


Umělá intelligence II



Roman Barták, KTIML

roman.bartak@mff.cuni.cz
<http://ktiml.mff.cuni.cz/~bartak>



2

Pro zopakování

- **Pravděpodobnost** je formální mechanismus pro zachycení **neurčitosti**.
- Pravděpodobnost každé atomické události zachycuje **úplná sdružená distribuce**.
- Odpověď můžeme získat vysčítáním přes atomické události (elementární jevy) odpovídající pozorování.
- Pro větší problémy ale bude potřeba efektivnější přístup.
- Hodit se nám bude **nezávislost** a **podmíněná nezávislost**.



■ A zase ten Wumpus!

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1 OK	2,1 B OK	3,1	4,1

- V bludišti se nachází díry, které se poznají podle váňku v okolní buňce (Wumpuse a zlato tentokrát neuvažujeme).
- Kam máme jít, když na (1,2) a (2,1) cítíme vánek?
- Logické odvození nepotvrdí bezpečnost žádné buňky!



Na kterou buňku máme jít?

Wumpus

pravděpodobnostní model

■ Booleovské proměnné:

- $P_{i,j}$ – na buňce (i,j) je díra
- $B_{i,j}$ – na buňce (i,j) je cítit vánek (zahrneme pouze proměnné $B_{1,1}$, $B_{1,2}$ a $B_{2,1}$.)

1,4	2,4	3,4	4,4
1,3	2,3	3,3	4,3
1,2 B OK	2,2	3,2	4,2
1,1 OK	2,1 B OK	3,1	4,1

■ Úplná sdružená distribuce

$$P(P_{1,2}, \dots, P_{4,4}, B_{1,1}, B_{1,2}, B_{2,1}) = P(B_{1,1}, B_{1,2}, B_{2,1} | P_{1,2}, \dots, P_{4,4}) * P(P_{1,2}, \dots, P_{4,4})$$

součinové pravidlo

$$P(P_{1,2}, \dots, P_{4,4}) = \prod_{i,j} P(P_{i,j})$$

díry jsou rozmístěny nezávisle

$$P(P_{1,2}, \dots, P_{4,4}) = 0.2^n * 0.8^{16-n}$$

bereme-li pravděpodobnost díry 0.2 a n děr

Známe následující **fakta**:

$$b = \neg b_{1,1} \wedge b_{1,2} \wedge b_{2,1}$$

$$\text{known} = \neg p_{1,1} \wedge \neg p_{1,2} \wedge \neg p_{2,1}$$

Zajímá nás **dotaz** $P(P_{1,3} \mid \text{known}, b)$.

Odpověď' snadno zjistíme enumerací úplné sdružené distribuce

necht' Unknown = proměnné $P_{i,j}$ kromě $P_{1,3}$ a Known

$$P(P_{1,3} \mid \text{known}, b)$$

$$= \sum_{\text{unknown}} P(P_{1,3}, \text{unknown}, \text{known}, b)$$


To ale znamená prozkoumat všechna ohodnocení proměnných Unknown a těch je $2^{12} = 4096$.

Nejde to udělat lépe (rychleji)?

	1,4	2,4	3,4	4,4
1,3				
1,2 B OK	2,2	3,2	4,2	
1,1 OK	2,1 B OK	3,1	4,1	

Pozorování:

- pozorování vánku je podmíněně nezávislé na ostatních skrytých buňkách (šedé) pokud jsou dány sousední skryté buňky (žluté)



Rozdělíme skryté buňky na sousedy a ostatní buňky

$$\text{Unknown} = \text{Fringe} \cup \text{Other}$$

Z podmíněné nezávislosti dostaneme:

$$P(b \mid P_{1,3}, \text{known}, \text{unknown}) = P(b \mid P_{1,3}, \text{known}, \text{fringe})$$

A teď tento vztah pouze vhodně použijeme.



$$P(P_{1,3} | \text{known}, b)$$

$$= \alpha \sum_{\text{unknown}} P(P_{1,3}, \text{known}, \text{unknown}, b)$$

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

$$= \alpha \sum_{\text{unknown}} P(b | P_{1,3}, \text{known}, \text{unknown}) * P(P_{1,3}, \text{known}, \text{unknown})$$

$$= \alpha \sum_{\text{fringe}} \sum_{\text{other}} P(b | P_{1,3}, \text{known}, \text{fringe}, \text{other}) * P(P_{1,3}, \text{known}, \text{fringe}, \text{other})$$

$$= \alpha \sum_{\text{fringe}} \sum_{\text{other}} P(b | P_{1,3}, \text{known}, \text{fringe}) * P(P_{1,3}, \text{known}, \text{fringe}, \text{other})$$

$$= \alpha \sum_{\text{fringe}} P(b | P_{1,3}, \text{known}, \text{fringe}) * \sum_{\text{other}} P(P_{1,3}, \text{known}, \text{fringe}, \text{other})$$

