

1) - Bayes döntési helyzet

PDSS-szelv.
PDSS becslesdöntes?

- Alaphelyzet: akció/leimenebel (hasznosság / akció
véltendő hasznossága) / maximális várh. hasznosság
elve

PDSS-ko-eth.

- További információ értéke

- Szekvenciális döntési helyzet, opt. döntés szelev.
problémákban

PDSS-szelv

2) - Döntés / Predikció minősége

6 \in | - Hasznosság függvények (DI, FI)

7 \Leftarrow | - Bináris eset

- Standard mérőszámok (sens., spec., ROC, AUC)

3) Markov-lánc

PDSS-ko-eth/22

- def

- állapotátmenet átmen. eloszlás szimmetrikussága

- invariáns eloszlás

- vekt. eo.

10/16

- stabilitás aperiodicitás & irreducibilitás mellett

- reverzibilitás

- Metropolis-Hasting alg (helyesség biz)

* - Gibbs n (n MH-ra való visszavezetéssel)

4) Rejtett Markov-modellek

12, 13

12 - eloszlás repr.

* - követh. tip: - prediktív }
- szűrés }
- levezetés }

- Bayes szabály

- Diagn. következtetés: - Általános forma / Bináris eset

⑤ Nai. Bayes-modell

8.3

PDSS-prob. graph. mod^{ur}

- Előzetés repr.

- Bayes - szabály

- Diagn. következtetés: Általános forma/bin. (log lin) eset

8.11

⑥ Előzetési függetlenségi viszonyai

10

PDSS-prob-graph. mod

- grafosszög axiómái (valószínűségi 4. ax)

- Bayes-kritérium definíciói (sorrendi és d-elt.)

10/14

o-reprezentálhatóság

- 2 példa magasabb. ftlu & tranzitivitás

- teljesítség összes param. tekintetbe

10/14 - ekvivalenciaosztályok & alábbi értékek lefedése

- Markov lánc repr való viszony

x - Markov - lánc def

14

PDSS-konv. 22

o-repr.

- 2 példa

- Bayes-h való viszony

⑦ Előzetési dekompozíció

9

- feltételes való def

- függetlenség

def

10/13

- láncszabály

10/13

- Markov lánc és faktor (Markov-lánc & lánc, Bayes-lánc)

- Bayes-lánc való repr (teljesítség biz)

- Markov ~ (érték és ~)

① Teljes Bayes-i megközelítés Bayes-hallásban

10/22 - strukturális priorok

11 20.04

10/23 - paraméter priorok (Dirichlet-ek)

Chapter 20.pdf

10/29 - Teljes Bayes-i kör ált. formulája

+

+ ⑨ Exakt következtetés polifalában

levezetés

19/11

PDSS-10-18

126

⑩ Az exakt következtetés NP teljes

3SAT levezetés 19/11

PDSS-26

+ ⑪ Exakt kör általános Bayes-hallásban

(levezetés már) 8/11

- Kardialis grafok és lefolyozás

- Kliquek fája 8/11 PDSS-P

⑫ Monte-Carlo következtetés általános

Bayes-hallásban

19

- Dirichlet mintavétel

- fontosság mintavétel (likelihood súlyozás)

- Gibbs mintavételi súlyozás

PDSS-10-22

Bayes döntési helyzet

$C(y, y')$ költségfn.

Ha $\forall y \in Y$ -ra $C(y, y')$ konstans $\forall y' \in \bar{Y} \forall y_1 - a \Rightarrow$
döntési probléma

Ha nem így van \rightarrow becslési probléma

$C(y, g(x))$ függ (y, y') -ből, maga is valószínű változó

$R(g) = E[C(y, g(x))] \Rightarrow$ optimális g megkeresése
 \Downarrow
 Risk g globális Bayes feladat

$$r(g, x) = E[C(y, g(x)) | X=x]$$

\downarrow
 Lokális becslés

Költségfüvek:

$C_0(y, y') = 1_{y \neq y'}$ indifferens

$C_1(y, y') = \|y - y'\|$ abszolút létsz

$C_2(y, y') = \|y - y'\|^2$

Optimalizálás

$\operatorname{argmax}_{y \in Y} P(Y=y)$

medialis

várható $E(Y)$

Bayes-döntés

$\{y = y_i\}$ - i - hipotézis

$q_i = P(Y=y_i)$ a priori valósz

$q_i(x) = P(Y=y_i | X=x)$ posteriori valósz

g - döntési fn
 $g(x)$ - döntés

X egy particiója: $D_i = \{x \in X | g(x) = y_i\} \quad i=1..k$

$D_j^* \Leftrightarrow d_j(x) < d_i(x) \quad \forall i < j$

$d_j(x) \leq d_i(x) \quad \forall i > j$

\Rightarrow feltételekkel megk. g^* döntési fn Bayes-döntés.
 x -re minimális leh. vesz \Rightarrow optimális $r(x) = \min_i d_i(x)$

Többlebinformáció értéke

$$VPI(x|E) = \sum_{x \in X} P(x|E) \cdot |E| \cdot [U(x)] - E_{\{U|E\}} [U(x)]$$

Egy vagy több új változó ismerete hogyan befolyásolja a változó hasznosságát.

