

OSNOVE UMETNE INTELIGENCE


2021/22

*ocenjevanje učenja,
diskretizacija, manjkajoči atributi
naivni Bayesov klasifikator*

Pridobljeno znanje s prejšnjih predavanj

- **strojno učenje**
 - prostor hipotez odločitvenih dreves
 - problem pretiranega prileganja učnim podatkom
 - učenje šuma
 - prevelika drevesa, slaba razumljivost
 - slaba splošnost
 - **strategije rezanja**: vnaprej, nazaj
 - ocenjevanje verjetnosti z bolj stabilnimi ocenami
 - rezanje nazaj:
 - REP: **uporaba rezalne množice**, odrežemo poddrevesa, ki povečujejo število napak glede na število napak v njihovem korenu
 - MEP: **uporaba m-ocene verjetnosti**, ki kombinira apriorno in empirično verjetnost, ocenimo statično in dinamično napako

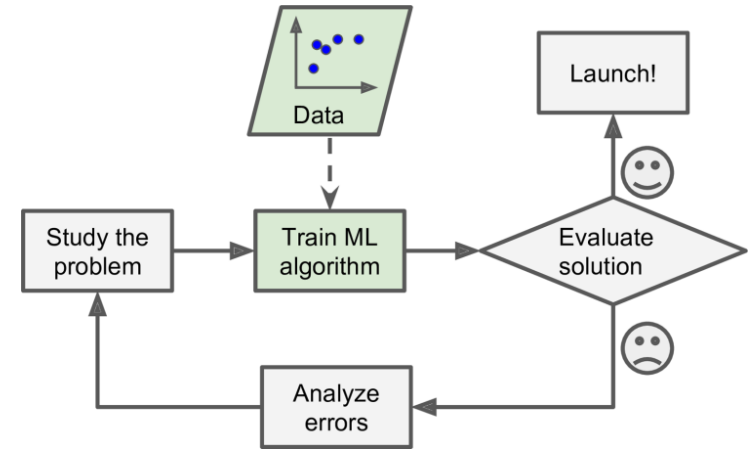
Pregled




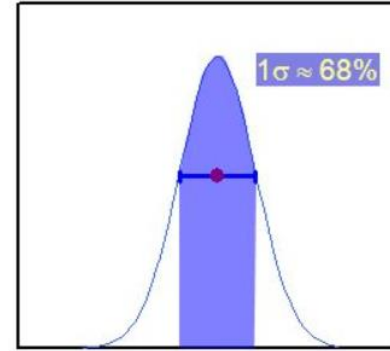
- strojno učenje
 - uvod v strojno učenje
 - učenje odločitvenih dreves
 - učenje dreves iz šumnih podatkov (rezanje dreves)
 - ocenjevanje učenja
 - diskretizacija atributov, obravnava manjkajočih vrednosti
 - naivni Bayesov klasifikator

Ocenjevanje učenja

- kriteriji za ocenjevanje hipotez:
 - **točnost** (angl. *accuracy*) (**konsistentnost, splošnost**)
 - **razumljivost** (angl. *comprehensibility*) – subjektivni kriterij ali tudi **kompleksnost** (angl. *complexity*)
- ocenjevanje točnosti:
 - na **učnih** podatkih (angl. *training set, learning set*)
 - na **testnih** podatkih (angl. *testing set, test set*)
 - izločimo del učnih podatkov, s katerimi simuliramo ne-videne podatke
 - želimo si, da je testna množica reprezentativna za nove podatke
 - uporabimo lahko **intervale zaupanja** v oceno uspešnosti na testni množici, ki upoštevajo število testnih primerov
 - na **novih** (ne-videnih) podatkih (angl. *new data, unseen data*)
 - na njih bo naučeni sistem dejansko deloval



