjeda isplati računati $d^2(x, x^{(i)})$

bez konjeka (najbliži su isti!) = broj različitih atributa

- Za novi primjer $x = (\text{crvena}, \text{kvadrat}, \text{mala})$ tražimo 3 najbliža susjeda

i	atributi od $x^{(i)}$	$d^2(x, x^{(i)}) =$	broj različitih atributa
1	crvena kvadrat velika	1	*
2	plava kvadrat velika	2	*
3	crvena krug mala	1	*
4	zelena kvadrat mala	1	*
5	crvena krug velika	2	
6	zelena kvadrat velika	2	

} 3 najbliža susjeda

Najbliža 3 susjeda su primjeri 1, 3, 4.

- Sva tri primjera najbliži susjeda imaju 1STU udaljenost (i kvadrat)

$$d^2(x, x^{(i)}) = 1, \quad i = 1, 3, 4$$

Dakle, težine w_1, w_3, w_4 sva tri najbliža susjeda su jednake 1

$$w_1 = w_3 = w_4 = 1$$

pa možemo uzeti kao da nema težina, za određivanje klase.

~~Primeri 3, 4~~,

- Primeri 3, 4 imaju klasu "-", a primer 1 ima klasu "+" pa odmah vidimo da "-" dominira među 3 susjeda, tj.

$$c(\text{crvena, kvadrat, mala}) = -$$

- Komplikiranije = gledamo po svim usljedima za c :

$$\sqrt{\sum_{i=1,3,4} \delta(c=+, c^{(i)})} = \sqrt{\underset{1}{\delta(+,+)} + \underset{0}{\delta(+,-)} + \underset{0}{\delta(+,-)}} = \sqrt{1}$$

$$\sqrt{\sum_{i=1,3,4} \delta(c=-, c^{(i)})} = \sqrt{\underset{0}{\delta(-,+)} + \underset{1}{\delta(-,-)} + \underset{1}{\delta(-,-)}} = \sqrt{2}$$

$$\Rightarrow c(x) = -$$

(c) Uzmimo iste pretpostavke kao u (b), tj. da imamo poznat skup T primjera za učenje, zajedno s pripadnim klasama

$$x^{(i)} = (x_{i,1}, \dots, x_{i,n}, c^{(i)}) \quad , \quad i=1, \dots, N$$

i treba klasificirati nov primjer

$$x = (x_1, \dots, x_n) \quad , \quad c = c(x) = ?$$

Uzmimo da varijabla klase C ima m mogućih vrijednosti:

$$c_\ell \quad , \quad \ell = 1, \dots, m.$$

Pripadni (a priori) distribuciju vjerojatnosti $P(C)$, naravno, NE znamo, ali ju možemo "naučiti" iz zadanih podataka T za učenje.

Ideja za klasifikaciju novog primjera x je primjena Bayesovog pravila

$$P(C=c_\ell | x) = \frac{P(x | C=c_\ell) \cdot P(C=c_\ell)}{P(x)} = \alpha \cdot P(x | C=c_\ell) \cdot P(C=c_\ell)$$

gdje je α normalizacijska konstanta za nepoznatu vjerojatnost $P(x)$, tj. $\alpha = 1/P(x)$. Na razini distribucije vjerojatnosti

$$P(C|x) = \alpha \cdot P(x|C) \cdot P(C)$$

→ što da se traži maksimalna a posteriori vrijednost C_{MAP} u ovoj distribuciji, a $P(x|C)$ i $P(C)$ se procjenjuju na bazi skupa za učenje T , tj.

$$c(x) = C_{MAP} = \arg \max_c P(x|c) \cdot P(c)$$

po svim mogućim vrijednostima $c=c_\ell$, $\ell=1, \dots, m$.

- Bayesova klasifikacija procjenjuje $P(c)$ i $P(x|C)$ na osnovu skupa za učenje T .

$$P(C) = \text{lagano: } \# \frac{\text{broj primjera s klasom } C=c_\ell}{\text{broj svih primjera}} = P(c_\ell)$$

Međutim, slična procjena za $P(x_1, \dots, x_n | c_\ell)$ je gotovo nemoguća, jer bismo morali imati egzaktnu broj primjera za učenje. Ukupan broj mogućih događaja koje treba brojati (= kardinalitet prostora mogućih događaja) je

$$N_{BC} = m \cdot |A_1| \cdot \dots \cdot |A_n| \quad , \quad |A_j| = \text{broj mogućih vrijednosti atributa } A_j$$

↓
za C

Kod naivne Bayesove klasifikacije pretpostavljamo da su atributne varijable A_1, \dots, A_n ujetno nezavisne, uz danu klasu C tj.

$$P(A_1, \dots, A_n | C) = \prod_{j=1}^n P(A_j | C).$$

Za zadani primjer atributa $x = (x_1, \dots, x_n)$ to znači da pretpostavljamo da je

$$P(x_1, \dots, x_n | c_\ell) = \prod_{j=1}^n P(x_j | c_\ell), \quad \forall \ell = 1, \dots, m$$

pa nam trebaju samo ujetne vrijednosti pojedinačnih atributa x_j , za danu klasu c_ℓ .