A léptet: Az új evidencia feltételes valószínűségi súlyozva melletti abszolút hasznosságát hozza elő az új evidencia belépése

Változó hasznosság maximalizáció

$$MEU(a^*|s) = \max_{a \in A} MEU(a|s) = \max_{a \in A} \sum_{s_i \in S} U(s_i) P(s_i|a, s)$$

Szekvenciális döntés

$$U^+(s) = U(s) + \sum_{s_i \in S} U^{++}(s_i) P(s_i|a, s)$$

$$MEU(a^*|s) = \max_{a \in A} \sum_{s_i \in S} U^+(s_i) P(s_i|a, s)$$

végtelen lépéses és esetében lezárítással

$$MEU'(a^*|s) = \max_{a \in A} \sum_{s_i \in S} \gamma U^+(s_i) P(s_i|a, s)$$

További info értéke

a_i hasznos
megsz. a det

$$MEU(a^*|d) = \max_{a \in A} EU(a|d) = \max_{a \in A} \sum_{d_i \in D} U(d_i) P(d_i|a, d)$$

$$VPI_d(D_j) = \left[\sum_{d_i \in D} P(D_j = d_i|d) MEU(a_{P_j}^*|D_j = d_i, d) \right] - MEU^*(a^*|d)$$

$d \subset d_i$

$VPI \geq 0$, VPI sorrendfüggetlen az infoval, nem additív

② Döntés / Preferencia minősége

Hasznosság függvények

$A \succ B$ Δ preferred over B

$A \sim B$ indifference

$A \succeq B$ B is not preferred to A

\succ - fel sorrendezhető

- tranzitív

- folytonos

- ~~titkosított~~ helyettesíthető

- monoton

} Ha csak látni
vannak nem teljesül,
irracionális pref

Hasznosság lehet: $- U \in [0, 1]$

- Microcost

- Quality Adjusted Life Years

Pénz nem az

Többparaméteres hasznosságú ritkán additív
szigorú dominancia

Eloszlású \Rightarrow bechertikus dominancia


Bináris

$$\text{Érzékenység} = \frac{TP}{TP+FN}$$

$$\text{Specifitás} = \frac{TN}{TN+FP}$$

} Nem függ P/N aránytól

$$AUC = P(g(x_{sick}) < g(x_{healthy}))$$



③ Markov - lánc

Def:

$X = \{x_0, x_1, \dots\}$ Markov lánc, ha $P(x_t | x_{t-1}, \dots, x_0) = P(x_t | x_{t-1})$

Homogén ha $P(x_t | x_{t-1}) = c \quad \forall t \geq 1$

Invariáns eo.

$$p^{inv} = p^{inv} P$$

↓

X átmeneti mátrixa

Ha $p_0 = p^{inv}$

↓

$$\forall t \quad p^{(t)} = p^{inv}$$

Stabilitás: X stabil, ha $\lim_{t \rightarrow \infty} p(x_t) = p^{(\infty)} \exists \&$

előzles, vmint fgtls $p(x_0)$ -tól.

$p^{(\infty)}$ határérték, vagy egyensúlyi előzles

Dimely állapotok bármely n -re elélele

Irreducibilitás diszkrét, véges állapotú X

irred. ha $\forall i, j \quad i \neq j \quad \exists n_{ij} > 0$ vagy $p_{ij}^{(n_{ij})} > 0$

Aperiodicitás \sim aperiodikus, ha $\exists i$ (irreducibilitás)

π_i), hogy $\exists n_i > 0$ bármely $n \geq n_i$ -re $p_{ii}^{(n)} > 0$

Tétel: Ha diszkrét, véges X irreducibilis aperiodikus

\Rightarrow stabil és \exists 1 invariáns eo, mely

X határérték eo.-a. Azaz $p^{(\infty)} = p^{(\infty)} P$ mely

$p^{(\infty)}$ az egyetlen me. és eo.

$$(p^{(\infty)} | p^{inv}) \Rightarrow \pi(x)$$

Metropolis - Hastings

Legyen $\pi(x)$ pozitív, nem normalizált cél-eloszlás
 az állapotterehen felett. Q - átmeneti valószínűségi m.
 $q_{ij} > 0 \Leftrightarrow q_{ji} > 0$. Definíció: X -et

$$i \neq j : p_{ij} = q_{ij} \min\left(1, \frac{\pi_j q_{ji}}{\pi_i q_{ij}}\right) \rightarrow \frac{0}{0} = 0$$

$$p_{ii} = 1 - \sum_{j \neq i} p_{ij}$$

Q definiált X eo. $\pi(x)$, a részletes
 egyensúly feltétel teljesül. $i=j$ & $q_{ij} = q_{ji} = 0$ esetre
 triviálisan. Ha $i \neq j$ & $q_{ij} > 0$

$$\pi_i p_{ij} = \pi_i \frac{q_{ij} q_{ji}}{q_{ij}} = \pi_j q_{ji} = \pi_j p_{ji} \quad \square$$

Ha Q irreducibilis $\Rightarrow P$ is az lesz
 \sim aperiodikus $\rightarrow \sim$

Teljesen ha legalább egy irreduc. és aperiod.
 Q javaslati eo., akkor adott $\pi(x)$ eo. a
 fenti konstrukció stabil és reverzibilis Markov-lánccal
 definiált, $\pi(x)$ invariáns leképezéssel.