$$= \alpha \sum_{\text{fringe}} P(b | P_{1,3}, \text{known}, \text{fringe}) * \sum_{\text{other}} P(P_{1,3}) P(\text{known}) P(\text{fringe}) P(\text{other})$$

$$= \alpha P(\text{known}) P(P_{1,3}) \sum_{\text{fringe}} P(b | P_{1,3}, \text{known}, \text{fringe}) P(\text{fringe}) \sum_{\text{other}} P(\text{other})$$


$$= \alpha' P(P_{1,3}) \sum_{\text{fringe}} P(b | P_{1,3}, \text{known}, \text{fringe}) P(\text{fringe})$$

$$\alpha' = \alpha \cdot P(\text{known}) \sum_{\text{other}} P(\text{other}) = 1$$




$$P(P_{1,3} | \text{known}, b) = \alpha' P(P_{1,3}) \sum_{\text{fringe}} P(b | P_{1,3}, \text{known}, \text{fringe}) P(\text{fringe})$$


Teď prozkoumáme možné modely pro Fringe, které jsou kompatibilní s pozorováním b.




$$0.2 \times 0.2 = 0.04$$




$$0.2 \times 0.8 = 0.16$$



$$0.8 \times 0.2 = 0.16$$



$$0.2 \times 0.2 = 0.04$$



$$0.2 \times 0.8 = 0.16$$

$$P(P_{1,3} | \text{known}, b)$$

$$= \alpha' \langle 0.2 (0.04 + 0.16 + 0.16), 0.8 (0.04 + 0.16) \rangle$$

$$= \langle 0.31, 0.69 \rangle$$

$$P(P_{2,2} | \text{known}, b) = \langle 0.86, 0.14 \rangle$$

Určitě se tedy vyhneme buňce (2,2)!

Diagnostické systémy

- Podívejme se ještě jednou na diagnostiku.
- Zpravidla nám jde o odhalení zdrojů problému podle symptomů.
 - zajímá nás tedy $P(\text{disease}|\text{symptoms})$ tj. **diagnostický směr**
- Z analýzy předchozích nemocí, poruch, ... máme ale k dispozici jiné údaje
 - pravděpodobnost nemoci $P(\text{disease})$
 - pravděpodobnost symptomu $P(\text{symptom})$
 - **kauzální vztah** nemoci a symptomu $P(\text{symptoms}|\text{disease})$
- **Jak je využít?**



Umělá inteligence II, Roman Barták

Bayesovo pravidlo

- Víme, že platí $P(a \wedge b) = P(a|b) P(b) = P(b|a) P(a)$
- Můžeme odvodit tzv. **Bayesovo pravidlo** (vzorec): $P(a|b) = P(b|a) P(a) / P(b)$
v obecné podobě:
$$P(Y|X) = P(X|Y) P(Y) / P(X) = \alpha P(X|Y) P(Y)$$
- To na první pohled vypadá jako krok zpět, protože potřebujeme znát $P(X|Y)$, $P(Y)$, $P(X)$.
- Často, ale právě tato čísla máme k dispozici.
 $P(\text{cause}|\text{effect}) = P(\text{effect}|\text{cause}) P(\text{cause}) / P(\text{effect})$
 - $P(\text{effect}|\text{cause})$ popisuje **kauzální vazbu**
 - $P(\text{cause}|\text{effect})$ popisuje **diagnostickou vazbu**

Umělá inteligence II, Roman Barták

Bayesovo pravidlo

příklad použití

■ Diagnostika v medicíně

- z předchozích případů známe $P(\text{symptoms}|\text{disease})$, $P(\text{disease})$, $P(\text{symptoms})$
- u nového pacienta známe symptomy a hledáme nemoc $P(\text{disease}|\text{symptoms})$

■ Příklad:

- meningitida způsobuje ztuhlou šíji u 70% procent pacientů
- pravděpodobnost meningitidy je 1/50 000
- pravděpodobnost ztuhlé šíje je 1%

Jaká je pravděpodobnost, že pacient se ztuhlou šíjí má meningitidu?

$$P(m|s) = P(s|m).P(m) / P(s) = 0.7 * 1/50000 / 0.01 = 0.0014$$

Proč ne přímo?

