



Umělá inteligence II



Roman Barták, KTIML

roman.bartak@mff.cuni.cz

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



Na úvod

- Zabýváme se konstrukcí racionálních agentů.
- **Agent** je entita, co vnímá okolní **prostředí** prostřednictvím **senzorů** a ovlivňuje ho prostřednictvím **akčních členů**.
- **Racionální agent** je agent maximalizující očekávanou míru svého zisku.
 - V UI I jsme se zabývali především logickým přístupem k řešení problému (tvrzení buď platí, neplatí nebo nevíme).
 - Ignorovali jsme
 - rozhraní do prostředí (senzory, akční prvky)
 - neurčitost informací
 - schopnost se samostatně zlepšovat (učení)



Obsah přednášky

■ Úvod

- motivace, novinky, trochu filozofie

■ Práce s nejistou informací

- neurčitost, pravděpodobností uvažování, teorie užitku

■ Strojové učení

- rozhodovací stromy, neuronové sítě, zpětnovazební učení

■ Vnímání a chování


- zpracování jazyka a obrazu, robotika



Umělá inteligence II, Roman Barták

Zdroje


Artificial Intelligence: A Modern Approach



- S. Russell and P. Norvig
- Prentice Hall, 2003 (třetí v.)
- <http://aima.cs.berkeley.edu/>

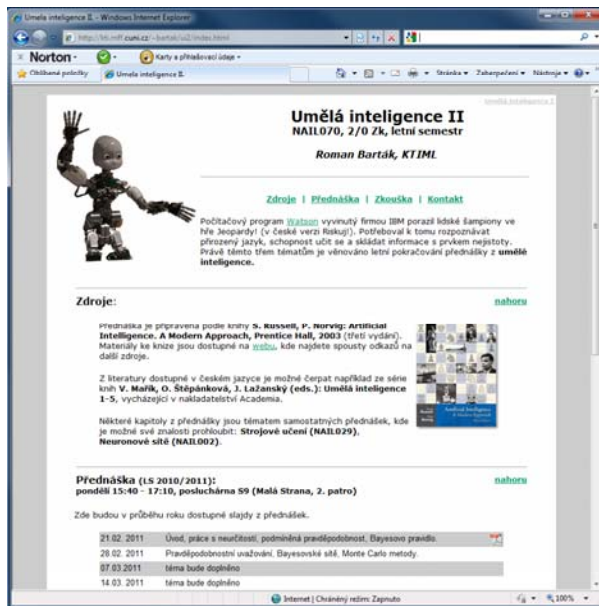
Umělá inteligence 1-5

- Vladimír Mařík, Olga Štěpánková, Jiří Lažanský a kol.
- Academia



Umělá inteligence II, Roman Barták

<http://ktiml.mff.cuni.cz/~bartak/ui2>



Zde najdete:

- slajdy k přednášce
- odkazy na zdroje
- informace o zkoušce
- ...


Umělá inteligence II, Roman Barták

Návaznosti

- **Seminář z umělé inteligence II**
 - referativní seminář, kde téma určují účastníci
- **Strojové učení**
 - jak se počítače (sami či s pomocí) učí
- **Neuronové sítě**
 - jak popsat a využít přirozený zdroj inteligence
- **Statistické metody zpracování přirozených jazyků**
 - jak „porozumět“ přirozenému jazyku
- **Umělé bytosti**
 - jak to vše spojit dohromady
- ...

Umělá inteligence II, Roman Barták


- Počítačový systém **Watson** právě porazil lidské šampiony ve hře Jeopardy!
- **O co jde?**
 - odpovídání na otázky položené v přirozeném jazyce s otevřeným obsahem (není omezené téma otázky)
 - systém analyzuje nápovědu v přirozeném jazyce
 - na základě sémantického porovnání s uloženými informacemi vyhledá odpověď
 - pokud má dostatečnou míru jistoty, tak odpoví
- **Použité technologie**
 - zpracování přirozeného jazyka
 - vybavování informací
 - reprezentace znalostí a uvažování o nich
 - strojové učení



Umělá inteligence II, Roman Barták

Watson inside

- **Rozumí** Watson kladeným otázkám?
 - ne
- Dělá Watson to samé, co **webové vyhledávače** typu Google?
 - ne (Watson vrací jedinou odpověď a musí si s ní být dostatečně jistý)
- Jak tedy Watson **funguje**?
 - rozloží otázku
 - vygeneruje kandidáty/hypotézy na odpověď
 - hledá podporu pro své hypotézy (masivní paralelismus)
- Odkud Watson čerpal **informace**?
 - přímo z textových dokumentů (včetně celé Wikipedie)



Umělá inteligence II, Roman Barták

Diagnostika zubního kazu

Pokusme se ji udělat čistě logicky.