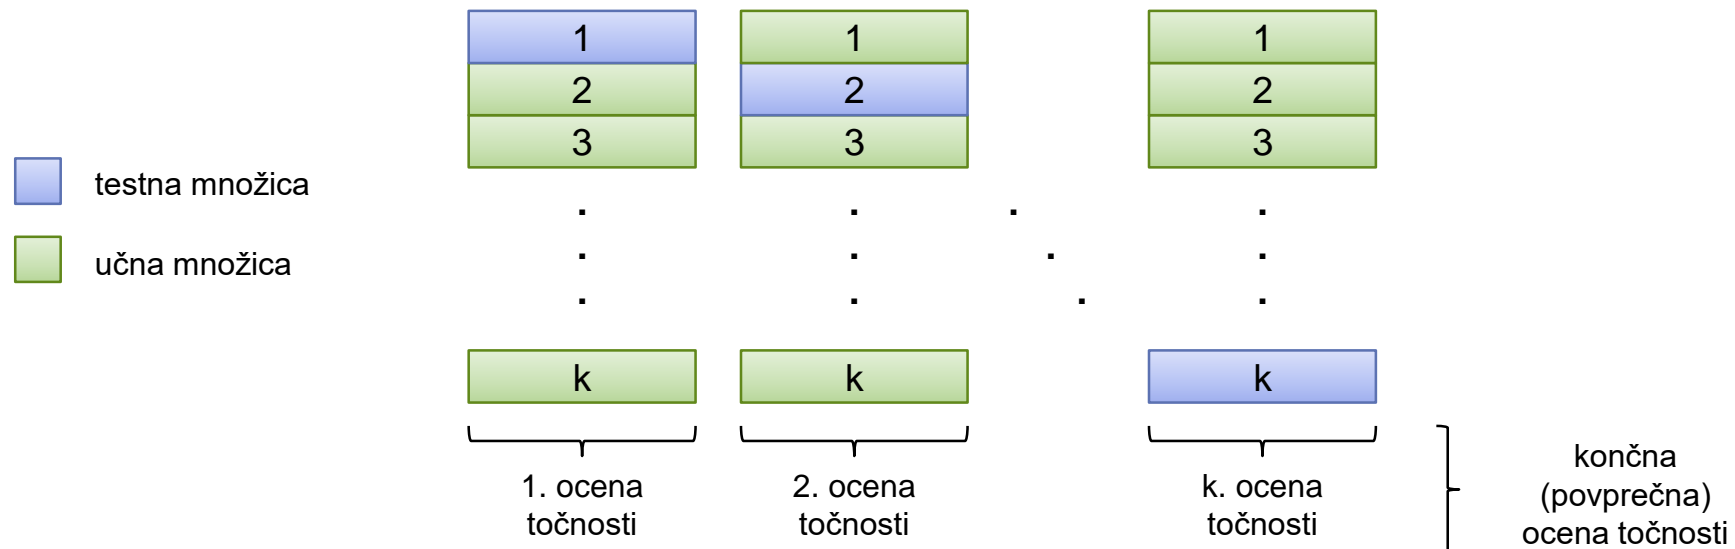
Ocenjevanje učenja



- nasprotujoča si cilja:
 - potrebujemo čim več podatkov za **uspešno učenje**
 - potrebujemo čim več podatkov za **zanesljivo ocenjevanje točnosti** (večje število testnih primerov nam daje ožji interval zaupanja v oceno točnosti)
- rešitev:
 - kadar je učnih podatkov dovolj, lahko izločimo **testno množico** (angl. *holdout test set*)
 - alternativa: **večkratne delitve** na učno in testno množico
- različni načini **vzorčenja testnih primerov**:
 - naključno, nenaključno (npr. prečno preverjanje)
 - poljubno ali stratificirano (zagotovimo enako porazdelitev razredov kot v učni množici)


Prečno preveranje

- poseben primer **večkratnega učenja** in testiranja
- **k-kratno prečno preverjanje** (angl. *k-fold cross-validation*):
 - celo učno množico razbij na k disjunktnih podmnožic
 - za vsako od k podmnožic:
 - uporabi **množico** kot **testno množico**
 - uporabi **preostalih $k-1$** množic kot **učno množico**
 - povpreči dobljenih k ocen točnosti v končno oceno




Prečno preveranje

- v praksi **najpogosteje: $k=10$** (10-kratno prečno preverjanje)
- vplive izbranega razbitja podatkov na podmnožice lahko zmanjšamo tako, da tudi prečno preverjanje **večkrat (npr. 10x) ponovimo** (torej $10 \times 10 = 100$ izvajanj učnega algoritma) in rezultate povprečimo
- poseben primer prečnega preverjanja je metoda **izloči enega** (angl. leave-one-out, LOO)
 - k je enak številu primerov (vsaka testna množica ima samo en primer)
 - najbolj stabilna ocena glede učinkov razbitja na podmnožice
 - časovno zelo zamudno, primerno za manjše množice
- iz meritev na vseh podmnožicah je možno izračunati tudi varianco/ intervale zaupanja



