

STATISTIČKO UČENJE

POGLAVLJE 20.1–2

Prema slajdovima Stuarta Russella i Tomislava Šmuca (hvala)!

Sadržaj

- ◊ Bayesovo učenje — optimalno predviđanje
- ◊ Maksimalno *a posteriori* učenje (MAP)
- ◊ Učenje maksimalne izglednosti (ML)
(engl. likelihood = izglednost, vjerodostojnost)
- ◊ Naivna Bayesova klasifikacija
- ◊ Mrežno Bayesovo učenje
 - maks. izgledno parametarsko učenje s potpunim podacima
 - linearna regresija

Učenje i vjerojatnosno učenje

Strojno učenje: naći najbolju ili najuspješniju tzv. hipotezu ili model
= ona koja dobro opisuje podatke koji su nam dostupni za učenje.

Cilj: koristiti tu hipotezu/model za predviđanje na ostalim/budućim podacima, izvan skupa za učenje.

Zato: dobro = dovoljno jednostavno, dobro za generalizaciju, ali ne “predobro” ili “presloženo” (pretreniranje), jer je loše za generalizaciju.

Vjerojatnosni pristup: hipoteza H = slučajna varijabla i
najbolja hipoteza = najvjerojatnija hipoteza (model).

Standardni model vjerojatnog ili Bayesovog učenja:

Hipoteze iz H imaju neku početnu distribuciju vjerojatnosti $P(H)$.
Učenje na podacima = ažuriranje te distribucije uz dane “dokaze” (podatke), prema Bayesovom pravilu (uvjetna vjerojatnost).

Bayesovo učenje — diskretni model

Diskretni prostor hipoteza:

H je diskretna slučajna varijabla, tzv. “hipotezna” varijabla, s vrijednostima h_i , za $i = 1, \dots, m$ (konačna), ili $i \in \mathbf{N}$ (niz).

Početna ili a priori distribucija vjerojatnosti $\mathbf{P}(H)$ je poznata.

Pretpostavka: varijabla H nije izravno opaziva = nije u podacima (tj. kao da je skrivena varijabla — usporediti poslije s klasifikacijom).

Podaci za učenje ili treniranje su: $\mathbf{d} = d_1, \dots, d_N$ (“d” = data), svaki podatak ili opažanje d_j = uzorak (ishod) slučajne varijable D_j .

Interpretacija je kao ranije kod “dokaza” u Bayesovim mrežama:

\mathbf{D} je skup svih pripadnih varijabli D_j , a $\mathbf{D} = \mathbf{d}$ je opažena vrijednost.

U danom trenutku, imamo N takvih uzoraka, s tim da N može rasti, kako dobivamo nova opažanja.

Bayesovo učenje — osnovni pojmovi

Prema Bayesovom pravilu, za dosad **dane** podatke **d**, svaka hipoteza h_i ima **a posteriori** vjerojatnost:

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

Nazivi pojedinih vrijednosti:

$P(h_i)$ = **a priori** (početna) vjerojatnost hipoteze h_i ,

$P(h_i|\mathbf{d})$ = **a posteriori** (naknadna) vjerojatnost od h_i , za **dane d**
= **izglednost** hipoteze za dane podatke,

$P(\mathbf{d}|h_i)$ = **izglednost** podataka **d**, uz **danu** hipotezu h_i .

Općenito: a posteriori vjerojatnost hipoteze h_i ovisi o

- njezinoj prethodnoj vjerojatnosti,
- samim podacima za učenje **d**,
- vjerojatnosti dobivanja baš **tih** podataka, uz **danu** hipotezu h_i .

Potpuno Bayesovo učenje — predviđanje

Predviđanje nepoznate vrijednosti X (slučajna varijabla), za dane \mathbf{d} , uz pretpostavku da svaka hipoteza određuje (zadaje) neku distribuciju vjerojatnosti za X , tj. traži se distribucija $\mathbf{P}(X|\mathbf{d})$, ili pojedinačna vjerojatnost $P(x_k|\mathbf{d})$.