- když pacienta bolí zuby, má kaz
Toothache \Rightarrow Cavity

Platí to ale vždy?

- ne každá bolest zubu je způsobena kazem, je tedy potřeba vypsát všechny důvody
Toothache \Rightarrow Cavity \vee GumProblem \vee Abscess \vee ...

A co to zkusit obráceně?

Cavity \Rightarrow Toothache

- to ale také není pravda – ne každý kaz způsobuje bolest

Abychom pravidlo měli správně, musí pokrývat úplný výčet problémů i symptomů.



Použití logiky

Proč použití logiky selhává v oblastech jako je medicínská (a jiná) diagnostika?

- **lenost:** je moc pracné sepsat přesně všechna pravidla a taková pravidla se špatně používají
- **teoretická ignorance:** medicína nemá přesnou teorii pro danou oblast
- **praktická ignorance:** i kdybychom měli úplnou teorii, nemůžeme si být u daného pacienta jisti, dokud neprovedeme všechny diagnostické testy.

Budeme potřebovat jiný nástroj, který umí pracovat se silou domněnek – **teorii pravděpodobnosti.**

Logický agent o každém tvrzení rozhoduje zda platí, neplatí nebo na něj nemá názor, teorie pravděpodobnosti nám umožní kvantifikovat víru v dané tvrzení.



- Podobně jako v logice máme možné světy, tak v teorii pravděpodobnosti máme množinu možných světů (říká se jim **elementární jevy**) – **sample space**.
 - elementární jevy jsou **vzájemně vylučné** (nemohou nastat zároveň)
 - prostor světů Ω je **úplný** (obsahuje všechny možné jevy)
- Každý elementární jev ω má přiřazenu pravděpodobnost $P(\omega)$ tak, že platí:
 - $0 \leq P(\omega) \leq 1$
 - $\sum_{\omega \in \Omega} P(\omega) = 1$

Příklad:

- elementární jevy jsou dvojice hodnot, které mohou padnout na dvou kostkách (je jich celkem 36)
- $P(\omega) = 1/36$



Umělá inteligence II, Roman Barták

Jevy

- Dotazy a tvrzení jsou zpravidla o množinách elementárních jevů – tzv. **jevech**.
např. „padla dvě stejná čísla“ je jev
- Pravděpodobnost jevu zjistíme součtem pravděpodobností elementárních jevů, ze kterých se skládá.
 - $P(\phi) = \sum_{\omega \in \phi} P(\omega)$např.
$$P(\text{doubles}) = 1/36 + 1/36 + 1/36 + 1/36 + 1/36 + 1/36 = 1/6.$$

Těmto pravděpodobnostem se říká **apriorní (nepodmíněné) pravděpodobnosti**.

Podmíněná pravděpodobnost

- Většinou máme o světě nějakou informaci (**evidence**) a zajímá nás pravděpodobnost nějakého jevu.
 - Jaká je pravděpodobnost páru, pokud víme, že na kostce 1 padla 5?
 $P(\text{doubles} \mid \text{Die}_1 = 5) = 1/36 / (6 \cdot 1/36) = 1/6$

■ Podmíněná pravděpodobnost

$P(a \mid b) = P(a \wedge b) / P(b)$, pokud $P(b) \neq 0$

často se zapisuje v podobě **součinného pravidla**

$$P(a \wedge b) = P(a \mid b) \cdot P(b)$$

Pozor! Pokud máme více vstupních informací, zajímá nás jiná podmíněná pravděpodobnost.
 $P(\text{doubles} \mid \text{Die}_1 = 5, \text{Die}_2 = 5) = 1$

Umělá inteligence II, Roman Barták

Náhodná proměnná

- Jak kompaktně popsat možné světy (elementární jevy)?
- Použijeme **náhodné proměnné** popisující vlastnosti světa. Každá proměnná může nabývat hodnot ze své domény (podobně jako u CSP, uvažujeme diskrétní domény).
 - Die_1 – hodnota, která padla na kostce 1 (1,...,6)
 - Cavity – pacient má či nemá kaz (true, false)
- Elementární jev je potom charakterizován hodnotami všech náhodných proměnných.
 $P(\text{Die}_1 = 5, \text{Die}_2 = 5)$

Umělá inteligence II, Roman Barták

Sdružená distribuce

- Pravděpodobnosti elementárních jevů můžeme popsat tabulkou, tzv. **úplnou sdruženou distribucí**, kde jednotlivé prvky jsou indexovány hodnotami náhodných proměnných.

