Reprezentace a vyvozování znalostí

Aleš Horák

E-mail: hales@fi.muni.cz

http://nlp.fi.muni.cz/uui/

Obsah:

- ➜ Reprezentace a vyvozování znalostí
- ➜ Logika – rezoluční pravidlo
- ➜ Extralogické informace – třídy, sémantické sítě, rámce
- ➜ Pravidlové systémy
- ➜ Nejistota a pravděpodobnost

Reprezentace a vyvozování znalostí

otázka:

Jak zapíšeme znalosti o problému/doméně?
Když je zapíšeme, můžeme z nich mechanicky odvodit nová fakta?

- ➜ **reprezentace znalostí** (*knowledge representation*) – hledá způsob vyjádření znalostí počítačově zpracovatelnou formou (za účelem odvozování)
- ➜ **vyvozování znalostí** (*reasoning*) – zpracovává znalosti uložené v **bázi znalostí** (*knowledge base, KB*) a provádí **odvození** (inference) nových závěrů:
  - odpovědi na dotazy
  - zjištění faktů, které vyplývají z faktů a pravidel v KB
  - odvodit akci, která vyplývá z dodaných znalostí, ...

Reprezentace znalostí

proč je potřeba speciální **reprezentace znalostí**?

vnímání lidí $\times$ vnímání počítačů

člověk

- ➜ když dostane novou věc (třeba pomeranč) – **prozkoumá** a **zapamatuje** si ho (a třeba sni)
- ➜ během tohoto procesu člověk zjistí a uloží všechny základní vlastnosti
- ➜ později, když se **zmíní** daná věc, vyhledají se a připomenou uložené informace

počítač

- ➜ musí se spolehnout na informace od lidí
- ➜ jednodušší informace – přímé *programování*
- ➜ složité informace – zadané v **symbolickém jazyce**

Volba reprezentace znalostí

která **reprezentace znalostí** je **nejlepší**?

> Pro řešení skutečně obtížných problémů musíme používat několik různých reprezentací. Každý konkrétní typ datových struktur má totiž své klady a zápory a žádný se sám o sobě nezdá adekvátní pro všechny funkce zahrnuté v tom, čemu říkáme “selský rozum” (*common sense*).
>
> – Marvin Minsky

Logika – rezoluční pravidlo

vyvozování nových znalostí = hledání **důkazu**

algoritmus konstrukce důkazu:

- ➜ dopředné a zpětné řetězení – neúplné pro PL1
- ➜ rezoluce – úplná pro důkaz sporem
- ➜ logické programování – SLD rezoluce

Historie logického vyvozování

450 př.n.l.	stoikové	výroková logika, inference (pravděpodobně)
322 př.n.l.	Aristoteles	inferenční pravidla, kvantifikátory
1565	Cardano	teorie pravděpodobnosti (výroková logika + nejistota)
1847	Boole	výroková logika (znovu)
1879	Frege	predikátová logika 1. řádu
1922	Wittgenstein	důkaz pomocí pravdivostních tabulek
1930	Gödel	$\exists$ úplný algoritmus pro PL1
1930	Herbrand	úplný algoritmus pro PL1 (redukce na výroky)
1931	Gödel	$\neg\exists$ úplný algoritmus pro aritmetiku
1960	Davis/Putnam	“praktický” algoritmus pro výrokovou logiku
1965	Robinson	“praktický” algoritmus pro PL1 – rezoluce

Předpoklad uzavřeného světa

2 užitečné předpoklady:

➜ **předpoklad uzavřeného světa** (*closed world assumption*)
- cokoliv o čem **nevíme**, že je **pravda** $\longrightarrow$ bereme za dané, že je to **nepravda**
- využitý např. v Prologu (negace jako neúspěch)

➜ **předpoklad jednoznačných pojmenování** (*unique names assumption*)
- různá jména označují různé objekty

Rezoluce v PL1

vyvozování v PL1 je pouze **částečně rozhodnutelné**:

➜ může najít důkaz α, když $KB \models \alpha$

➜ nemůže vždy dokázat, že $KB \not\models \alpha$
viz *problém zastavení* – důkazová procedura nemusí skončit

rezoluce je **důkaz sporem**:

pro důkaz $KB \models \alpha$ ukážeme, že $KB \wedge \neg\alpha$ je nesplnitelné

rezoluce používá KB, $\neg\alpha$ v **konjunktivní normální formě** (CNF). Existuje přesný algoritmus pro převod každé PL1 klauzule do CNF, např.:

$$\begin{aligned}(P \vee Q) \Rightarrow (Q \Leftrightarrow R) \quad \equiv \quad & (\neg P \vee \neg Q \vee R) \\ \wedge \quad & (\neg P \vee Q \vee \neg R) \\ \wedge \quad & (\neg Q \vee R)\end{aligned}$$