0. Aposterior eloszlás P^s konstr
1. Konstr irreduc. & aperi. Q ebben javaslati eo. a domain lez
2. sorozat x_0 kiinduló áll. P^s -ből
3. $t=1,2,\dots$ sorolás $x^t | x^{t-1}$ q -ből

④ 3. lépés
 konvergenciáig

$$\alpha(x, x^*) = \min\left(1, \frac{\pi(x^*) q_{x^* x}}{\pi(x) q_{x x^*}}\right)$$

elfogadási valószínűség

rem, akkor $x_{t+1} = x^*$, ha igen $x_{t+1} = x^t$
 $x^t \rightarrow x^*$

⑤ konvergencia sebesség, $d_j Q \rightarrow \text{Caroz}$

④ Rejtett Markov-modell

Előrejelzés reprezentációja:

- Szűrés (filtering) : bizonyos ^{filtering} állapot számítása,
a jelenlegi állapot feletti a posteriori eo. az
adott időpontig utt bizonyítékok ismerében.

$$P(x_t | e_{1:t})$$

- Előrejelzés (prediction) : jövőbeli állapot
a posteriori eo. $P(x_{t+u} | e_{1:t}) \quad u > 0$

- Simítás : múltbeli állapot feletti a posteriori

$$P(x_u | e_{1:t}) \quad 1 \leq u < t$$

- Legvalószínűbb magyarázat : melyik állapot sorozat
a legvalószínűbb adott megf. generálására

$$\operatorname{argmax}_{x_{1:t}} P(x_{1:t} | e_{1:t})$$

- Lehetséges paraméterezés : (Viterbi-algoritmus)

$$\operatorname{argmax}_{\theta} P(x|\theta)$$

$$P(x_t | e_{1:t})$$

• Szűrés

(Forward - algoritmus)

Model-Likelihood

Szűrés dinamikus programozással

Rekurzió:

$$P(x_{t+1} | e_{1:t+1}) = f(e_{t+1}, P(x_t | e_{1:t}))$$

$$\begin{aligned} P(x_{t+1} | e_{1:t+1}) &= P(x_t | e_{1:t}, e_{t+1}) = \\ &= \alpha P(e_{t+1} | x_t, e_{1:t}) P(x_t | e_{1:t}) \end{aligned}$$

Q1: predikció + becslés
|
 \sum_{x_t}

$$P(x_{t+1} | e_{1:t+1}) = \alpha P(e_{t+1} | x_{t+1}) \sum_{x_t} P(x_{t+1} | x_t) P(x_t | e_{1:t})$$

Idő & állapot, m. konstans elg $f_{1:t+1} = \text{FORW}(f_{1:t}, e_{1:t+1})$

• Stabilitás zörlés $P(x_{t+k} | e_{1:t}) \rightarrow 0$

Naïv Bayes feltevése

Cél $P(Y, X_1, \dots, X_n)$ eo modellezése
teljesen egyetemes valószínűségi modell:

$P(Y | X_1, \dots, X_n)$ eloszlásban $\forall X_i$ teljesen függtlen.

Y hipotézis ismerete

$$P(X_j | X_1, \dots, X_{j-1}, Y) = P(X_j | Y) \quad \text{bármely } j \text{ in } \{1, \dots, n\}$$

Ha H_a - feltételes eloszlások adottak

$P(X_i | Y)$ $\forall i$ -re, akkor a hipotézis

eo:

Bayes-szabály:

$$P(Y | X_{i_1}, \dots, X_{i_m}) = P(X_{i_1}, \dots, X_{i_m} | Y) \frac{P(Y)}{P(X_{i_1}, \dots, X_{i_m})}$$

miel a fttl. miatt

$$P(X_{i_1}, \dots, X_{i_m} | Y) = P(X_{i_1} | Y) P(X_{i_2} | Y) \dots$$

Ha H_a - hipotézisek kölcsönösen kizárólagosak és teljesek is lesznek

$$P(X_{i_1}, \dots, X_{i_m}) = \sum_{Y \in \text{Range}(Y)} P(X_{i_1}, \dots, X_{i_m} | Y) P(Y)$$

és mivel ez adathoz megfigyelés mellett egy normalizációs konstans, elhagyható

$$\boxed{P(Y | X_{i_1}, \dots, X_{i_m}) \propto P(X_{i_1} | Y) \dots P(X_{i_m} | Y) P(Y)}$$

Egy hipotézis valószínűsége az a priori valószínűség és a szimptómák feltételes valószínűsége szorzata.

Diagnosztikai Lövedeztetés

S_1 struktúráján \rightarrow param. helyén

$P(y|x, \theta, S)$ kiszámítása, vagy sztochasztikus közelítése.

Bayes-i paradigmaiban helyett $P(y|x, \theta, S)$ -t
determin. valósz. változó $[0, 1]$ es-t keretében
megkapni vagy \leftarrow

$$P(y|x) = \mathbb{E}_{P(\theta, S)} P(y|x, \theta, S)$$

$$\downarrow$$
$$P(\theta|S) P(S)$$

\downarrow
Dirichlet es. típus.

- Alkalmazás esetében $\neq P$ alg

- Értékés fájl esetén - csomópontok es. lin

- Értékés kilitelési függ. - kilitelésben exp

- Sztochasztikus eszm. - főleg azonos nevelési.

állapotátmeneteknél zst.