Pregled



- strojno učenje
 - uvod v strojno učenje
 - učenje odločitvenih dreves
 - učenje dreves iz šumnih podatkov (rezanje dreves)
 - ocenjevanje učenja
 - diskretizacija atributov, obravnava manjkajočih vrednosti
 - naivni Bayesov klasifikator

Različne vrste atributov

- vrste atributov:
 - **diskretni:**
 - **nominalni** ({true, false}, {M, F}, {French, Thai, Burger, Italian})
 - **ordinalni** ({None, Some, Full}, {Low, Med, High})
 - **zvezni/numerični** ($\in \mathbb{R}$)
- **Kako obravnavati zvezne/numerične attribute?**
 - Običajno izvedemo diskretizacijo v dva (binarizacija) ali več diskretnih intervalov.
 - Različni pristopi k diskretizaciji:
 - intervali **enake širine** (equal-width)
 - intervali z **enako frekvenco** primerov (equal-frequency)
 - intervali, ki **maksimizirajo informacijski prispevek**

• **Data** : 0, 4, 12, 16, 16, 18, 24, 26, 28


• **Equal width**

- Bin 1: 0, 4 [-,10)
- Bin 2: 12, 16, 16, 18 [10,20)
- Bin 3: 24, 26, 28 [20,+)


• **Equal frequency**

- Bin 1: 0, 4, 12 [-, 14)
- Bin 2: 16, 16, 18 [14, 21)
- Bin 3: 24, 26, 28 [21,+)

Equal width



Equal frequency




Diskretizacija z maksimizacijo informacijskega prispevka

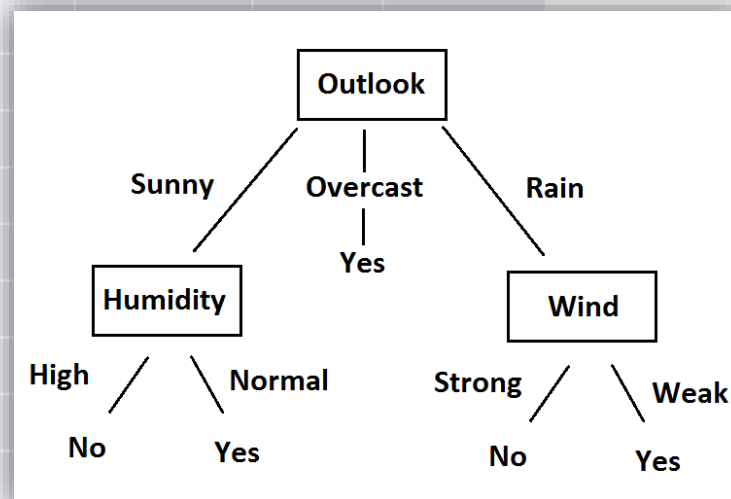
- numerični atributi namesto diskretnih?

Day	Outlook	Temperature	Humidity	Wind	Play
1	Sunny	Hot	High	Weak	No
2	Sunny	Hot	High	Strong	No
3	Overcast	Hot	High	Weak	Yes
4	Rain	Mild	High	Weak	Yes
5	Rain	Cool	Normal	Weak	Yes
6	Rain	Cool			
7	Overcast	Cool			
8	Sunny	Mild			
9	Sunny	Cool			
10	Rain	Mild			
11	Sunny	Mild			
12	Overcast	Mild			
13	Overcast	Hot			
14	Rain	Mild			

???