- diagnostická vazba je citlivější než kauzální vazba
- pokud například vypukne epidemie meningitidy, bude hodnota přímé diagnostické vazby jiná, v našem vzorci ale stačí aktualizovat hodnotu $P(m)$

Umělá inteligence II, Roman Barták

Bayesovo pravidlo

spojování pozorování

- Co když máme k dispozici více pozorování?
- Můžeme využít podmíněnou nezávislost

$$\begin{aligned} &P(\text{Toothache}, \text{Catch}, \text{Cavity}) \\ &= P(\text{Toothache}|\text{Cavity}) P(\text{Catch}|\text{Cavity}) P(\text{Cavity}) \end{aligned}$$

Pokud jsou všechny efekty podmíněně nezávislé při dané příčině, dostaneme

$$\begin{aligned} &P(\text{Cause}, \text{Effect}_1, \dots, \text{Effect}_n) \\ &= P(\text{Cause}) \prod_i P(\text{Effect}_i|\text{Cause}) \end{aligned}$$

Jedná se o často používaný tzv. **naivní Bayesův model** (používá se, i když neplatí podmíněná nezávislost).

Umělá inteligence II, Roman Barták

Reprezentace znalostí


s nejistotou

- Víme, že **úplná sdružená distribuce** poskytuje kompletní informaci pro výpočet libovolné pravděpodobnosti metodou **marginalizace** (vysčítáním).
- Jedná se ale o metodu paměťově a časově náročnou ($O(d^n)$ pro n náhodných proměnných s d hodnotami).

Jak to udělat lépe?

Nápověda:

využijeme podmíněné nezávislosti



Umělá inteligence II, Roman Barták

Další program


- **Bayesovské sítě**
 - efektivní způsob reprezentace podmíněných pravděpodobností a nezávislostí
- **Sémantika sítě**
 - vztah k úplné složené distribuci
- **Konstrukce sítě**
- **Odvozování v Bayesovských sítích**
 - exaktní metody
 - enumerace, eliminace proměnných
 - aproximační metody
 - vzorkovací (sampling) techniky



Umělá inteligence II, Roman Barták

Bayesovská síť

- zachycuje **závislosti mezi náhodnými proměnnými**
- orientovaný acyklický graf (DAG)
 - uzel odpovídá náhodné proměnné
 - předchůdci uzlu v grafu se nazývají rodiče
 - každý uzel má přiřazenu tabulku podmíněné pravděpodobnosti distribuce $P(X \mid \text{Parents}(X))$
- jiné názvy
 - belief network, probabilistic network, causal network (spec. případ BS), knowledge map



Umělá inteligence II, Roman Barták

Bayesovská síť

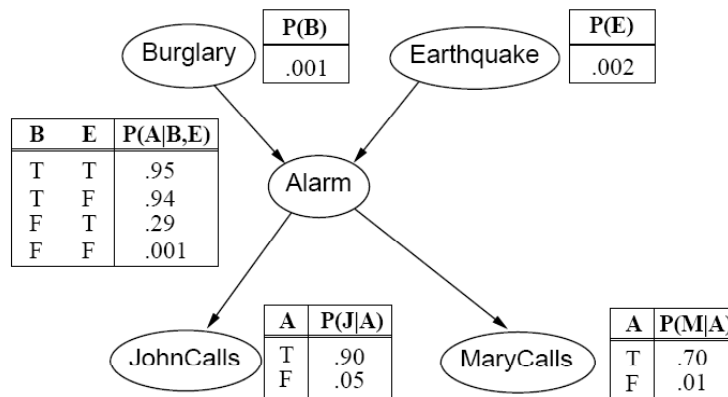
modelová situace

- Máme v domě zabudovaný **alarm**, který spustí při **vloupání** ale někdy také při **zemětřesení**.
- Sousedi Mary a John slíbili, že vždy, když alarm uslyší, tak nám **zavolají**.
 - John volá skoro vždy, když slyší alarm, ale někdy si ho spletě s telefonním zvoněním
 - Mary poslouchá hlasitou hudbu a někdy alarm přeslechne
- Zajímá nás **pravděpodobnost vloupání, pokud John i Mary volají**.
- Další předpoklady:
 - sousedi přímo nevidí vloupání ani necítí zemětřesení
 - sousedi se nedomlouvají (volají nezávisle na sobě)



Umělá inteligence II, Roman Barták

- **Náhodné Booleovské proměnné** reprezentují možné události.
 - některé události (zvonění telefonu, přelet letadla, vadu alarmu ...) ignorujeme
- **pravděpodobnostní tabulky** reprezentují vztah podmíněné pravděpodobnosti
 - stačí reprezentovat hodnoty true



Sémantika sítě

- Bayesovská síť kompaktním způsobem reprezentuje úplnou sdruženou distribuci.
$$P(x_1, \dots, x_n) = \prod_i P(x_i \mid \text{parents}(X_i))$$
- Zpětně lze ukázat, že tabulky $\mathbf{P}(X \mid \text{Parents}(X))$ jsou podmíněné pravděpodobnosti podle nahore definované úplné sdružené distribuce.
- Protože úplnou sdruženou distribuci lze použít pro odpověď na libovolnou otázku v dané doméně, lze stejnou odpověď získat z Bayesovské sítě (marginalizací).