6) Eloszlások függetlenségi viszonyai

Gráfok axiómái (függetlenségi ax)

- Szimmetria : $I_p(x, y | z)$ iff $I_p(y, x | z)$

- dekompozíció : $I_p(x, y \cup w | z)$

$$\Downarrow$$
$$I_p(x, y | z) \& I_p(x, w | z)$$

- széles unió : $I_p(x, y \cup w | z) \Rightarrow I_p(x, y | w \cup z)$

- összekezelés : $I_p(x, y | z) \& I_p(x, w | z \cup y)$

$$\Downarrow$$
$$I_p(x, y \cup w | z)$$

Bayes-háló reprezentáció lete

- csúttól eo. látehang ábrázolása

- összefüggései téte

- kezelté rep.

• $P(x_1 \dots x_n)$ eo. faktorizálható G DAG szerint,

$$P(x_1 \dots x_n) = \prod P(x_i | Pa(x_i))$$

• \cup eo. -ra teljesül a szerendi Markov-feltétel G szerint, ha

$$\forall i = 1 \dots n : P(x_{\pi(i)} | Pa(x_{\pi(i)}) \setminus \{x_{\pi(j)} | j < i\}}) = P(x_{\pi(i)} | Pa(x_{\pi(i)}))$$

struktúra topológik. rendezése

• n eo-ra teljesül a lokális (széles) Marlow feltétel G szerint, ha bármely változó ftk. nem lezárható feltétel-szűleit.

• n eo-ra teljesül a globális Marlow feltétel G szerint, ha

$$\forall x, y, z \in \{x_i\} : (x/z/y) \Rightarrow ((x/z/y))'$$

Azaz ha z d. szerepe x -t y -tel.

Az előző 4 feltétel ekvivalens.

Gráf reprezentáció nem képes ábrázolni, hogy a valószínűségi szerint, páronkénti ftk. ből nem következik változóhalmazok függetlensége.

Kauzalitás sem biztos, hogy egyértelmű. A gráf irányítottsága függ a változók felvételek sorrendjétől

Stabilitás P eo stabil, ha $\exists G \text{ DAF}$ (perfect map), mely minden P beli függőséget (és függetlenséget) reprezentál.