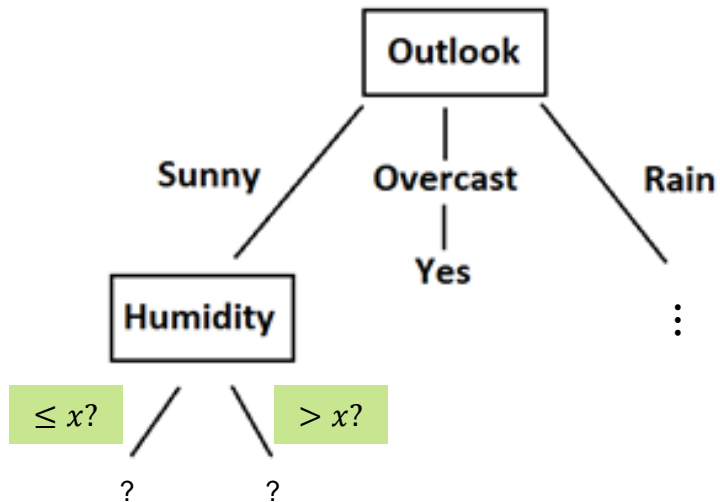


Day	Outlook	Temperature	Humidity	Windy	Play
1	Sunny	85	85	Weak	No
2	Sunny	80	90	Strong	No
3	Overcast	83	86	Weak	Yes
4	Rain	70	96	Weak	Yes
5	Rain	68	80	Weak	Yes
6	Rain	65	70	Strong	No
7	Overcast	64	65	Strong	Yes
8	Sunny	72	95	Weak	No
9	Sunny	69	70	Weak	Yes
10	Rain	75	80	Weak	Yes
11	Sunny	75	70	Strong	Yes
12	Overcast	72	90	Strong	Yes
13	Overcast	81	75	Weak	Yes
14	Rain	71	91	Strong	No



Diskretizacija z maksimizacijo informacijskega prispevka

- kako diskretizirati atribut Humidity?



Day	Outlook	Temperature	Humidity	Windy	Play
1	Sunny	85	85	Weak	No
2	Sunny	80	90	Strong	No
8	Sunny	72	95	Weak	No
9	Sunny	69	70	Weak	Yes
11	Sunny	75	70	Strong	Yes

- primeri možni vrednosti za mejo x: 70, 85, 90

- entropije ob različnih delitvah:

- $x = 70 \rightarrow$ levo [2,0], desno [0,3]
 $H_{res} = \frac{2}{5} \cdot 0 + \frac{3}{5} \cdot 0 = 0$ ← najnižja residualna entropija (najvišji informacijski prispevek)
- $x = 85 \rightarrow$ levo [2,1], desno [0,2]
 $H_{res} = \frac{3}{5} \cdot \left(-\frac{2}{3} \log_2 \frac{2}{3} - \frac{1}{3} \log_2 \frac{1}{3} \right) + \frac{2}{5} \cdot 0 = 0,551$
- $x = 90 \rightarrow$ levo [2,2], desno [0,1]
 $H_{res} = \frac{4}{5} \cdot 1 + \frac{1}{5} \cdot 0 = 0,8$

- izberemo:

- LOW: ≤ 70
- HIGH: > 70

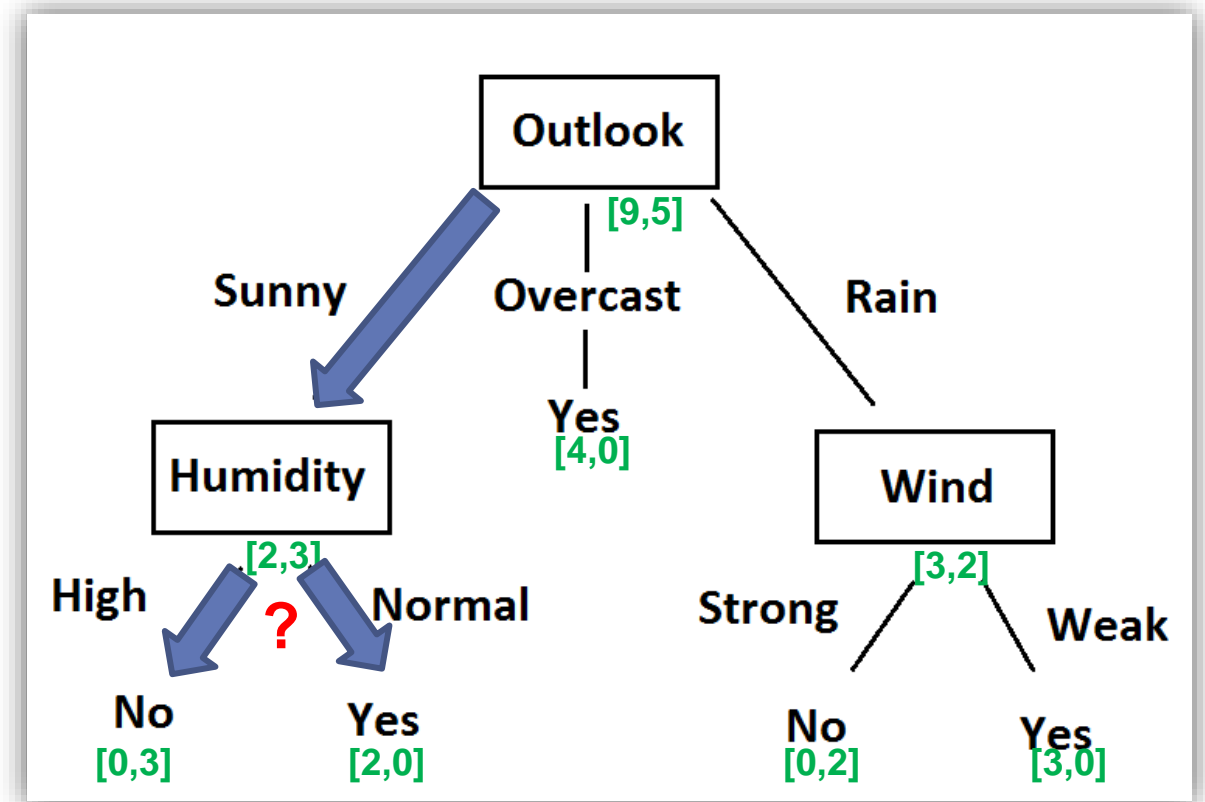
Obravnavanje manjkajočih atributov

Day	Outlook	Temperature	Humidity	Wind	PlayTennis
1	Sunny	Hot	High	Weak	No
2	Sunny	Hot	High	Strong	No
8	Sunny	Mild	???	Weak	No
9	Sunny	Cool	Normal	Weak	Yes
11	Sunny	Mild	Normal	Strong	Yes


- različni načini **obrnave manjkajočih** atributov, glede na:
 - ali učni algoritem lahko poišče hipotezo **tudi, če manjkajo** vrednosti atributov?
 - ali imamo **dovolj** učnih primerov na razpolago?
 - ali je primerno **nadomeščanje** manjkajočih vrednosti?
- **pristopi pri učenju:**
 - učimo z manjkajočimi vrednostmi
 - ignoriranje celih učnih primerov z neznanimi vrednostmi
 - uporaba posebne vrednosti NA/UNKNOWN?
 - nadomestiti manjkajočo vrednost (povprečna, najbolj pogosta, najbolj pogosta glede na razred, naključna, napovedana)
 - primer obravnavamo verjetnostno glede na vse možne vrednosti atributa
- **pristopi pri napovedovanju:**
 - verjetnostna klasifikacija glede na vse možne vrednosti atributa (npr. pri drevesu: klasificiramo v več listov)

Obravnava manjkajočih atributov

- Kako klasificirati primer
Outlook=Sunny,
Temperature=Mild,
Humidity=???,
Wind=Weak ?
- verjetnostna klasifikacija glede na relativno frekvenco:
 - $P(\text{razred} = \text{No} \mid \text{primer}) = 3/5$
 - $P(\text{razred} = \text{Yes} \mid \text{primer}) = 2/5$



Pregled



- strojno učenje
 - uvod v strojno učenje
 - učenje odločitvenih dreves
 - učenje dreves iz šumnih podatkov (rezanje dreves)
 - ocenjevanje učenja
 - diskretizacija atributov, obravnava manjkajočih vrednosti
 - naivni Bayesov klasifikator

Naivni Bayesov klasifikator

- Thomas Bayes, 1702 – 1761
- opomnik iz teorije o verjetnosti:


$$P(AB) = P(A|B) \cdot P(B)$$

$$P(AB) = P(B|A) \cdot P(A)$$

$$P(A|B) \cdot P(B) = P(B|A) \cdot P(A)$$

$$P(B|A) = \frac{P(A|B) \cdot P(B)}{P(A)}$$

Bayesovo pravilo



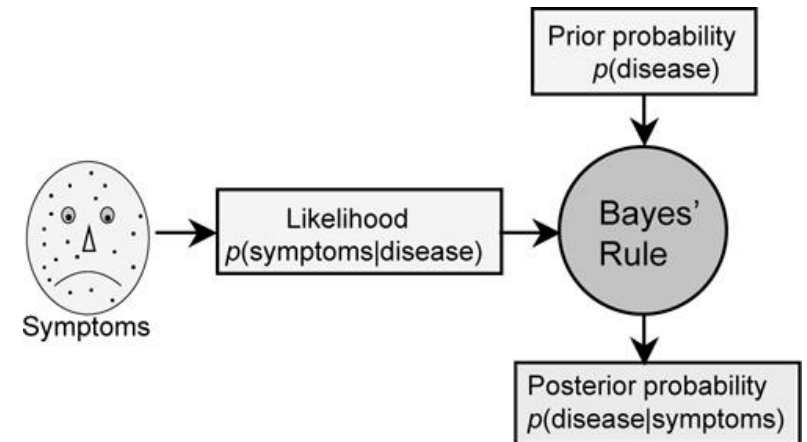
Naivni Bayesov klasifikator

- zdravniki razpolagajo z **vzročno in statistično informacijo**:
 - verjetnost **izraženih simptomov pri neki bolezni** - $P(\text{opažanje}|\text{hipoteza})$
 - verjetnost **določene bolezni** - $P(\text{hipoteza})$
 - verjetnost **določenega simptoma** - $P(\text{opažanje})$

- aplikacija v medicini:


$$P(\text{hipoteza}|\text{opažanje}) = \frac{P(\text{opažanje}|\text{hipoteza}) \cdot P(\text{hipoteza})}{P(\text{opažanje})}$$

- Bayesovo pravilo nam izraža **diagnostično pogojno verjetnost** $P(\text{hipoteza}|\text{opažanje})$ na podlagi **vzročne pogojne verjetnosti** $P(\text{opažanje}|\text{hipoteza})$



Vaja – opomnik iz verjetnosti

- dve vrsti vrečk s frnikulami:
 - 4 vrečke tipa A (vsaka 5 črnih, 15 belih frnikul)
 - 1 vrečka tipa B (16 črnih, 4 bele frnikule)
- primeri vprašanj, zapisanih kot verjetnosti:
 - Kakšna je verjetnost, da je to vrečka tipa B?
 $P(B) = ?$
 - Kakšna je verjetnost, da naključno izberemo črno frnikulo, če izbiramo iz vrečke tipa B?
 $P(\check{C}|B) = ?$
 - Naključno izberemo eno izmed vrečk in iz nje naključno izberemo frnikulo. Kakšna je verjetnost, da smo izbrali črno frnikulo iz vrečke tipa B?
 $P(B\check{C}) = P(B) \cdot P(\check{C}|B) = ?$
 - Naključno izberemo eno izmed vrečk in iz nje naključno izberemo frnikulo. Kakšna je verjetnost, da smo izbrali črno frnikulo?
 $P(\check{C}) = P(B) \cdot P(\check{C}|B) + P(A) \cdot P(\check{C}|A)$



Bag A

Bag B

Vaja

- Ena vrečka ima poškodovan ovoj tako, da se skozi njega vidi črna frnikula. Kakšna je verjetnost, da je to vrečka tipa B?

$$P(B|\check{C}) = ?$$

- B = hipoteza, Č = evidenca, opažanje
- verjetnost $P(B|\check{C})$ lahko določimo iz drugih bolj očitnih verjetnosti z Bayesovo formulo:

$$P(B|\check{C}) = \frac{P(B) \cdot P(\check{C}|B)}{P(\check{C})}$$

- $P(B) = \frac{1}{5} = 0,2$
 $P(\check{C}|B) = \frac{16}{20} = 0,8$
 $P(\check{C}) = \frac{4 \cdot 5 + 1 \cdot 16}{5 \cdot 20} = 0,360$
- $P(B|\check{C}) = \frac{0,2 \cdot 0,8}{0,360} = 0,444$

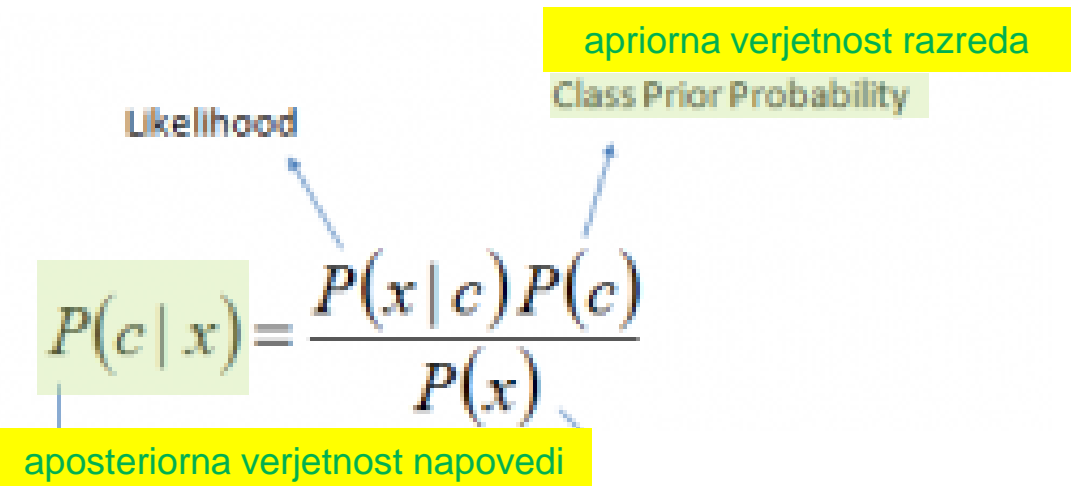
dve vrsti vrečk s frnikulami:

- 4 vrečke tipa A (vsaka 5 črnih, 15 belih frnikul)
- 1 vrečka tipa B (16 črnih, 4 bele frnikule)

Naivni Bayes v strojnem učenju


- evidenca → atributi
hipoteza → razred
- zanima nas, kakšna je verjetnost razreda C pri podanih vrednostih atributov $A_1 = X_1, A_2 = X_2, \dots, A_n = X_n$:

$$P(C|X_1X_2 \dots X_n) = \frac{P(C) \cdot P(X_1X_2 \dots X_n|C)}{P(X_1X_2 \dots X_n)}$$



Naivni Bayes v strojnem učenju

$$P(\text{hipoteza}|\text{evidenca}) = \frac{P(\text{hipoteza}) \cdot P(\text{evidenca}|\text{hipoteza})}{P(\text{evidenca})} \longrightarrow P(C|X_1X_2 \dots X_n) = \frac{P(C) \cdot P(X_1X_2 \dots X_n|C)}{P(X_1X_2 \dots X_n)}$$

- pravilo za produkt verjetnosti: $P(AB) = P(A) \cdot P(B|A)$ 
- pravilo za produkt verjetnosti s pogojno verjetnostjo: $P(AB|C) = P(A|C) \cdot P(B|AC)$
- $P(X_1X_2 \dots X_n|C) = P(X_1|C) \cdot P(X_2 \dots X_n|X_1C) =$
 $= P(X_1|C) \cdot P(X_2|X_1C) \cdot P(X_3 \dots X_n|X_1X_2C) =$
 $= P(X_1|C) \cdot P(X_2|X_1C) \cdot P(X_3|X_1X_2C) \cdot \dots \cdot P(X_n|X_1X_2 \dots X_{n-1}C)$
- $P(X_1X_2 \dots X_n) = P(X_1|X_2 \dots X_n) \cdot P(X_2|X_3 \dots X_n) \cdot \dots \cdot P(X_{n-1}|X_n) \cdot P(X_n)$
- potrebujemo veliko število pogojnih verjetnosti, katerih poznavanje je v praksi težavno
- število kombinacij pogojnih verjetnosti je glede možne vrednosti $X_1X_2 \dots X_n$ eksponentno
- praktična rešitev: **naivni Bayesov klasifikator**

Naivni Bayes v strojnem učenju

- predpostavimo, da so atributi med seboj **verjetnostno neodvisni** in poenostavimo:

$$P(X_1 X_2 \dots X_n | C) = P(X_1 | C) \cdot P(X_2 | X_1 C) \cdot \dots \cdot P(X_n | X_1 X_2 \dots X_{n-1} C)$$

$$P(X_1 X_2 \dots X_n) = P(X_1 | X_2 \dots X_n) \cdot P(X_2 | X_3 \dots X_n) \cdot \dots \cdot P(X_{n-1} | X_n) \cdot P(X_n)$$



$$P(X_1 X_2 \dots X_n | C) \approx P(X_1 | C) \cdot P(X_2 | C) \cdot \dots \cdot P(X_n | C)$$

$$P(X_1 X_2 \dots X_n) \approx P(X_1) \cdot P(X_2) \cdot \dots \cdot P(X_{n-1}) \cdot P(X_n)$$

- približki so dobri, **če so atributi med seboj dovolj neodvisni**
- velja torej:

$$P(C | X_1 X_2 \dots X_n) = \frac{P(C) \cdot P(X_1 X_2 \dots X_n | C)}{P(X_1 X_2 \dots X_n)} \approx \frac{P(C) \cdot \prod_i P(X_i | C)}{\prod_i P(X_i)}$$

konstanten člen, ki je neodvisen od ciljne spremenljivke
(če opazujemo samo relativne velikosti napovedi
različnih razredov, ga lahko izpustimo)