REZOLUČNÍ PRAVIDLO

algoritmus je založen na opakované aplikaci **rezolučního pravidla** – ze dvou klauzulí odvoď novou klauzuli

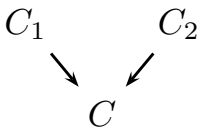

- ➜ klauzule: $C_1 = P_1 \vee P_2 \vee \ldots \vee P_n$
  a $C_2 = \neg P_1 \vee Q_1 \vee Q_2 \vee \ldots \vee Q_m$
- ➜ výsledek: $C = P_2 \vee P_3 \vee \ldots \vee P_n \vee Q_1 \vee Q_2 \vee \ldots \vee Q_m$
- ➜ vyruší se opačné literály P_1 a $\neg P_1$

postup **rezolučního důkazu tvrzení** F:

- začneme s $\neg F$
- rezolvujeme s klauzulí z KB (která obsahuje F)
- opakujeme až do odvození **prázdné klauzule** $\square$
- když se to podaří $\longrightarrow$ došli jsme ke sporu (pro $\neg F$) $\longrightarrow$ **musí platit** F

REZOLUCE – PŘÍKLAD

- ➜ **pravidla**
  - mráz $\wedge$ srážky $\Rightarrow$ sněží
    $\neg$mráz $\vee$ $\neg$srážky $\vee$ sněží
  - Leden $\Rightarrow$ mráz
    $\neg$Leden $\vee$ mráz
  - mraky $\Rightarrow$ srážky
    $\neg$mraky $\vee$ srážky
- ➜ **fakta** – Leden, mraky
- ➜ **dotaz** (co se má dokázat) – **sněží**?

Důkaz tvrzení "sněží"

S – sněží, s – srážky, m – mráz, L – Leden, M – mraky

$\neg M \vee \neg s \vee S$
$\neg L \vee M$
$\neg M \vee s$
L, M

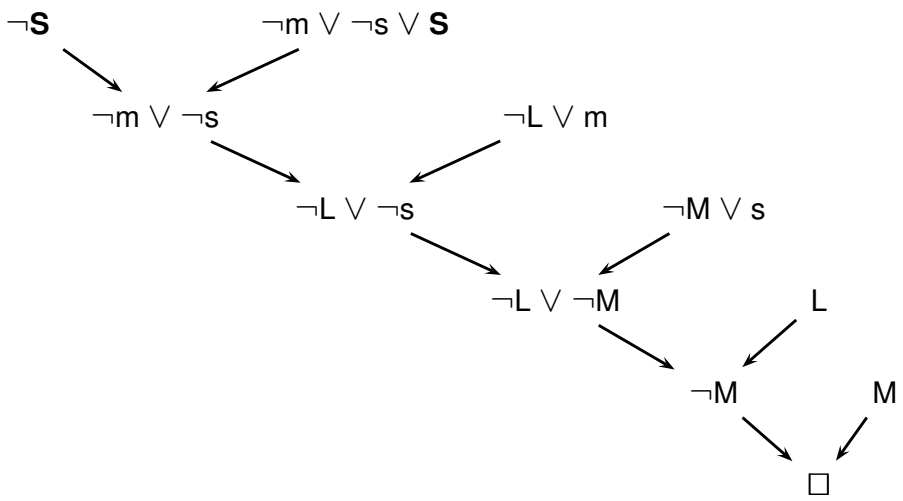

Extralogické informace

co jsme dosud ignorovali:

➜ objekty reálného světa mají mezi sebou **vztahy**
- třídy/kategorie, podtřídy × nadtřídy
- hierarchie vztahů části/celku
- dědění vlastností v hierarchiích

➜ stav světa se může **měnit** v čase
- explicitní reprezentace času
- nemonotónní uvažování (pravdivost se může měnit v čase)

➜ ne každá informace je "černobílá"
- nejistota
- statistika, fuzzy logika

TŘÍDY OBJEKTŮ

➜ "Chci si koupit fotbalový míč."
- *Chci si koupit FM27341* – špatně
- *Chci si koupit objekt, který je prvkem třídy fotbalových míčů* – správně

➜ objekty jsou organizovány do **hierarchie tříd**
- FM27341 $\in$ fotbalové_míče
- fotbalové_míče $\subset$ míče

➜ fakta (objekty) $\times$ pravidla (třídy)
- Všechny míče jsou kulaté.
- Všechny fotbalové míče mají X cm v průměru.
- FM27341 je červenomodrobílý.
- FM27341 je fotbalový míč.
- (Proto: FM27341 je kulatý a má X cm v průměru.)