Ekvivalencia G_1 és G_2 megfigyelés-ekv. ha

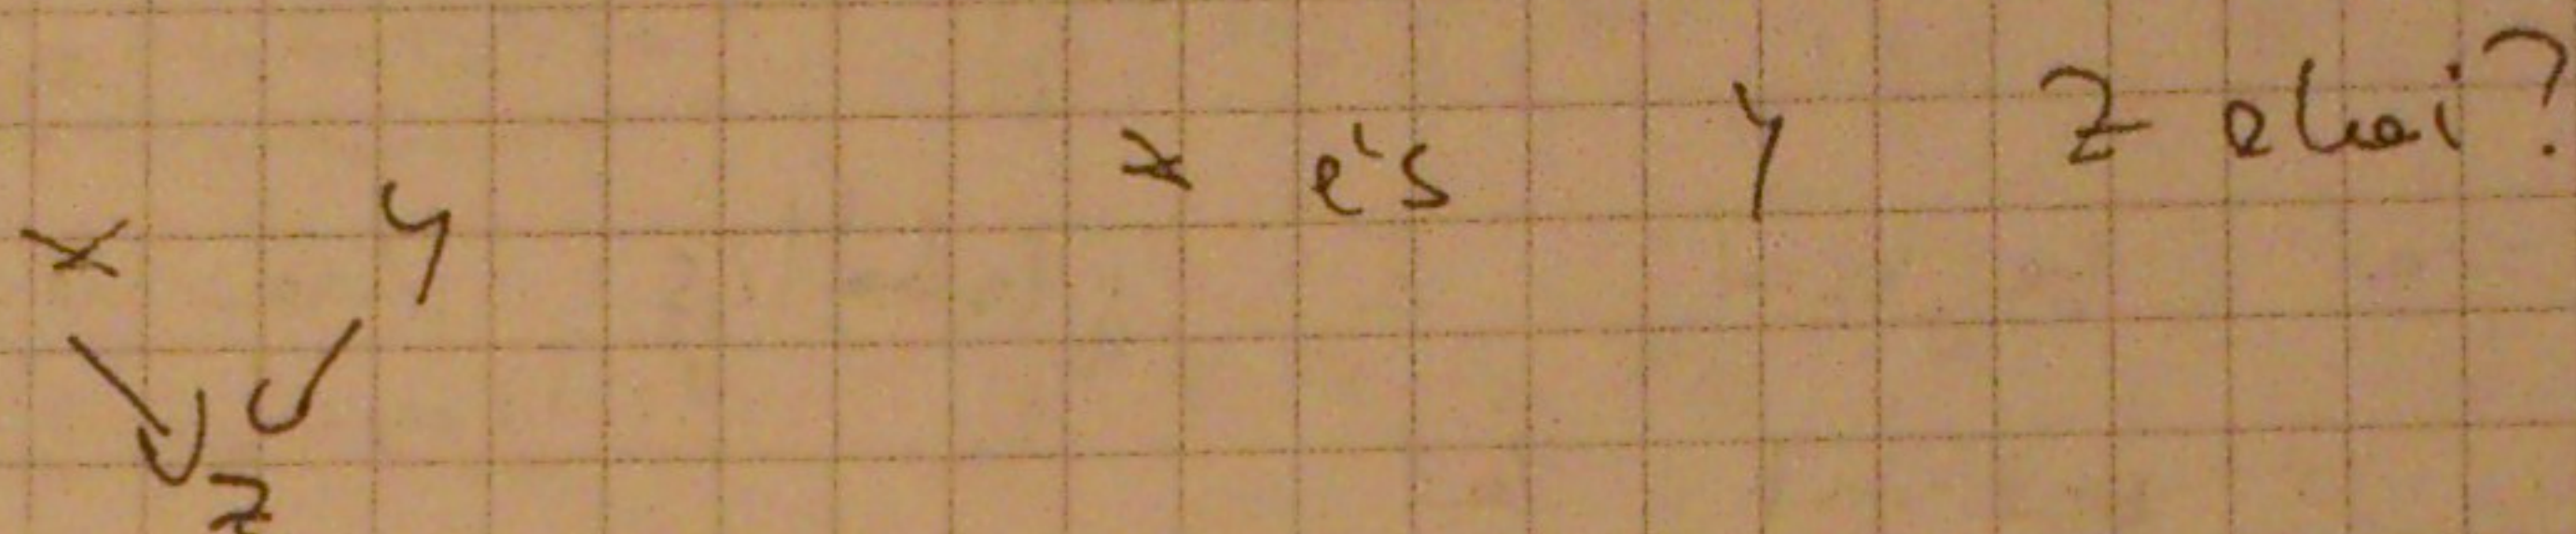
ugyanazon függés halmazt tartalmaznak

\Downarrow az

U. irányítatlan struktúra és ugyanazon V -struktúrán

Esszenciális graf

↳ maxf. elev. DAG, mely az ugyanolyan irányú élket tartalmazza.



Alapgi paradoxonok

- Tiszta magasabbrendű függés:

x, y, z bin, x, y független egyenletes eo,
 $z = \text{XOR}(x, y) \Rightarrow (x \perp\!\!\!\perp z) \& (y \perp\!\!\!\perp z)$
de
 $(\{x, y\} \not\perp\!\!\!\perp z)$

- Függés irány: Markov lánc $\mathbb{P}(x_1, \dots, x_n)$
 $p(x_i | x_{i-1})$ átmeneti valószínűségi helyett lehet látni
 $p(x_{i-1} | x_i)$ alakban is.

- Intranszitiv függés: Tfh x, y, z közül
legalább 1 bináris. \exists olyan eo. $p(x, y, z)$, hogy
 $(x \not\perp\!\!\!\perp y) \& (y \not\perp\!\!\!\perp z)$ de $(x \perp\!\!\!\perp z)$. Ez egy
 $x \rightarrow y \leftarrow z$ V-strukturúra magyarázható,
melyben $(x \not\perp\!\!\!\perp z | y)$

- Simpson paradoxona: $p(y|x) > p(y|\bar{x})$ de
 $p(y|x, z) \leq p(y|\bar{x}, z)$ és $p(y|x, \bar{z}) < p(y|\bar{x}, \bar{z})$,
azaz az asszociáció látása vétegesként
és öccesitív elb-d lehet.

7) Eloszlások felbontása

$$\text{Létszám: } P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | K_1, \dots, x_{i-1}) \\ = \prod_{i=1}^n P(x_i | \text{Parents}(x_i))$$

- Each node is conditionally independent of its nondescendants given its parents
- \sim of all others given its Markov-blanket (parents + children + children's parents)

Markov-takaró $MB_p(x_i)$ \cup $MB(x_i)$

$$(x_i \perp\!\!\!\perp U \setminus MB_p(x_i) \mid MB(x_i))_p$$

A minimális Markov-takaró \rightarrow Markov-lejtő

8. Teljes Bayes-i megközelítés BN-val

Paraméterfüggetlenség

$$\text{Globalis: } P(\theta | G) = \prod_{i=1}^n p(\theta_i | G)$$

$$\text{Lokális: } p(\theta_i | G) = \prod_{j=1}^{q_i} p(\theta_{ij} | G)$$

Likelihood elv: G_1 és G_2 megf. elv.

$$p(\theta_u | G_1) = p(\theta_u | G_2)$$

↓ ↙
Paraméterek nem redundánsak az együttes co. felett

Paraméter priorok - Dirichlet

Ha a szűrés feltevése, likelihood és normalizációs feltétel teljesítése G_c struktúrára vádjuk, hogy $p(\theta_u | E)$ Dirichlet eloszlású $N_{x_1} \dots x_n$ paraméterekkel

Paraméter modularitás

Ha $p_a(x_i)$ G_1 és G_2 -ben ugyanolyan

$$p(\theta_{ij} | G_1) = p(\theta_{ij} | G_2)$$

Ahol θ_{ij} a $p(x_i | p_a(x_i))$ feltételes valószínűség $p_a(x_i)$ konfigurációiban valamilyen fix sorrendezésében.