Naivni Bayes v strojnem učenju

- Bayesov klasifikator: primer **klasificiramo v razred, ki je najbolj verjeten:**

$$h(X_1 X_2 \dots X_n) = \operatorname{argmax}_k P(C_k) \cdot \prod_{i=1}^n P(X_i | C_k)$$

- **učenje:** ocenimo verjetnosti $P(C_k)$ in $P(X_i | C_k)$ za vse razrede C_k in vrednosti atributov X_i
- **napovedovanje:** uporabimo zgornjo enačbo za napovedovanje razreda novim primerom
- *opomba: s poenostavitvijo formule in izpustitvijo imenovalca izgubimo verjetnostno interpretacijo (verjetnosti razredov se ne seštevajo več v 1). Problem rešujemo npr. z normalizacijo rezultatov.*

Primer

- Zajeli smo podatke za 1000 sadežev, ki so lahko bodisi: *banana*, *pomaranča* ali *drugi sadež* (= vrednosti **razreda**). Za vsakega izmed sadežev smo izmerili, ali je *podolgovat*, *sladek* in *rumen* (= **atributi**). Meritve smo zapisali v tabelo:

sadež	podolgovat		sladek		rumen		skupaj
	da	ne	da	ne	da	ne	
banana	400	100	350	150	450	50	500
pomaranča	0	300	150	150	300	0	300
drugo	100	100	150	50	50	150	200
	500	500	650	350	800	200	1000

- iz tabele lahko razberemo različne verjetnosti, npr.:
 - verjetnosti razredov: $P(\textit{banana}) = \frac{500}{1000} = 0,5$, $P(\textit{pomaranča}) = 0,3$, $P(\textit{drugo}) = 0,2$
 - pogojne verjetnosti: $P(\textit{dolga}|\textit{banana}) = \frac{4}{5} = 0,8$
 $P(\textit{sladek}|\textit{banana}) = 0,7$
 $P(\textit{rumen}|\textit{banana}) = 0,9$

Primer

sadež	podolgovat		sladek		rumen		skupaj
	da	ne	da	ne	da	ne	
banana	400	100	350	150	450	50	500
pomaranča	0	300	150	150	300	0	300
drugo	100	100	150	50	50	150	200
	500	500	650	350	800	200	1000

- Imamo sadež, ki ni podolgovat, ni sladek, je pa rumen. Kateri sadež je to?

$$\begin{aligned} &P(\text{banana} | \text{neP}, \text{neS}, \text{daR}) \\ &\approx P(\text{banana}) \cdot P(\text{neP} | \text{banana}) \cdot P(\text{neS} | \text{banana}) \cdot P(\text{daR} | \text{banana}) = \\ &= \frac{500}{1000} \cdot \frac{100}{500} \cdot \frac{150}{500} \cdot \frac{450}{500} = 0,5 \cdot 0,2 \cdot 0,3 \cdot 0,9 = 0,027 \end{aligned}$$

$$P(\text{pomaranča} | \text{neP}, \text{neS}, \text{daR}) \approx 0,3 \cdot 1 \cdot 0,5 \cdot 1 = 0,15$$

$$P(\text{drugo} | \text{neP}, \text{neS}, \text{daR}) \approx 0,2 \cdot 0,5 \cdot 0,25 \cdot 0,25 = 0,00625$$



ta sadež je
najverjetneje
pomaranča



Izpitna naloga

- 2. izpitni rok, 15. 2. 2018 (prilagojena naloga)

2. NALOGA (25t):

Podana je učna množica primerov, ki je prikazana v tabeli (*vreme* in *pritisk* sta atributa, *glavobol* pa je razred). Naloga:

V kateri razred bi naivni Bayesov klasifikator klasificiral učni primer z vrednostmi atributov *vreme=deževno*, *pritisk=srednji* (verjetnosti računamo z relativno frekvenco)?

vreme	pritisk	glavobol
sončno	nizek	ne
sončno	nizek	ne
sončno	srednji	da
sončno	visok	ne
sončno	nizek	ne
sončno	nizek	da
deževno	srednji	ne
deževno	srednji	da
deževno	visok	da



nomogrammi, k najbližjih sosedov, regresija