

18. Probabilistički grafički modeli II

Strojno učenje 1, UNIZG FER, ak. god. 2021./2022.

Jan Šnajder, natuknice s predavanja, v1.4

1 Zaključivanje

- Primjer trave i prskalice (v. predavanje 17):

$$p(c, s, r, w) = p(c)p(s|c)p(r|c)p(w|s, r)$$

- Upit: Ako je trava mokra ($w = 1$), koja je vjerojatnost kiše (r) i prskalice (s)?

$$\begin{aligned} P(s = 1|w = 1) &= \frac{P(s = 1, w = 1)}{P(w = 1)} \\ &= \frac{\sum_{c,r} P(c, s = 1, r, w = 1)}{\sum_{c,r,s} P(c, s, r, w = 1)} = 0.2781/0.6471 = 0.43 \\ P(r = 1|w = 1) &= \frac{P(r = 1, w = 1)}{P(w = 1)} \\ &= \frac{\sum_{c,s} P(c, s, r = 1, w = 1)}{\sum_{c,r,s} P(c, s, r, w = 1)} = 0.4851/0.6471 = 0.708 \end{aligned}$$

gdje je $P(w = 1)$ **vjerojatnost dokaza**

- Dvije vrste upita: (1) posteriorni upiti i (2) MAP-upiti
- **Posteriorni upit** je izračun uvjetne vjerojatnosti:

$$p(\mathbf{x}_q|\mathbf{x}_o) = \frac{\sum_{\mathbf{x}_n} p(\mathbf{x}_q, \mathbf{x}_o, \mathbf{x}_n)}{p(\mathbf{x}_o)} = \frac{\sum_{\mathbf{x}_n} p(\mathbf{x}_q, \mathbf{x}_o, \mathbf{x}_n)}{\sum_{\mathbf{x}'_n, \mathbf{x}'_q} p(\mathbf{x}'_q, \mathbf{x}_o, \mathbf{x}'_n)}$$

gdje su \mathbf{x}_q varijable upita, \mathbf{x}_o su opažene varijable, a \mathbf{x}_n varijable smetnje (*nuisance*)

- **MAP-upiti** – najvjerojatnija vrijednost varijabli upita:

$$\mathbf{x}_q^* = \operatorname{argmax}_{\mathbf{x}_q} \sum_{\mathbf{x}_n} p(\mathbf{x}_q, \mathbf{x}_o, \mathbf{x}_n)$$

2 Zaključivanje: eliminacija varijabli

- Odgovaranje upita iziskuje konstrukciju $p(\mathbf{x}_q, \mathbf{x}_o, \mathbf{x}_n)$ pa marginalizaciju/normalizaciju
- Velik $n \Rightarrow$ **kombinatorna eksplozija** \Rightarrow NP-složen problem
- Poništava prednost Bayesove mreže (sažet zapis zajedničke distribucije)
- Alternative: **egzaktno zaključivanje i približno zaključivanje**
- **Eliminacija varijabli** – egzaktno zaključivanje pomoću dinamičkog programiranja
- **Eliminacija varijabli zbroj-umnožak** – potiskivanje marginalizacije što dublje:

$$\begin{aligned} p(w) &= \sum_c \sum_s \sum_r p(c, s, r, w) \\ &= \sum_c \sum_s \sum_r p(c)p(s|c)p(r|c)p(w|s, r) \\ &= \sum_s \sum_r p(w|s, r) \underbrace{\sum_c p(c)p(s|c)p(r|c)}_{t_1(s, r)} \\ &= \sum_s \underbrace{\sum_r p(w|s, r)t_1(s, r)}_{t_2(s, w)} \\ &= \sum_s t_2(s, w) \\ &= t_3(w) \end{aligned}$$

- Varijante algoritma za skriveni Markovljev model (HMM):
 - eliminacija varijabli \Rightarrow **algoritam naprijed nazad** (*forward-backward algorithm*)
 - MAP-upiti \Rightarrow **Viterbijev algoritam**
- Za općenite Bayesove mreže eliminacija varijabli je presložena
- Alternativa: približno zaključivanje – **propagacijski algoritmi i metode uzorkovanja**

3 Zaključivanje: metode uzorkovanja

- Ideja: procjena distribucije na temelju uzorka
- Ako uzorkujemo uzorke $\mathbf{x} \sim P(\mathbf{x})$, očekivanje je:

$$P(\mathbf{x} = x) = \frac{1}{N} \sum_{i=1}^N \mathbf{1}\{\mathbf{x} = x\}$$

- Najjednostavnija metoda: **unaprijedno uzorkovanje** (*forward sampling*)
 - Uzorkovanje varijable za varijablom, prema topološkom uređaju mreže

– Problem: želimo uzorkovati iz uvjetne vjerojatnosti $P(\mathbf{x}_q | \mathbf{x}_o)$

- **Uzorkovanje s odbijanjem** (*rejection sampling*)

- Uzorkovanje unaprijed i odbijanje \mathbf{x} za koje \mathbf{x}_o nisu na željenim vrijednostima
- Problem: neučinkovito, osobito ako je vjerojatnost dokaza $P(\mathbf{x}_o)$ malena

