

# Strojno učenje

Tehnike učenja bazirane na Bayesovom pristupu

Tomislav Šmuc

## Bayesian Learning ; Hidden Markov Models

### •The Elements of Statistical Learning

Hastie, Tibshirani, Friedman (Ch 17 Undirected Graphical Models)

Chris Bishop: Pattern Recognition and Machine Learning

- Chapter 8: Graphical Models
- Chapter 12: Sequential Models

L.R. Rabiner: "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition"

- » Osnovni koncepti
  - Vjerojatnost
  - Slučajne varijable
  - Bayesovo pravilo
- Bayesove mreže
- Zaključivanje u BM
- Učenje BM iz podataka

## Dva pristupa

### Frekvencijski pristup

- „Fizička” izglednost da će se događaj s ishodom  $i$  zbiti
- Aproksimira se kao omjer broja događaja s ishodom  $i$  / ukupan broj događaja
- „Točkaste” procjene  $n/N$

### Bayesov pristup

- Vjerojatnost je **stupanj uvjerenja** da će se događaj s ishodom  $i$  zbiti
- Vjerojatnosti moraju biti uvjetovane podacima, t.j.  $p(y/x)$
- B. pristup = Optimalan pristup (ako je model dobar, apriorna distribucija dobra, funkcija gubitaka dobra...)
- „Točkaste” procjene su loše. Valjane vjerojatnosti su dobivene a posteriori i bazirane su na evidenciji (podacima) uz dane apriorne vjerojatnosti

- Distribucije vjerojatnosti  $P(X/\xi)$ 
  - $X$  slučajna varijabla
    - diskretne
    - kontinuirane
  - $\xi$  neko stanje ili informacija o stanju u „pozadini”

## Diskretne slučajne varijable


- Konačni broj ishoda

$$X \in \{x_1, x_2, x_3, \dots, x_n\}$$

$$P(x_i) \geq 0$$

$$\sum_{i=1}^n P(x_i) = 1$$

binarna X:  $P(x) + P(\bar{x}) = 1$




## Kontinuirane slučajne varijable

- Distribucije vjerojatnosti (funkcije gustoće vjerojatnosti) preko kontinuiranih vrijedosti

$$X \in [0,10] \quad P(x) \geq 0$$

$$\int_0^{10} P(x) dx = 1$$

$$P(5 \leq x \leq 7) = \int_5^7 P(x) dx$$



## Vjerojatnost (drugi oblici)

- Skupna vjerojatnost

$$P(x, y) \equiv P(X = x \wedge Y = y)$$

– Vjerojatnost da su (istovremeno)  $X=x$  i  $Y=y$

- Uvjetna vjerojatnost

$$P(x | y) \equiv P(X = x | Y = y)$$

– Vjerojatnost da je  $X=x$  u slučajevima kada je  $Y=y$

## Bayes i vjerojatnost, osnovni koncepti

- „Produktno” pravilo

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

- Marginalizacija

$$P(Y) = \sum_{i=1}^n P(Y, x_i) \quad \text{Binarna X: } P(Y) = P(Y, x) + P(Y, \bar{x})$$

- Bayesovo pravilo

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



$$P(X | Y) = \frac{P(Y | X)P(X)}{P(Y)}$$

## Problem

Iz  $N$  pokušaja bacanja novčića želimo odrediti vjerojatnost pojave glave u  $N+1$  bacanju.

## Rješenje

Bayesovo pravilo: aposteriorna vjerojatnost modela  $\theta$  uz dane podatke  $D$  i znanje (background knowledge)  $\rho$ :

$$p(\theta|D, \rho) = \frac{p(\theta|\rho) \cdot p(D|\theta, \rho)}{p(D|\rho)}$$

Gdje je  $p(D|\rho) = \int p(D|\theta, \rho) \cdot p(\theta|\rho) d\theta$

$\theta$  je (u ovom slučaju) varijabla čija vrijednost odgovara mogućoj stvarnoj vrijednosti „fizičke” vjerojatnosti

## Funkcija izglednosti(?) („Likelihood“)

Koliko je dobra/ispravna vrijednost  $\theta$  ?