\mathcal{E} bel $H = p(\theta | \mathcal{E})$ asy $N_{x_1 \dots x_n}$ param
 Dirichlet előzetes és az egér lalózatra
 teljesül a param modularitás $G_{\mathcal{E}}(G_0) \geq 0$,
 akkor teljesül a lokális $\&$ függetlenségi
 ekvivalencia és a felbontott eo. a
 paramétereknek a Dirichlet - eo. szerűk.

$$p(\theta | \mathcal{E}) = \prod_{i=1}^n \prod_{j=1}^q \prod_{h=1}^{r_i} \theta^{N_{ijh} - 1} \quad (x_i = h, p_{\theta}(x_i, h) = p_{\theta ij})^{-1}$$

\downarrow
 szülői
 konf. param
 $\rightarrow x_i$ értékei

Fix G -struktúrában

$$p(\theta | \mathcal{E}) = \prod_{i=1}^n \prod_{j=1}^q \text{Dir}(\theta_{ij} | N_{ij}) \propto \prod_{i,j,h} \theta^{N_{ijh} - 1}$$

Strukturális priorok

Minden kidőz, vagy extra elő uniform
 K valóssággal modellezhető G_0 referenciával

$$P(G) \propto \prod_{k \leq j \leq n} \{ \mathbb{1}_{\{e_{ij} \in G\}} \mathbb{1}_{\{e_{ij} \notin G_0\}} \vee \mathbb{1}_{\{e_{ij} \notin G\}} \mathbb{1}_{\{e_{ij} \in G_0\}} \}$$

$$P(G) = c \prod_{i=1}^K p(F_i(G))$$

$F_i(G)$

feature
 értéke G -ben

A strukturális modularitás leírása

Ha v_i $F_i(G)$ csak $p_{\theta}(x_i)$ -től függ

$$P(G) \propto \prod_{i=1}^n p(p_{\theta}(x_i, G))$$

Teljes Bayes-i kör. átfutásos formulája

- ① Domain értékek és megfigyelések ~~adott~~ felett
- fix param & struktúra
 - Bayes-i param, fix strukt
 - Bayes-i param & strukt

$$p(y|x) = E_{p(\theta)} [E_{p(\theta|\phi)}]$$

$$p(y|x) = E_{p(\theta)} [E_{p(\theta|\phi)} [p(y|x, \theta, \phi)]]$$

- ② Domain értékek és beavatkozási info ~~adott~~ felett

- ③ Modellparaméterek felett

- ④ Modelstruktúrák felett

$$p(\theta | D_N) \propto p(\theta) \int p(D_N | \theta, \phi) p(\theta | \phi) d\theta =$$
$$= p(\theta) p(D_N | \theta)$$

- ⑤ Modell függetlenség és ABN-propozíciók felett

$$p(\alpha(\theta) \text{ ABN-KB}) = \sum_{\alpha(\theta) \text{ is true}} p(\theta)$$

10) Az egzaktt követeltetés NP teljes

A CPT táblák miatt a szülőszámban
exponenciális esz látszó mérete

Karp-redukció alapú követelés.