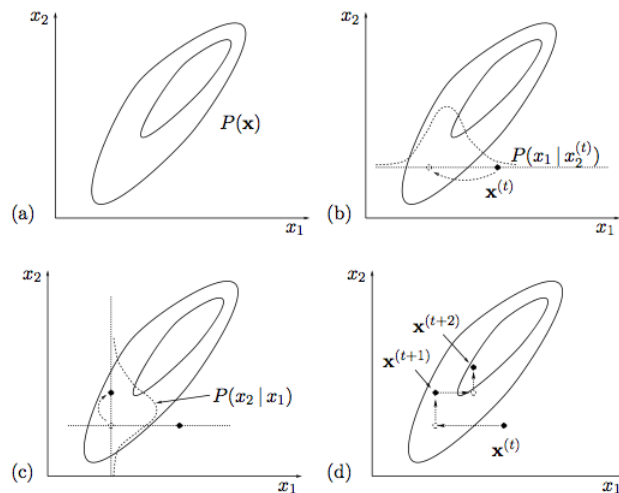
- **Uzorkovanje po važnosti** (*importance sampling*)

- Postavljanje \mathbf{x}_o na željene vrijednosti, unaprijedno uzorkovanje i korekcija očekivanja
- Problem: loša kvaliteta procjene, pogotovo ako su \mathbf{x}_o pri dnu Bayesove mreže

- **Gibbsovo uzorkovanje** (*Gibbs sampling*)

- Postupak iz porodice **Markov Chain Monte Carlo (MCMC)**
- Krenuvši od slučajnog vektora \mathbf{x} , uzorkujemo ciklički varijablu po varijablu

$$\begin{aligned} \mathbf{x}^0 &\sim p(x_1^0, x_2^0, x_3^0) && \Rightarrow \text{početni vektor (npr., unaprijednim uzorkovanjem)} \\ x_1^1 &\sim p(x_1 | x_2^0, x_3^0) \\ x_2^1 &\sim p(x_2 | x_1^1, x_3^0) \\ x_3^1 &\sim p(x_3 | x_1^1, x_2^1) && \Rightarrow \text{vektor } \mathbf{x}^1 = (x_1^1, x_2^1, x_3^1) \\ x_1^2 &\sim p(x_1 | x_2^1, x_3^1) \\ x_2^2 &\sim p(x_2 | x_1^2, x_3^1) \\ x_3^2 &\sim p(x_3 | x_1^2, x_2^2) && \Rightarrow \text{vektor } \mathbf{x}^2 = (x_1^2, x_2^2, x_3^2) \\ &\vdots \end{aligned}$$



4 Učenje

- PGM-ovi su probabilistički modeli \Rightarrow učenje se svodi na **procjenu parametara θ**
- MLE, MAP ili bayesovska procjena

- Log-izglednost za općenitu Bayesovu mrežu:

$$\begin{aligned}
 \ln \mathcal{L}(\boldsymbol{\theta}|\mathcal{D}) &= \ln p(\mathcal{D}|\boldsymbol{\theta}) \\
 &= \ln p(\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(N)}|\boldsymbol{\theta}) \\
 &= \ln \prod_{i=1}^N p(\mathbf{x}^{(i)}|\boldsymbol{\theta}) \\
 &= \ln \prod_{i=1}^N \prod_{k=1}^n p(x_k^{(i)}|\text{pa}(x_k^{(i)}), \boldsymbol{\theta}_k) \\
 &= \ln \prod_{k=1}^n \prod_{i=1}^N p(x_k^{(i)}|\text{pa}(x_k^{(i)}), \boldsymbol{\theta}_k) \\
 &= \sum_{k=1}^n \sum_{i=1}^N \ln p(x_k^{(i)}|\text{pa}(x_k^{(i)}), \boldsymbol{\theta}_k)
 \end{aligned}$$

- MLE procjena za k -ti čvor:

$$\boldsymbol{\theta}_k^* = \underset{\boldsymbol{\theta}_k}{\operatorname{argmax}} \sum_{i=1}^N \ln p(x_k^{(i)}|\text{pa}(x_k^{(i)}), \boldsymbol{\theta}_k)$$

- MAP procjena za k -ti čvor:

$$\boldsymbol{\theta}_k^* = \underset{\boldsymbol{\theta}_k}{\operatorname{argmax}} \left(\sum_{i=1}^N \ln p(x_k^{(i)}|\text{pa}(x_k^{(i)}), \boldsymbol{\theta}_k) + \ln p(\boldsymbol{\theta}_k) \right)$$

- MAP-procjena za kategorijsku razdiobu (Dirichlet-kategorijski model uz $\alpha = 2$):

$$\begin{aligned}
 \hat{\mu}_{k,j,l} &= \frac{N_{kjl} + 1}{N_{kj} + K_k} \\
 N_{kjl} &= \sum_{i=1}^N \mathbf{1}\{\mathbf{x}_{\text{pa}(x_k)}^{(i)} = j \wedge x_k^{(i)} = l\} \\
 N_{kj} &= \sum_l N_{kjl}
 \end{aligned}$$

gdje je K_k broj mogućih vrijednosti varijable x_k

- Primjer: MAP procjena za čvor w u mreži s travom i prskalicom (v. predavanje 17):

$$P(w|s, r) = \frac{\sum_{i=1}^N \mathbf{1}\{x_s^{(i)} = s \wedge x_r^{(i)} = r \wedge x_w^{(i)} = w\} + 1}{\sum_{i=1}^N \mathbf{1}\{x_s^{(i)} = s \wedge x_r^{(i)} = r\} + 2}$$

- Modeli sa skrivenim varijablama (npr., HMM, GMM) \Rightarrow tzv. **nepotpuni podatci**
 - Log-izglednost se ne dekomponira po strukturi grafa
 - \Rightarrow MLE nema rješenje u zatvorenoj formi
 - Učenje pomoću **algoritma maksimizacije očekivanja** ili **gradijentnim usponom**
- **Učenje strukture mreže:**
 - Polunaivan Bayesov klasifikator: v. 4.3.2–4.3.4 u skripti
 - Učenje općenite strukture Bayesove mreže: **algoritam K2**