To ovisi o tome koliko dobro može generirati uočenu sekvencu !

$$L(\theta|D) = P(D|\theta)$$

T.j. izglednost sekvence G,P,G,P,P je npr.

$$L(\theta|D) = \theta \cdot (1 - \theta) \cdot \theta \cdot (1 - \theta) \cdot (1 - \theta)$$

## MLE - Maximum Likelihood Estimation

### MLE princip:

- Učenje modela => učenje parametara koji maksimiziraju izglednost-vjerojatnost generiranja podataka
- Jedan od najčešćih u statistici – i u strojnom učenju
- Da bi odredili ML – potrebno je imati funkciju (dovoljnu statistiku) koja iz podataka sumira potrebnu informaciju za izračunavanje izglednosti (u slučaju pismo-glava sekvenci => broj G/P

## Određivanje $P(X | D, \kappa)$ ....

Prosjek preko vrijednosti  $\theta$  da bi se odredila vjerojatnost da će N+1 bacanje biti G:

$$P(X = G | D, \kappa) = \int \Theta p(\Theta | D, \kappa) d\theta$$

$P(X | D, \kappa)$  – očekivanje  $\theta$  s obzirom na distribuciju  $p(\theta | D, \kappa)$

## Osnove

- Definicije
- Reprezentacija
- Uvjetna nezavisnost

## Bayesova mreža

- grafički model probabilističkih odnosa između grupa varijabli, koji efikasno definira/kodira združenu distribuciju vjerojatnosti vrijednosti svih varijabli u skupu

Zašto je pristup (učenju) preko Bayesovih mreža interesantan ?

- Okvir za učenje o kauzalnim odnosima
- Zaključivanje na nekompletnim podacima
- Olakšano kombiniranje znanja u domeni (background knowledge) i podataka
- Efikasan način izbjegavanja overfitting-a podataka

## Definicija:

- Bayesova mreža nad skupom varijabli  $\mathbf{X} = \{X_1, X_2, \dots, X_n\}$  je:
  - Mrežna struktura  $\mathbf{S}$  koja kodira „tvrdnje“ o uvjetnoj nezavisosti među varijablama iz  $\mathbf{X}$
  - Skup lokalnih distribucija (uvjetnih) vjerojatnosti
- Mrežna struktura  $\mathbf{S}$  je usmjereni aciklički graf (DAG);
- Čvorovi su varijable;
- Veze između čvorova označuju probablističku zavisnost između dvije varijable;
- Uvjetne vjerojatnosti kodiraju jačinu veze između vrijednosti varijabli

## Konstrukcija Bayesove mreže (ekspertski pristup)

Pristup se zasniva na slijedećim praktičnim uvidima:

- Ljudi često dobro poznaju kauzalne odnose između varijabli;
- Kauzalni odnosi tipično korespondiraju sa tvrdnjama uvjetne vjerojatnosti;
- Da bi konstruirali BM jednostavno crtamo veze između varijabli i to od uzročnih prema njihovim neposrednim efektima;
- U konačnom koraku određujemo lokalne distribucije vjerojatnosti.

Određivanje u praksi (korištenje) može dovesti do promjene strukture mreže

## Kriteriji za odabir modela

Kriterij mora biti dovoljno dobar da odredi stupanj do kojeg mreža odgovara prethodnom znanju i podacima

Prmjer kriterija

- Relativna posteriorna vjerojatnost

Logaritam relativne posteriorne vjerojatnosti :

$$\log(p(D|S)) = \underbrace{\log(p(S))}_{\text{log apriorne vjerojatnosti}} + \underbrace{\log(p(D|S))}_{\text{log marginalne vjerojatnosti}}$$

## Apriorne vjerojatnosti

Potrebne su za izračun relativne posteriorne vjerojatnosti

- Apriorne strukturne vjerojatnosti  $p(S)$ 
  - Pretpostavka da je svaka hipoteza jednako vjerojatna
  - Varijable mogu biti poredane a prisustvo/odsustvo veza su međusobno nezavisni
  - Mogu se koristiti i prije određene mreže (sa sličnom namjenom)
- Parametarske apriorne vjerojatnosti  $p(\theta | S)$

## Koristi od učenja strukture BM

- Efikasno učenje/modeliranje → točniji modeli sa manje podataka
  - $P(A)$  i  $P(B)$  → velika ušteda podataka u odnosu na  $P(A,B)$  !
- Otkrivanje strukturnih (kauzalnih) svojstava domene
- Uređivanje događaja koji se događaju sekvencionalno
- Pomaže u analizama osjetljivosti te u zaključivanju
- Predviđanje efekata nekih akcija