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

- Z tabulky snadno vypočteme pravděpodobnosti jednotlivých hodnot náhodných proměnných
 - $P(\text{toothache}=\text{true}) = 0.108 + 0.012 + 0.016 + 0.064 = 0.2$
 - $P(\text{toothache}=\text{false}) = 0.072 + 0.008 + 0.144 + 0.576 = 0.8$Zkráceně budeme zapisovat takto:
 - $\mathbf{P}(\text{toothache}) = \langle 0.2, 0.8 \rangle$

Umělá inteligence II, Roman Barták

Vlastnosti

- $P(\neg a) = 1 - P(a)$
- **princip inkluze a exkluze**
 $P(a \vee b) = P(a) + P(b) - P(a \wedge b)$
- **řetězcové pravidlo**
 $\mathbf{P}(A, B, C, D)$
 $= \mathbf{P}(A|B, C, D) \mathbf{P}(B, C, D)$
 $= \mathbf{P}(A|B, C, D) \mathbf{P}(B|C, D) \mathbf{P}(C, D)$
 $= \mathbf{P}(A|B, C, D) \mathbf{P}(B|C, D) \mathbf{P}(C|D) \mathbf{P}(D)$

Umělá inteligence II, Roman Barták

Odvozování

ze sdružené distribuce

- Jak odpovídat na otázky?
- Báze znalostí je reprezentována úplnou sdruženou distribucí.
- Chceme-li znát pravděpodobnost nějakého tvrzení, sečteme pravděpodobnosti všech „světů“, kde tvrzení platí (**marginalizace**).

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

$$P(\phi) = \sum_{\omega:\omega|\phi} P(\omega)$$

$$\mathbf{P}(\mathbf{Y}) = \sum_{z \in \mathbf{Z}} \mathbf{P}(\mathbf{Y}, z)$$

Umělá inteligence II, Roman Barták

Příklady odvozování

z úplné sdružené distribuce

	<i>toothache</i>		\neg <i>toothache</i>	
	<i>catch</i>	\neg <i>catch</i>	<i>catch</i>	\neg <i>catch</i>
<i>cavity</i>	.108	.012	.072	.008
\neg <i>cavity</i>	.016	.064	.144	.576

$$P(\phi) = \sum_{\omega:\omega|\phi} P(\omega)$$

$$\mathbf{P}(\mathbf{Y}) = \sum_{z \in \mathbf{Z}} \mathbf{P}(\mathbf{Y}, z)$$

$$P(\text{toothache}) (= P(\text{Toothache}=\text{true}))$$

$$= 0.108 + 0.012 + 0.016 + 0.064 = 0.2$$

$$P(\text{cavity} \vee \text{toothache})$$

$$= 0.108 + 0.012 + 0.072 + 0.008 + 0.016 + 0.064 = 0.28$$

$$P(\neg \text{cavity} | \text{toothache})$$

$$= P(\neg \text{cavity} \wedge \text{toothache}) / P(\text{toothache})$$

$$= (0.016 + 0.064) / (0.108 + 0.012 + 0.016 + 0.064)$$

$$= 0.4$$

Umělá inteligence II, Roman Barták

Normalizace

	toothache		\neg toothache	
	catch	\neg catch	catch	\neg catch
cavity	.108	.012	.072	.008
\neg cavity	.016	.064	.144	.576

$$\begin{aligned} P(\neg \text{cavity} | \text{toothache}) &= P(\neg \text{cavity} \wedge \text{toothache}) / P(\text{toothache}) \\ &= (0.016 + 0.064) / (0.108 + 0.012 + 0.016 + 0.064) = 0.4 \end{aligned}$$

$$\begin{aligned} P(\text{cavity} | \text{toothache}) &= P(\text{cavity} \wedge \text{toothache}) / P(\text{toothache}) \\ &= (0.108 + 0.012) / (0.108 + 0.012 + 0.016 + 0.064) = 0.6 \end{aligned}$$

V obou případech je jmenovatel stejný!

Nepotřebujeme ho dokonce ani znát, protože víme, že

$$P(\neg \text{cavity} | \text{toothache}) + P(\text{cavity} | \text{toothache}) = 1$$

Můžeme tedy uvažovat **normalizační konstantu** α , jejíž hodnotu dopočteme tak, aby příslušná distribuce byla v součtu 1.

$$\begin{aligned} \mathbf{P}(\text{Cavity} | \text{toothache}) &= \alpha \mathbf{P}(\text{Cavity}, \text{toothache}) \\ &= \alpha [\mathbf{P}(\text{Cavity}, \text{toothache}, \text{catch}) + \alpha \mathbf{P}(\text{Cavity}, \text{toothache}, \neg \text{catch})] \\ &= \alpha [\langle 0.108, 0.016 \rangle + \langle 0.012, 0.064 \rangle] \\ &= \alpha [\langle 0.12, 0.08 \rangle] = [\langle 0.6, 0.4 \rangle] \end{aligned}$$

Umělá inteligence II, Roman Barták

Enumerační odvozování

krátké shrnutí

- Typicky známe hodnoty e proměnných \mathbf{E} z **pozorování** a zajímá nás pravděpodobnosti distribuce pro hodnoty proměnných \mathbf{Y} z **dotazu**.