Bitna prednost ovog modela je što je ukupan broj mogućih događaja za model

$$N_{NBC} = m \cdot (|A_1| + \dots + |A_n|)$$

tj. trebamo mnogo manje skup podataka za učenje da bismo (na uzorku) procijenili

$$P(x_j | c_\ell) = \frac{\text{broj primjera s klasom } c_\ell \text{ u kojima je } A_j = x_j}{\text{broj primjera s klasom } c_\ell}$$

- Algoritam: Na bazi skupa T računamo procjene za $P(c_\ell)$, Za zadane attribute x_j računamo procjene za $P(x_j | c_\ell)$, iskoristimo naivno Bayesovo pravilo za računanje

$$P(x_1, \dots, x_n | c_\ell) = \prod_{j=1}^n P(x_j | c_\ell)$$

i zatim tražimo vrijednost C_{MAP} za koju se dostiže maksimum

$$P(x_1, \dots, x_n | c_\ell) \cdot P(c_\ell), \quad \ell = 1, \dots, m.$$



U našem primjeru, moguće klase su $+$ i $-$, a na 6 primjera iz skupa T dobivamo

$$P(C=+) = P(C=-) = \frac{1}{2}$$

(imamo po 3 primjera svake klase). Onda je još lakše, treba naći

$$C_{MAP} = C_{ML} = \max_c \arg P(x|c) = \max_c \arg \prod_{j=1}^n P(x_j|c).$$

Novi priuyer je ^{x=} (crvena, kvadrat, mala)

Treba naći wzjetne vjerovatnosti svakog od svih atributa, za sve uopucé klase.

Za C = + : imamo N₊ = 3 priuyera.

P(crvena | +) = (imamo 2 priuyera) = 2/3

P(kvadrat | +) = (- " -) = 2/3

P(mala | +) = (imamo 0 priuyera) = 0

=> P(x | ~~C+~~) = 2/3 * 2/3 * 0 = 0

Za C = - : imamo N₋ = 3 priuyera.

P(crvena | -) = (imamo 1 priuyer) = 1/3

P(kvadrat | -) = (imamo 2 priuyera) = 2/3

P(mala | -) = (imamo 2 priuyera) = 2/3

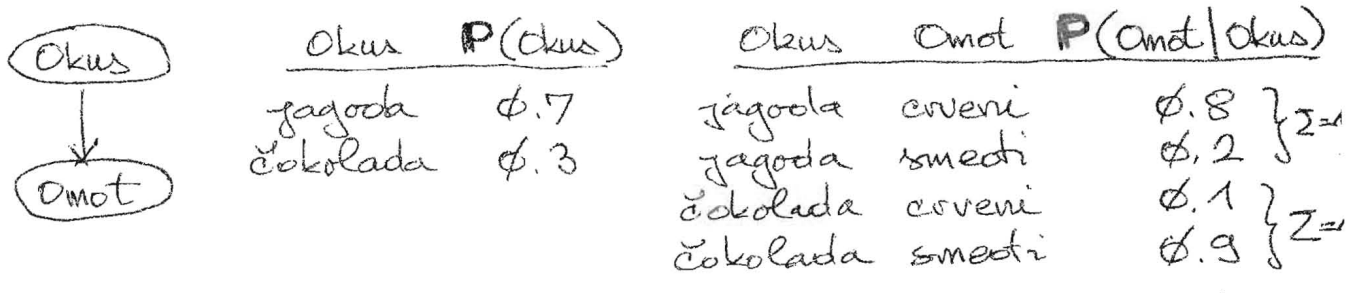
=> P(x | -) = 1/3 * 2/3 * 2/3 = 4/27

Za C = - dobivamo veću vjerovatnosti =>

C(x) = -

4. zad. - rješenje

U ovom problemu, svi bomboni imaju isti (okrugli) oblik, pa ostaju samo dvije slučajne varijable - to su Okus i Omot. Pripadna binijalna Bayesova mreža je



Podatke iz ove mreže koristimo za računanje potrebnih podataka za problem učenja u zadatku.

Stravno zaključivanje u zadatku ne izravne mreže s ovom mrežom - jer još imamo i hipoteze h_1, h_2 , te skup podataka za učenje.

Uočiti: hipoteze su formulirane preko distribucije vjerojatnosti omota (a ne okusa).