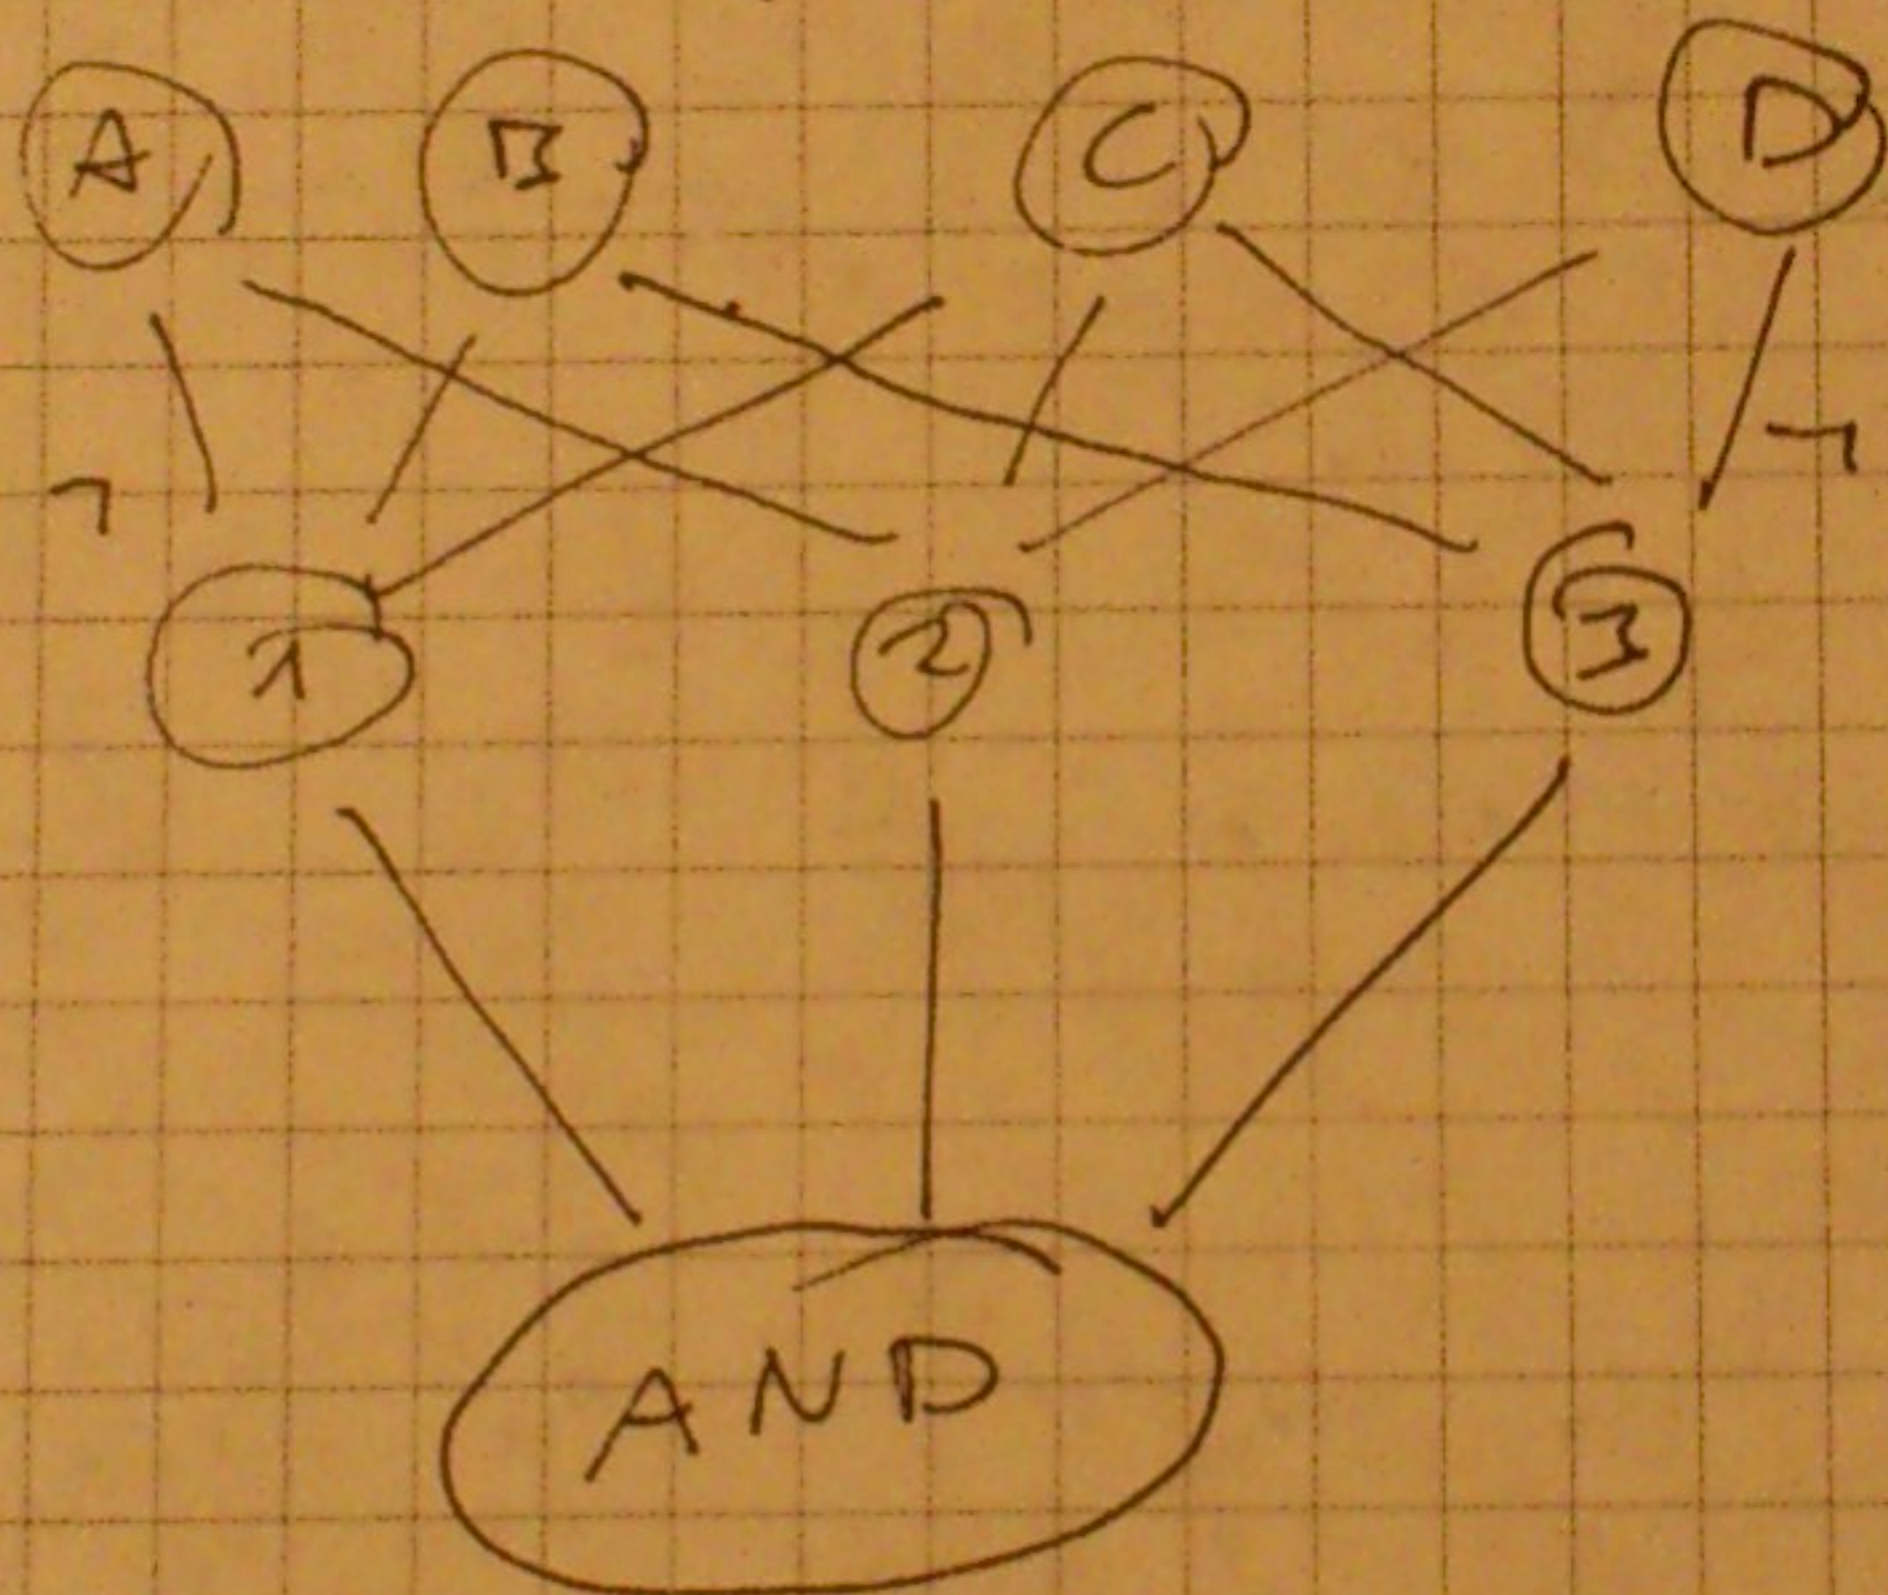
3SAT \rightarrow Bayes követeltetés

A követeltetés 3-CNF (konj. normal forma),

3SAT probléma \rightarrow 3CNF

pl: $(\bar{A} \vee B \vee C) \wedge (A \vee C \vee D) \wedge (B \vee C \vee \bar{D})$

Konstruáljunk esz követelt, A, B, C, D 50% igaz/hamis



1, 2, 3 csomópontok
CPT táblája a közzéjük
terjedő változók miatt.
igazságtáblája.
Hasonlóan az AND
csomópont is

A 3SAT visszavezethető ebben a követeltetésre

\Downarrow
követeltetés NP teljes

12) Monte-Carlo lövélvezetés algoritmus

Bayes-képletben

Az ötlet, hogy az elvárás feletti integrált/összeget
analízis helyett mintavételkel lehet közelíteni

$$\bar{f} = E_{\pi(x)} [f(x)] \leftarrow \text{ezt kell kiszámítani}$$

Direkt $\left\{ \begin{array}{l} 1 - \text{Mintavétel generálása } \{x_i\}_{i=1}^N \text{ (független,} \\ \text{mintavétel)} \end{array} \right\}$ azonos $\pi(x)$ mintavételre való

2 - Minta alapján $\hat{f}_N = \sum_{i=1}^N f(x_i)$ számítása

3 - $|\bar{f} - \hat{f}_N|$ hiba számítása, megbízhatósági
becslés a hiba mértékére

- \hat{f}_N a nagy számok törvénye alapján erősen

konzisztens: $P(\lim_{N \rightarrow \infty} \hat{f}_N = \bar{f}) = 1$

- Központi limitáris tétel alapján \hat{f}_N standardizálva
aszimptotikus Gauss-eo.