Hipotezu H tretiramo kao “skrivenu” varijablu — marginalizacija ili zbrajanje po svim mogućim vrijednostima hipoteze H

$$\mathbf{P}(X|\mathbf{d}) = \sum_i \mathbf{P}(X | \mathbf{d}, h_i) P(h_i|\mathbf{d}).$$

Ključna stvar u modelu — vrlo razumna u praksi:

Za danu hipotezu H , nepoznata vrijednost X i podaci \mathbf{D} su uvjetno nezavisni, tj. vrijedi $\mathbf{P}(X | \mathbf{d}, h_i) = \mathbf{P}(X|h_i)$, pa je

$$\mathbf{P}(X|\mathbf{d}) = \sum_i \mathbf{P}(X|h_i) P(h_i|\mathbf{d}).$$

Ovo je tzv. optimalno ili potpuno Bayesovo predviđanje učenjem.

Potpuno Bayesovo učenje — komentar

Prethodna formula za optimalno Bayesovo predviđanje

$$\mathbf{P}(X|\mathbf{d}) = \sum_i \mathbf{P}(X|h_i) P(h_i|\mathbf{d})$$

koristi sve hipoteze h_i , tj. nije bazirana na samo jednoj “najbolje” pogodenoj ili predviđenoj hipotezi!

Optimalno predviđanje je “težinska” srednja vrijednost

- predviđanja po svim pojedinačnim hipotezama, a
- “težine” su a posteriori vjerojatnosti pojedinih hipoteza.

Lijepo, ali skupo — u praksi, obično, koristimo neku aproksimaciju, tako da biramo jednu = “najbolju” hipotezu.

Opći pogled na gornju formulu: hipoteze h_i su “međuvrijednosti” između sirovih podataka i predviđanja.

Možemo i bez njih — uz dodatne vrijednosti u podacima (klasifikacija).

Primjer

Prepostavimo da imamo pet različitih vrsta vrećica s bombonima:


10% su h_1 : 100% bomboni s višnjom

20% su h_2 : 75% bomboni s višnjom + 25% bomboni s limunom

40% su h_3 : 50% bomboni s višnjom + 50% bomboni s limunom

20% su h_4 : 25% bomboni s višnjom + 75% bomboni s limunom

10% su h_5 : 100% bomboni s limunom




Gledano izvana, vrećice se ne razlikuju — ne znamo koja je koja!

Stvarno, prepostavljamo da su “vrećice” jako velike, tako da izvlačenje nekog bombona iz vreće ne mijenja vjerojatnost njezinog sadržaja, tj.

– $p(h_i)$ se time neće promijeniti.

Primjer — podaci za učenje, uvjetna nezavisnost



Zatim, vadimo 10 bombona iz neke (iste) vreće i dobivamo uzorak

$$d_1, \dots, d_{10} = \bullet .$$

Ova opažanja gledamo kao “rastući” uzorak podataka za **učenje**, tj.
u trenutku N je $\mathbf{d} = d_1, \dots, d_N$, za $N = (0), 1, \dots, 10$.

A priori distribucija hipoteza (prema proizvođaču bombona) je

$$\mathbf{P}(H) = \langle 0.1, 0.2, 0.4, 0, 2, 0.1 \rangle$$

Izglednost podataka računamo kao da su opažanja **nezavisna**, s **istom**
distribucijom vjerojatnosti (velika vreća)

$$P(\mathbf{d}|h_i) = \prod_j P(d_j|h_i).$$

Primjer — pitanja, uvjetna nezavisnost

Pitanja:

Koja je to vrsta vrećice?

Kojeg će okusa biti sljedeći bombon?

Prvo pitanje: hipoteza h_i koja ima najveću a posteriori vjerojatnost.

$$P(h_i|\mathbf{d}) = \alpha P(\mathbf{d}|h_i) P(h_i).$$

Drugo pitanje: predviđanje za varijablu X = “okus bombona”


$$\mathbf{P}(X|\mathbf{d}) = \sum_i \mathbf{P}(X | \mathbf{d}, h_i) P(h_i|\mathbf{d}) = \sum_i \mathbf{P}(X|h_i) P(h_i|\mathbf{d}),$$

s tim da se traži vrijednost x_k koja ima najveću vjerojatnost u $\mathbf{P}(X|\mathbf{d})$.