Poznati podaci o sadržaju meća u hipotezama mogu se zapisati u obliku tablice uvjetne distribucije $P(\text{Omot} | H)$ gdje H ima vrijednosti h_1 i h_2

$H = \text{hipoteza}$	Omot	$P(\text{Omot} H)$
h_1	crveni	0.93
h_1	smeđi	0.07
h_2	crveni	0.25
h_2	smeđi	0.75

Stravne oznake za kasnije su:

$$P(\text{crveni} | h_1) = p_1 = 0.93$$

$$P(\text{smeđi} | h_1) = 1 - p_1 = 0.07$$


$$P(\text{crveni} | h_2) = p_2 = 0.25$$

$$P(\text{smeđi} | h_2) = 1 - p_2 = 0.75$$

Znamo i a priori distribuciju vjerojatnosti za H - obje hipoteze su jednako vjerojatne

H	$P(H)$
h_1	0.5
h_2	0.5

Digresija: svi podaci odgovarali bi Bayesovoj mreži



samo fali učenje!

Podaci za učenje zadani su mjedenostima omota:

d_1 : Omot = crveni, d_2 : Omot = smeđi

Graceni zapis

$d_1 = \text{crveni}, d_2 = \text{smeđi}$

Cijeli skup podataka za učenje označavamo s $d = (d_1, d_2)$.

(a) A posteriori distribuciju vjerojatnosti hipoteza uz dane podatke za učenje računamo prema Bayesovom pravilu - u terminima distribucija vjerojatnosti

$$P(H|d) = \frac{P(d|H) \cdot P(H)}{P(d)} = \alpha \cdot P(d|H) \cdot P(H)$$

gdje je α normalizacijski faktor - da ne moramo računati $P(d)$ - što je teško/ nepoznato;

- u terminima vjerojatnosti pojedine hipoteze h_i

$$P(h_i|d) = \frac{P(d|h_i) \cdot P(h_i)}{P(d)} = \alpha \cdot P(d|h_i) \cdot P(h_i)$$

Hipoteza maksimalne a posteriori vjerojatnosti h_{MAP} je

$$h_{MAP} = \arg \max_{h_i} P(h_i|d) = \arg \max_{h_i} P(d|h_i) \cdot P(h_i)$$

- A priori vjerojatnosti hipoteza $P(h_i)$ znamo, a vjerojatnosti $P(d|h_i)$ računamo iz dobivenog uzorka za učenje, koristeći pretpostavku da su izvlačenja "omota" nezavisna i jednako distribuirana:

$$P(d|h_i) = \prod_{j=1}^2 P(d_j|h_i)$$

U našem primjeru, vjerojatnost izvlačenja crvenog omota iz vreće " h_i " je p_i , a za smeđi omot je $1 - p_i$.

Onda je:

$P(d_1, d_2 | h_i) = p_i \cdot (1 - p_i)$ $i = 1, 2$

Sad iskoristimo poznate vrijednosti za p_i , pa je

4-3

$$P(d|h_1) = 0.93 \cdot 0.07 = 0.0651$$

$$P(d|h_2) = 0.25 \cdot 0.75 = 0.1875$$

Obzirom na to da je $P(h_1) = P(h_2)$, odmah vidimo da hipoteza h_2 ima veću a posteriornu vjerovatnost

$$h_{\text{MAP}} = h_2$$

Usput, zbog jednake a priori vjerovatnosti hipoteza, sledi i da je hipoteza maksimalne izglednosti h_{ML} jednaka h_{MAP}

$$h_{\text{MAP}} = h_{\text{ML}} = h_2$$

A posteriornu distribuciju $P(H|d)$ dobivamo normalizacijom

$$P(H|d) = \alpha \cdot P(d|H) \cdot P(H) = \left\{ P(h_1) = P(h_2) = \frac{1}{2} \right\}$$

$$= \alpha \cdot P(d|H)$$

$$= \alpha \cdot \langle 0.0651, 0.1875 \rangle = \left\{ \alpha = \frac{1}{0.2526} = 3.9588281869 \right\}$$

$$= \langle 0.2577197156, 0.7422802850 \rangle$$

(b) Na temelju podataka za učenje, treba "predvidjeti" distribuciju vjerovatnosti "upitne" varijable X , uz dane podatke d .

- Optimalno Bayesovo predviđanje (OBP):

$$P(X|d) = \sum_i P(X|h_i) \cdot P(h_i|d)$$

(marginalizacija po svim uzjednostima hipoteza, h_i i još pretpostavljamo uvjetnu nezavisnost X i podataka d uz danu hipotezu h_i , tj. $P(X|d, h_i) = P(X|d)$).

- Maksimalno a posteriornu (MAP) predviđanje

$$P(X|d) \approx P(X|h_{\text{MAP}})$$

(jer h_{MAP} maksimizira faktor $P(h_i|d)$, pa aproksimacija uzima ~~u~~ pripadni član, kao da mu je težina samo $P(h_{\text{MAP}}|d) = 1$)

U našem primjeru, traži se predviđanje za $X=Okus$, i dovoljno je naći vjerojatnost za $X=Okus=jagoda$ (ne treba cijela distribucija vjerojatnosti - dva člana, već samo prvi - za jagodu).