$$\frac{\hat{f}_N - \bar{f}}{\sigma_N} \rightarrow N(0,1) \text{ Ha } N \rightarrow \infty \quad \sigma_N = \frac{\text{Var}(f(x))}{\sqrt{N}}$$

- Korlátos $f(x)$ esetben (mint itt), a konvergencia
sebességéről is becslések adhatók

Hoeffding-Bernstein: $0 \leq f(x) \leq 1$

$$P(|\hat{f}_N - \bar{f}| \geq \epsilon) \leq 2 \exp(-2\epsilon^2 N) \leq \delta$$

$$E[|\hat{f}_N - \bar{f}|] \leq \sqrt{\frac{C_0}{N}}$$

// Mi a szórás
a C_0 és δ ?

Fontossági mintavételezés

Ha $\pi(x)$ nem mintavételezhető hirtelen,
de van egy megegyező tartójú $q(x)$ eo.

$$\bar{f} = E_{\pi(x)}[f(x)] = E_{q(x)}\left[\frac{f(x)\pi(x)}{q(x)}\right]$$
$$\bar{f}_w = \frac{\frac{1}{N} \sum_{t=1}^N w(x_t) f(x_t)}{\frac{1}{N} \sum_{t=1}^N w(x_t)} = \frac{1}{N} \sum_{t=1}^N w^*(x_t) f(x_t)$$

$$w(x_t) = \frac{\pi(x_t)}{q(x_t)}$$

$$w^* = \frac{w(x_t)}{\frac{1}{N} \sum_{t=1}^N w(x_t)}$$

Fibbs - mintavételezés

Az állapotváltások mindig csak 1 elemet
váltanak meg, annak többi ből való feltételes eo.
szerint, 1 elfogadási valószínűséggel

- bizonyítékekkel kompatibilis konfiguráció
sorozata
- evidencia változó rögzítése, többi változóban:
 - aktuális változó értékek új sorozatuk
markov-láncja, mint feltétel szerint
- minden így kapott konfiguráció eleme
lesz a mintabehatározó