## Terminologija i semantika BM

Z je roditelj od X



Z utječe na X;  
Z uzrokuje X;  
X ovisi o Z

X je dijete od Z


BM => DAG => izjave o zavisnosti/nezavisnosti među varijablama  
Nezavisnost => familija distribucija vjerojatnosti

## Primjer: bacanje dva novčića

$P(y):$

G:0.5

P:0.5



$P(z):$


G:0.5

P:0.5

## Definiranje BM

1. Struktura  
(zavisnost ,nezavisnost)
2. Distribucija vjerojatnosti

x	GG	GP	PG	PP
$P(x y,z):$	0.25	0.25	0.25	0.25



## BM

Kompaktna reprezentacija odnosa varijabli

Faktorizacija distribucije vjerojatnosti

Svaka distribucija vjerojatnosti konzistentna sa nekim DAG – morase faktorizirati prema:


$$P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | \mathbf{R}_i)$$

gdje je

$\mathbf{R}_i$  – oznaka za roditelje  $X_i$


(pravilo produkta za BM!)

# Združena vjerojatnost - faktorizacija



$$\begin{aligned}
 &P(D, S, Z, Pu, R, SC, Rp) \\
 &= P(D) \cdot P(S) \cdot P(Z | D) \\
 &\cdot P(Pu | D, S) \cdot P(R | Pu, Z) \\
 &\cdot P(SC | R) \cdot P(Rp | R)
 \end{aligned}$$

## Nezavisnost varijabli



Dob i spol su nezavisni  $\rightarrow P(D,S) = P(D)P(S)$

---


$$P(D|S) = P(D) \quad D \perp S$$

$$P(S|D) = P(S) \quad S \perp D$$

$$P(D,S) = P(S|D) P(D) = P(S)P(D)$$

$$P(D,S) = P(D|S) P(S) = P(D)P(S)$$

## Uvjetna nezavisnost u BM




Ukoliko znamo status varijable *Pušenje*, *Rak* postaje nezavisna o *Dobi* i *Spolu*.

$$P(R|D,S,Pu) = P(R|Pu) \quad R \perp D,S \mid Pu$$

## Uvjetna nezavisnost u BM

Varijabla (čvor) je uvjetno nezavisan od svojih nepotomaka, uz zadane roditelje




*Rak* je nezavisan od *Dobi* i *Spola* uz zadano *Zagađenje* i *Pušenje*.

## Nezavisnost i odvojenost u DAG

- Uz dane (neke) opservacije, da li je neki skup varijabli neovisan o drugom skupu ?
- Opservacije induciraju zavisnosti !
- **d-separacija** (Pearl 1988) – kako grafički provjeriti uvjetnu nezavisnost u grafu


# Prediktivno zaključivanje



Koliko je vjerjatno da  
*Stariji muškarci*  
Obole od *Raka*?

$$P(R=Da \mid Dob > 60, Spol = muški)$$

# Prediktivno zaključivanje

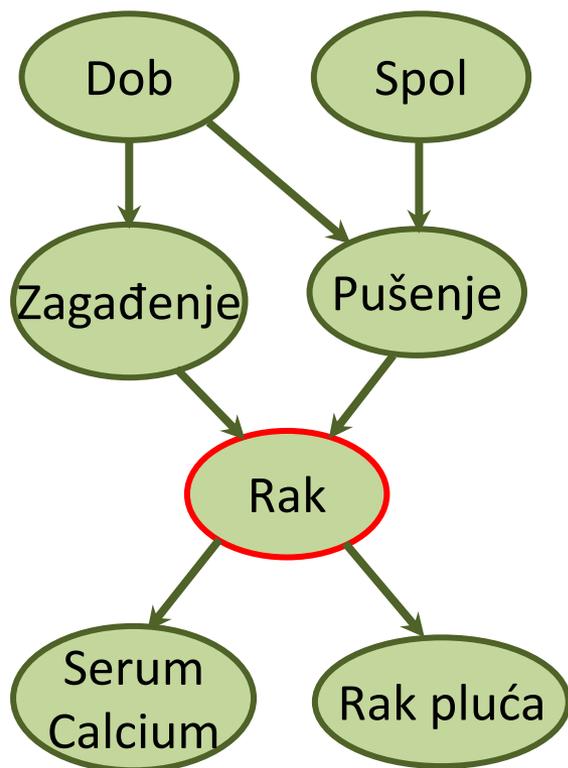


Koliko je vjerojatno da *stariji muškarci*

Sa povišenim *SC* dobiju *Rak*?

$$P(R=Da \mid Dob > 60, Spol = muški, SC = visok)$$

## Efekt “objašnjavanja” (explaining away)



- Ako smo otkrili *Rak pluća*, vjerojatnost *povišenog pušenja* i *zagađenja* rastu !
- Ako smo dodatno ustanovili prisutnost *zagađenja* vjerojatnost *povišenog pušenja* pada !