Jak konstruovat Bayesovské sítě?

Nápovědu nám dává vztah

$$P(x_1, \dots, x_n) = \prod_i P(x_i \mid \text{parents}(X_i))$$

a rozepsání $P(x_1, \dots, x_n)$ řetězcovým pravidlem

$$P(x_1, \dots, x_n) = \prod_i P(x_i \mid x_{i-1}, \dots, x_1).$$

Dohromady dostaneme

$$\mathbf{P}(X_i \mid \text{Parents}(X_i)) = \mathbf{P}(X_i \mid X_{i-1}, \dots, X_1)$$

za předpokladu $\text{Parents}(X_i) \subseteq \{X_{i-1}, \dots, X_1\}$, což platí pokud je očíslování uzlů konzistentní s uspořádáním uzlů v síti.

- **Uzly:**
rozhodněte, jaké náhodné proměnné jsou potřeba a uspořádejte je
 - funguje libovolné uspořádání, ale pro různá uspořádání dostaneme různě kompaktní sítě
 - doporučené uspořádání je takové, kdy příčiny předcházejí efekty
- **Hrany:**
bereme proměnné X_i v daném pořadí od 1 po n
 - v množině $\{X_1, \dots, X_{i-1}\}$ vybereme nejmenší množinu rodičů X_i tak, že platí $\mathbf{P}(X_i \mid \text{Parents}(X_i)) = \mathbf{P}(X_i \mid X_{i-1}, \dots, X_1)$
 - z rodičů vedeme hranu do X_i
 - vypočteme podmíněné pravděpodobnostní tabulky $\mathbf{P}(X_i \mid \text{Parents}(X_i))$

Vlastnosti:

- síť je z principu konstrukce acyklická
- síť neobsahuje redundantní informaci a tudíž je vždy konzistentní (splňuje axiomy pravděpodobnosti)

Konstrukce sítě

poznámky


- Bayesovská síť může být mnohem **kompaktnější** než úplná sdružená distribuce, pokud je síť řídká (je lokálně strukturovaná).
 - náhodná proměnná často přímo závisí jen na omezeném počtu jiných proměnných
 - necht' je takových proměnných k a všech proměnných je n , potom potřebujeme prostor
 - $n \cdot 2^k$ pro Bayesovskou síť
 - 2^n pro úplnou sdruženou distribuci
 - můžeme **ignorovat „slabé“ vazby**, čímž budeme mít menší přesnost reprezentace, ale reprezentace bude kompaktnější
 - např. to, zda Mary nebo John zavolají není přímo ovlivněno zemětřesením, ale pouze alarmem
 - samozřejmě kompaktnost sítě hodně závisí na **vhodném uspořádání proměnných**

Umělá inteligence II, Roman Barták

Konstrukce sítě

příklad

- Necht' jsme zvolili pořadí MaryCalls, JohnCalls, Alarm, Burglary, Earthquake
 - MaryCalls nemá rodiče
 - pokud volá Mary, je zřejmě aktivní alarm, což ovlivňuje Johnovo zavolání
 - Alarm asi zní, pokud volá Mary nebo John
 - pokud známe stav Alarmu, tak vloupání nezávisí na tom, zda volá Mary ani John



$$P(\text{Burglary} \mid \text{Alarm}, \text{JohnCalls}, \text{MaryCalls}) = P(\text{Burglary} \mid \text{Alarm})$$



- Alarm je svým způsobem detektor pro zemětřesení, ale pokud došlo k vloupání, tak pravděpodobně nebylo zemětřesení

Umělá inteligence II, Roman Barták

Konstrukce sítě

uspořádání proměnných



- Máme sice jen dvě hrany navíc oproti původnímu návrhu, ale problém je vyplnění tabulek podmíněných závislostí.
 - stejný problém jako u kauzální vs. diagnostické vazby
 - je lepší se držet kauzální vazby (příčina před následkem)
 - dává menší síť a je snazší vyplnit tabulky podmíněných závislostí
- Při „špatném“ uspořádání proměnných nemusíme nic uspořít vzhledem k úplné sdružené distribuci
 - MaryCalls, JohnCalls, Earthquake, Burglary, Alarm



Umělá inteligence II, Roman Barták

Podmíněná nezávislost

- Zatím jsme se dívali na sémantiku Bayesovských sítí **globálně** (ve vztahu k úplné sdružené distribuci).
 - hodí se pro konstrukci sítí
- Můžeme se na síť podívat **lokálně** a uvědomit si, že proměnná je podmíněně nezávislá na uzlech, které nejsou její potomci, pokud známe rodiče
- proměnná je podmíněně nezávislá na ostatních uzlech sítě, pokud známe rodiče, děti a rodiče dětí (tzv. **Markovský obal** proměnné)



Umělá inteligence II, Roman Barták