Zbylé proměnné jsou **skryté** $\mathbf{H} = \mathbf{X} - \mathbf{Y} - \mathbf{E}$.

$$\mathbf{P}(\mathbf{Y} | \mathbf{E}=e) = \alpha \mathbf{P}(\mathbf{Y}, \mathbf{E}=e) = \alpha \sum_h \mathbf{P}(\mathbf{Y}, \mathbf{E}=e, \mathbf{H}=h)$$

Zřejmé problémy:

- časová složitost v nejhorším případě $O(d^n)$, kde d je max. počet hodnot náhodné proměnné
- pro uložení úplné sdružené distribuce potřebujeme prostor $O(d^n)$
- jak zjistíme hodnoty všech prvků úplné sdružené distribuce?



Umělá inteligence II, Roman Barták

Nezávislost

- Uvažujme v naší sdružené distribuci ještě čtvrtou proměnnou Weather se čtyřmi hodnotami {cloudy, sunny, rain, snow}, tj. úplná sdružená distribuce má $2 \times 2 \times 2 \times 4 = 32$ prvků.

$$P(\text{toothache}, \text{catch}, \text{cavity}, \text{cloudy}) \\ = P(\text{cloudy} | \text{toothache}, \text{catch}, \text{cavity}) * P(\text{toothache}, \text{catch}, \text{cavity})$$

Opravdu problémy se zuby ovlivňují počasí?

$$P(\text{cloudy} | \text{toothache}, \text{catch}, \text{cavity}) = P(\text{cloudy})$$

Můžeme tedy obecně psát:

$$\mathbf{P(\text{Toothache}, \text{Catch}, \text{Cavity}, \text{Weather})} \\ = \mathbf{P(\text{Toothache}, \text{Catch}, \text{Cavity})} * \mathbf{P(\text{Weather})}$$

Úplná sdružená distribuce tak lze popsat dvěma tabulkami, jedna s 8 prvky a druhá se 4 prvky.



Této vlastnosti se říká **(úplná) nezávislost**:

$$\mathbf{P(X|Y) = P(X)} \text{ nebo } \mathbf{P(Y|X) = P(Y)} \text{ nebo } \mathbf{P(X,Y) = P(X).P(Y)}$$

Umělá inteligence II, Roman Barták

Podmíněná nezávislost

- Úplná nezávislost nám umožňuje **zmenšit reprezentaci** sdružené distribuce, bohužel je málo častá a vlastní nezávislé množiny mohou být pořád velké.
- Můžeme jít ale dál.
- Pokud máme kaz (cavity), záleží zachycení nástroje (catch) na bolesti (toothache)?
 $P(\text{catch} | \text{toothache}, \text{cavity}) = P(\text{catch} | \text{cavity})$
 $P(\text{catch} | \text{toothache}, \neg \text{cavity}) = P(\text{catch} | \neg \text{cavity})$
- Proměnná Catch je podmíněně nezávislá na proměnné Toothache při znalosti Cavity.
 $\mathbf{P(\text{Catch} | \text{Toothache}, \text{Cavity}) = P(\text{Catch} | \text{Cavity})}$

Této vlastnosti se říká **podmíněná nezávislost**:

$$\mathbf{P(X|Y,Z) = P(X|Y)} \text{ nebo } \mathbf{P(Z|X,Y) = P(Z|Y)} \text{ nebo } \\ \mathbf{P(Z,X|Y) = P(Z|Y) P(X|Y)}$$

Umělá inteligence II, Roman Barták

- Podmíněnou nezávislost můžeme dále využít pro redukci velikosti reprezentace sdružené distribuce.

$P(\text{Toothache}, \text{Catch}, \text{Cavity})$

= $P(\text{Toothache} | \text{Catch}, \text{Cavity}) P(\text{Catch}, \text{Cavity})$

= $P(\text{Toothache} | \text{Catch}, \text{Cavity}) P(\text{Catch} | \text{Cavity}) P(\text{Cavity})$

= $P(\text{Toothache} | \text{Cavity}) P(\text{Catch} | \text{Cavity}) P(\text{Cavity})$

- Pro reprezentaci teď potřebujeme tři tabulky o velikosti $2 + 2 + 1 = 5$ (stačí reprezentovat nezávislé prvky).