## Osnovno zaključivanje: Pravilo produkta

$P(R_j, Pu_i)$

$Pu \downarrow R \Rightarrow$	ne	da
ne	0.70	0.05
malo	0.13	0.07
puno	0.03	0.02

$Pu \in \{ne, malo, puno\}$

$Rak \in \{ne, da\}$



$P(R_j | Pu_i)$

Pušenje=	ne	malo	puno
$P(R=ne)$	0.933	0.65	0.6
$P(R=Da)$	0.067	0.35	0.4

## Pravilo produkta

$$P(R, Pu) = P(R | Pu)P(Pu)$$

		$P(R, Pu)$	
$Pu \downarrow$	$R \Rightarrow$	ne	da
ne		0.70	0.05
malo		0.13	0.07
puno		0.03	0.02



## Marginalizacija

$Pu \downarrow$	$R \Rightarrow$	ne	da	ukupno
ne		0.70	0.05	<b>0.75</b>
malo		0.13	0.07	<b>0.20</b>
puno		0.03	0.02	<b>0.05</b>
ukupno		<b>0.86</b>	<b>0.14</b>	

$P(Pu)$

$P(R)$


$$P(Pu | R) = \frac{P(R | Pu)P(Pu)}{P(R)} = \frac{P(R, Pu)}{P(R)}$$

$Pu \downarrow$	$R \Rightarrow$	ne	da
ne		0.70/0.86	0.05/0.14
malo		0.13/0.86	0.07/0.14
puno		0.03/0.86	0.02/0.14

$$P(R | Pu) = \frac{P(Pu | R)P(R)}{P(Pu)} = \frac{P(R, Pu)}{P(Pu)}$$

$Pu \downarrow$	$R \Rightarrow$	ne	da
ne		0.70/0.75	0.05/0.75
malo		0.13/0.20	0.07/0.20
puno		0.03/0.05	0.02/0.05

## Osnovno zaključivanje




$$\underbrace{P(b)} = \sum_a P(a, b) = \sum_a P(b | a) P(a)$$

$$P(c) = \sum_b P(c | b) \overbrace{P(b)}$$

$$P(c) = \sum_{b,a} P(a, b, c) = \sum_{b,a} P(c | b) P(b | a) P(a)$$

$$= \sum_b P(c | b) \underbrace{\sum_a P(b | a) P(a)}_{P(b)}$$

## Osnovno zaključivanje



Stabla

$$P(x) = \sum_{z, y} P(x / z, y) P(z, y)$$



Zato što su  $z, y$  nezavisne

$$= \sum_{z, y} P(x / z, y) P(z) P(y)$$


# Eliminacija varijabli




$$P(c) = \sum_b P(c | b) \underbrace{\sum_a P(b | a) P(a)}_{P(b)}$$



## Združena stabla (Join trees)



## Parcijalna faktorizacija



## BM zaključivanje kao eliminacija varijabli

- Faktorizacija preko  $\mathbf{X}$  je funkcija koja preslikava vrijednosti  $\mathbf{X}$  na  $[0,1]$ :
  - Tablica uvjetnih vjerojatnosti
  - Združena distribucija vjerojatnosti
- BM zaključivanje:
  - Faktore možemo množiti da bi dobili nove
  - Možemo sumirati po varijablama (marginalizacija) i time ih “izbaciti” iz daljnjeg razmatranja
  - Varijabla se može izbaciti (sumirati) kada su svi faktori koji je koriste izmnoženi

## Učenje Bayesovih mreža iz podataka


### Zadaci

- Učenje parametara
  - Kompletni podaci
  - Nekompletne podaci (missing values)
- Učenje strukture

## Učenje BM

<i>D</i>	<i>S</i>	<i>Z</i>	<i>Pu</i>	<i>R</i>
<30	z	v	p	ne
<40	m	?	m	da
		⋮		

skup za učenje



- Ulaz: kompletni ili nekompletni podaci?
- Model: Parametri uz zadanu mrežu ili parametri +struktura?