Uvjetna nezavisnost: ako znamo h_i = koja je vreća, onda je vjerojatnost okusa bombona potpuno određena tipom vreće i nema veze s podacima, tj. vrijedi


$$\mathbf{P}(X | \mathbf{d}, h_i) = \mathbf{P}(X|h_i).$$

Aposteriorna vjerojatnost hipoteza



Za $N = 0$ (bez učenja) dobivamo a priori vjerojatnosti hipoteza.
Nakon $N = 3$, hipoteza h_5 postaje najizglednija!

Predviđanje vjerojatnosti



Prema optimalnom predviđanju, vjerojatnost limuna brzo ide prema 1. To se slaže s “pravom” hipotezom h_5 .

Maksimalna a posteriori aproksimacija — MAP

Optimalno predviđanje je **skupo** — sve hipoteze su “u igri”!

Zbrajanje preko cijelog prostora hipoteza je često neostvarivo,
na pr., 18 446 744 073 709 551 616 Booleovih funkcija sa 6 atributa.

Maksimalno a posteriori (MAP) učenje:

izabrati hipotezu h_{MAP} koja maksimizira $P(h_i|\mathbf{d})$,
za predviđanje je onda $\mathbf{P}(X|\mathbf{d}) \approx \mathbf{P}(X|h_{MAP})$.

Tj., treba maksimizirati $P(\mathbf{d}|h_i) P(h_i)$, ili $\log P(\mathbf{d}|h_i) + \log P(h_i)$.

Log članovi mogu se shvatiti kao (negativni) broj bitova za
kodiranje podataka uz danu hipotezu + kodiranje hipoteze.

To je osnovna ideja učenja **minimalno dugog opisa** (MDL)
(engl. “minimum description length”).

Za determinističke hipoteze, $P(\mathbf{d}|h_i)$ je 1 ako je konzistentno, 0 inače
 \Rightarrow MAP = najjednostavnija konzistentna hipoteza (vidi znanost).

Maksimalno izgledna aproksimacija — ML

Za velike skupove podatake, a priori vjerojatnost postaje beznačajna (pogledati prethodni primjer).

Učenje maksimalne izglednosti (ML):

izabratи h_{ML} koja maksimizira $P(\mathbf{d}|h_i)$.

Tj., jednostavno se uzme najbolja aproksimacija podataka; identično MAP-u za uniformne apriori vjerojatnosti (što je razumno ako su sve hipoteze iste složenosti).

ML je “standardna” (ne-Bayesova) metoda statističkog učenja.


Problemi s ML za male skupove podataka = loša aproksimacija.

ML parametarsko učenje u Bayesovim mrežama

Vrećica s bombonima novog proizvođača; udio θ bombona s višnjom?

Moguće je bilo koji $\theta \in [0, 1]$ — imamo kontinuum hipoteza h_θ

θ je parametar za ovu jednostavnu (**binomnu**) familiju modela



Pretpostavimo da smo razmotali N bombona, od toga c s višnjama i $\ell = N - c$ s limunom,

To su **nezavisna, jednakodistribuirana** opažanja, pa je izglednost za \mathbf{d}

$$P(\mathbf{d}|h_\theta) = \prod_{j=1}^N P(d_j|h_\theta) = \theta^c \cdot (1-\theta)^\ell$$

Maksimizacija toga po θ — što je jednostavnije za **log-izglednost**:

$$L(\mathbf{d}|h_\theta) = \log P(\mathbf{d}|h_\theta) = \sum_{j=1}^N \log P(d_j|h_\theta) = c \log \theta + \ell \log(1-\theta)$$

$$\frac{dL(\mathbf{d}|h_\theta)}{d\theta} = \frac{c}{\theta} - \frac{\ell}{1-\theta} = 0 \quad \Rightarrow \quad \theta = \frac{c}{c+\ell} = \frac{c}{N}$$

Izgleda razumno, ali postoji problem kad se dogodi 0 u brojanju!