Uočiti: predviđamo okus na temelju omota (njihov omjer ili distribucija vjerojatnosti je hipoteza). To je obratno od polazne Bayesove mreže i zato trebamo dodatne podatke iz nje.

Traži se $P(X=jagoda | d)$, a za OBP nam treba (skraćeni zapis)

$$P(jagoda | h_i), i=1, 2.$$

(već znamo da je $h_{MAP} = h_2$ pa namo trebamo samo $P(jagoda | h_2)$)

Ove vjerojatnosti računamo "margijalizacijom" po omotu, jer omot veže okus i hipoteze:

$$P(jagoda | h_i) = \sum_{\substack{\text{omot} \\ = \text{crveni} \\ \text{smeti}}} P(jagoda | \text{omot}) \cdot \underbrace{P(\text{omot} | h_i)}_{\text{znamo}}$$

↓
treba izračunati
iz polazne Bayesove mreže

- Za $P(jagoda | \text{omot})$ koristimo Bayesovo pravilo i vjerojatnosti iz 1. zadatka (CPT na početku ovog zadatka):

$$P(jagoda | \text{omot}) = \frac{P(\text{omot} | jagoda) \cdot P(jagoda)}{P(\text{omot})}$$

za $\text{omot} = \text{crveni}$, smeti.

Vrijednosti za brojnik imamo, a nazivnik treba izračunati marginalizacijom po okusima (kao u 1. zadatku), ~~ne~~ ne smijemo samo normalizirati.

$$P(\text{Omot} = \text{crveni}) = P(\text{crveni} | jagoda) \cdot P(jagoda) + P(\text{crveni} | \text{čokolada}) \cdot P(\text{čokolada}) = 0.8 \cdot 0.7 + 0.1 \cdot 0.3 = \underline{0.59}$$

$$P(\text{Omot} = \text{smeti}) = (\text{može kao gore, ali lakše je...}) = 1 - P(\text{Omot} = \text{crveni}) = \underline{0.41}$$

$$P(\text{Omot}) = \langle 0.59, 0.41 \rangle$$

Vjerojatnosti okusa jagode za dati omot su:

$$\begin{aligned}
P(\text{jagoda} | \text{crveni}) &= \frac{P(\text{crveni} | \text{jagoda}) \cdot P(\text{jagoda})}{P(\text{crveni})} \\
&= \frac{0.8 \cdot 0.7}{0.59} = \frac{0.56}{0.59} = \underline{\underline{0.9491525424}}
\end{aligned}$$

$$\begin{aligned}
P(\text{jagoda} | \text{smeći}) &= \frac{P(\text{smeći} | \text{jagoda}) \cdot P(\text{jagoda})}{P(\text{smeći})} \\
&= \frac{0.2 \cdot 0.7}{0.41} = \frac{0.14}{0.41} = \underline{\underline{0.3414634146}}
\end{aligned}$$

Vjerojatnosti okusa jagode za dane hipoteze (veće) su:

$$\begin{aligned}
P(\text{jagoda} | h_1) &= p_1 \cdot P(\text{jagoda} | \text{crveni}) + (1-p_1) \cdot P(\text{jagoda} | \text{smeći}) \\
&= 0.93 \cdot \frac{0.56}{0.59} + 0.07 \cdot \frac{0.14}{0.41} \\
&= \underline{\underline{0.966143634}}
\end{aligned}$$

$$\begin{aligned}
P(\text{jagoda} | h_2) &= p_2 \cdot P(\text{jagoda} | \text{crveni}) + (1-p_2) \cdot P(\text{jagoda} | \text{smeći}) \\
&= 0.25 \cdot \frac{0.56}{0.59} + 0.75 \cdot \frac{0.14}{0.41} \\
&= \underline{\underline{0.4933856966}}
\end{aligned}$$

- BOP:

$$\begin{aligned}
P(\text{jagoda} | d) &= P(\text{jagoda} | h_1) \cdot P(h_1 | d) + P(\text{jagoda} | h_2) \cdot P(h_2 | d) \\
&= 0.9661... \cdot 0.25771... + 0.49338... \cdot 0.74228... \\
&= 0.2336523799 + 0.366234755 \\
&= \underline{\underline{0.5998828554}}
\end{aligned}$$

tj. vjerojatniji okus trećeg bombona je jagoda.

- MAP

$$P(\text{jagoda} | d) \approx P(\text{jagoda} | h_2) = 0.4933856966$$

tj. po MAP predviđanju, vjerojatniji okus trećeg bombona je čokolada.