# MLE (podsjetnik)

- Ulaz: rezultat bacanja

$$X_1, \dots, X_n = \underbrace{\{G, G, G, P, P, P, \dots, G, P\}}$$

- Procjena  $\theta$
- Izglednost  $P(X_1, \dots, X_n \mid \theta) = \theta^G (1-\theta)^P$
- ML rezultat:  $\theta^* = \frac{G}{G+P}$

# Učenje BM parametara

- Kompletни podaci:

$$\theta_{x/z} = \frac{\# \text{ primjera } x, z}{\# \text{ primjera } z} = \frac{\sum_j I(x, z | d_j)}{\sum_j I(z | d_j)}$$

$$I(z/d_j) = \begin{cases} 1 & \text{Ako } Z=z \text{ za podatak } d_j \\ 0 & \text{inače} \end{cases}$$

- Nekompletни podaci  $I(z/d_j)$  nije poznato?!

Procijeniti  $I$ :  $\hat{I}(x, z | d_j) = P_\theta(x, z | d_j)$

No – ne znamo  $\theta$  !

BM učenje parametara u slučaju nekompletnih podataka – EM algoritam

Iteriraj do konvergencije ( $|\Delta\theta| \sim 0$ )

- Izračunaj očekivanje (Expectation – E step)
  - Koristi trenutne parametre  $\theta_k$  da bi popunio MV u podacima

$$\hat{I}(x, z | d_j) = P_{\theta_k}(x, z | d_j)$$

- Izračunaj novi  $\theta_{k+1}$  (Maximization -M step)
  - Koristi komplet(ira)ne podatke da bi dobio novi MLE  $\theta$

$$\theta_{x|z} = \frac{\sum_j \hat{I}(x, z | d_j)}{\sum_j \hat{I}(x | d_j)}$$

## Učenje strukture BM

### **Cilj:**

“Dobra” BM (u odnosu na podatke)

### **Tipično rješenje:**


Heurističko pretraživanje prostora struktura

## Učenje strukture BM = pretraživanje

Prostor pretraživanja = prostor mrežnih struktura

Operatori = dodaju/brišu veze; mijenjaju usmjerenje veza

Algoritmi pretraživanja = greedy, hill-climbing, GA...



TS: Strojno učenje – Tehnike učenja zasnovane na Bayesovom pristupu

## Evaluacija BM strukture

- Uz popunjene parametre (CPT) korištenjem tehnika (faktorizacija, eliminacija varijabli) moguća je evaluacija kompletne mreže
- Evaluacija => ML funkcija:

$$ML(BM) = P(\text{podaci} / BM)$$

Tipično => potpuni graf !? (overfitting)

## MDL mjere

- MDL - Minimum Description Length:  
(regularizacija!) uzima u obzir kompleksnost modela  
(broj parametara  $\sim$  veza u BM)

$$Eval(BM) = P(data \mid BM) - kompleksnost(BM)$$

## **Online materijali i tutoriali**

K. Murphy (2001) <http://www.cs.berkeley.edu/~murphyk/Bayes/bayes.html>

W. Buntine. Operations for learning with graphical models. Journal of Artificial Intelligence Research, 2, 159-225 (1994).

D. Heckerman (1999). A tutorial on learning with Bayesian networks. In Learning in Graphical Models (Ed. M. Jordan). MIT Press.

## **Knjige:**

Daphne Koller and Nir Friedman, "Probabilistic graphical models: principles and techniques", MIT Press 2009

J. Pearl (2000). Causality: Models, Reasoning, and Inference. Cambridge University Press.

M. I. Jordan (ed, 1988). Learning in Graphical Models. MIT Press.

## **Algoritmi:**

C. Huang: Inference in Belief Networks: A Procedural Guide PPTC (Probability Propagation in Trees of Clusters)

## Software

- B-Course (Online course + demo; CoSco – University of Helsinki)
- BAYDA: <http://www.cs.Helsinki.FI/research/cosco>  
Classification
- GeNIe + SMILE (<http://genie.sis.pitt.edu/>)
- BN Power Constructor: BN PowerConstructor
- Microsoft Research: WinMine  
<http://research.microsoft.com/~dmax/WinMine/Tooldoc.htm>
- BUGS: <http://www.mrc-bsu.cam.ac.uk/bugs>
- Hugin: <http://www.hugin.dk>