ML parametarsko učenje — nastavak

Riječima: h_{ML} hipoteza kaže da je **stvarni** udio višnji u vreći jednak **opaženom** udjelu do tada, tj. puno posla za **očitu** stvar!

Primjer je prejednostavan, pa izgleda očito . . . , svejedno, to je **standardna** metoda za ML **parametarsko učenje**, s puno primjena:

1. Izabrati **parametriziranu** familiju modela koji opisuju sve podatke
zahtijeva znatan uvid i ponekad nove modele
2. Napisati **izglednost** podataka kao funkciju parametara
može zahtijevati zbrajanje preko nevidljivih varijabli, tj. zaključivanje
3. Napisati **derivaciju** log izglednosti obzirom na svaki parametar
4. Naći **vrijednosti** parametara tako da su derivacije jednake nuli
može biti teško / nemoguće; pomažu moderne tehnike optimizacije.

Više parametara

Crveni / zeleni omoti bombona vjerojatnosno ovise o okusu — uvjetna distribucija za dani okus, s nepoznatim parametrima:


Izglednost za, na primjer, zeleno–omotani bombon s višnjom:

$$\begin{aligned}
 & P(F = \text{cherry}, W = \text{green} | h_{\theta, \theta_1, \theta_2}) \\
 &= P(F = \text{cherry} | h_{\theta, \theta_1, \theta_2}) P(W = \text{green} | F = \text{cherry}, h_{\theta, \theta_1, \theta_2}) \\
 &= \theta \cdot (1 - \theta_1)
 \end{aligned}$$

Uzorak: N bombona, višnje: r_c s crvenim, g_c sa zelenim omotima, itd.

$$P(\mathbf{d} | h_{\theta, \theta_1, \theta_2}) = \theta^c (1 - \theta)^\ell \cdot \theta_1^{r_c} (1 - \theta_1)^{g_c} \cdot \theta_2^{r_\ell} (1 - \theta_2)^{g_\ell}$$

$$\begin{aligned}
 L &= [c \log \theta + \ell \log(1 - \theta)] \\
 &+ [r_c \log \theta_1 + g_c \log(1 - \theta_1)] + [r_\ell \log \theta_2 + g_\ell \log(1 - \theta_2)]
 \end{aligned}$$



Više parametara — nastavak

Derivacije od L sadrže samo bitan parametar:



$$\frac{\partial L}{\partial \theta} = \frac{c}{\theta} - \frac{\ell}{1-\theta} = 0 \quad \Rightarrow \quad \theta = \frac{c}{c+\ell}$$

$$\frac{\partial L}{\partial \theta_1} = \frac{r_c}{\theta_1} - \frac{g_c}{1-\theta_1} = 0 \quad \Rightarrow \quad \theta_1 = \frac{r_c}{r_c+g_c}$$

$$\frac{\partial L}{\partial \theta_2} = \frac{r_\ell}{\theta_2} - \frac{g_\ell}{1-\theta_2} = 0 \quad \Rightarrow \quad \theta_2 = \frac{r_\ell}{r_\ell+g_\ell}$$

U slučaju potpunog skupa podataka, parametri se mogu učiti zasebno.

ML za neprekidni model — linearni Gaussov model



Maksimizacija $P(y|x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(y-(\theta_1x+\theta_2))^2}{2\sigma^2}}$ obzirom na θ_1, θ_2

= minimizacija $E = \sum_{j=1}^N (y_j - (\theta_1x_j + \theta_2))^2$

Minimizacija sume kvadrata grešaka daje ML rješenje za linearnu aproksimaciju uz pretpostavku da **Gaussov šum ima fiksnu varijancu**

Sažetak

Potpuno Bayesovo učenje daje najbolja moguća predviđanja ali nije ostvarivo

MAP učenje uravnotežuje složenost s točnošću na podacima za treniranje

Maksimalna izglednost prepostavlja uniformnu apriori vjerojatnost, OK za velike skupove podataka