SÉMANTICKÉ SÍTĚ

sémantické sítě – reprezentace faktových znalostí (pojmy + vztahy)

➜ vznikly kolem roku 1960 pro reprezentaci významu anglických slov

➜ znalosti jsou uloženy ve formě grafu

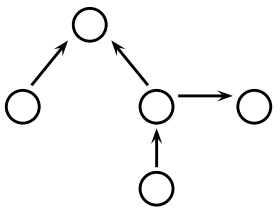

pojmy (objekty, třídy)

vztahy

➜ nejdůležitější vztahy:
- **podtřída** (*subclass*) – vztah mezi třídami
- **instance** – vztah mezi konkrétním objektem a jeho rodičovskou třídou

jiné vztahy – část (has-part), barva, ...

SÉMANTICKÉ SÍTĚ – PŘÍKLAD

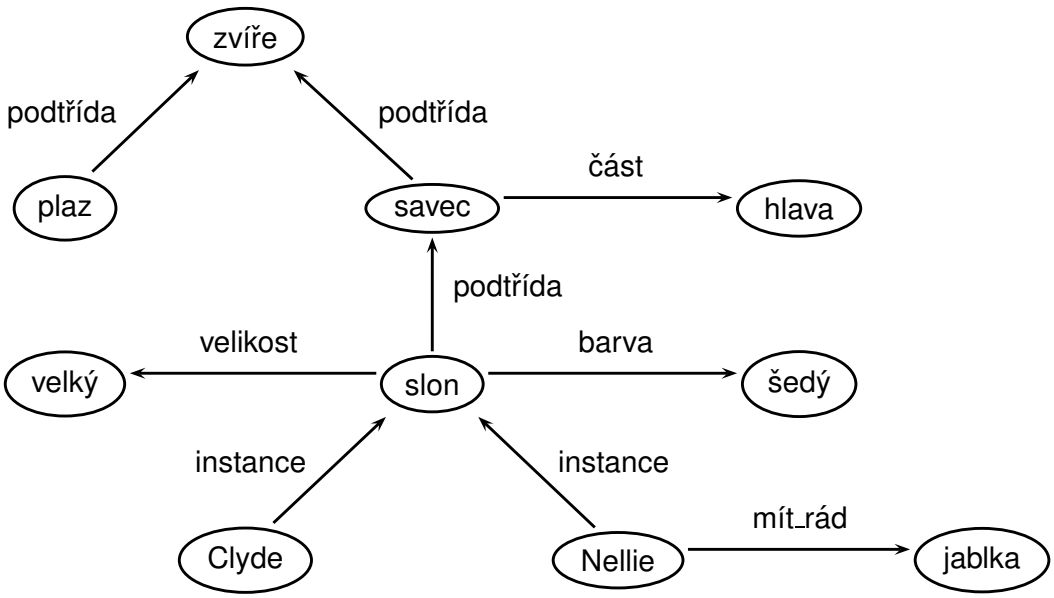

DĚDIČNOST V SÉMANTICKÝCH SÍTÍCH

- ➜ pojem sémantické sítě *předchází* OOP
- ➜ **dědičnost**:
  - jestliže určitá vlastnost platí pro třídu⟶ platí i pro všechny její podtřídy
  - jestliže určitá vlastnost platí pro třídu⟶ platí i pro všechny prvky této třídy
- ➜ určení hodnoty vlastnosti – rekurzivní algoritmus
- ➜ potřeba specifikovat i výjimky – mechanizmus **vzorů** a **výjimek** (*defaults and exceptions*)
  - vzor – hodnota vlastnosti u třídy nebo podtřídy, platí ta, co je blíž objektu
  - výjimka – u konkrétního objektu, odlišná od vzoru

Dědičnost vztahů část/celek

- ➜ "krávy mají 4 nohy."
  - – každá noha je částí krávy
- ➜ "Na poli je (konkrétní) kráva."
  - – všechny části krávy jsou taky na poli
- ➜ "Ta kráva (na poli) je hnědá (celá)."
  - – všechny části té krávy jsou hnědé
- ➜ "Ta kráva je šťastná."
  - – ~~všechny části té krávy jsou šťastné~~ – neplatí
- ➜ lekce: některé vlastnosti jsou děděny částmi, některé nejsou
  explicitně se to vyjadřuje pomocí pravidel jako
  part-of$(x, y) \wedge$ location$(y, z) \Rightarrow$ location(x, z)

Vzory a výjimky – příklad

- ➜ "všichni ptáci mají křídla."
- ➜ "všichni ptáci umí létat."
- ➜ "ptáci se zlomenými křídly jsou ptáci, ale neumí létat."
- ➜ "tučnáci jsou ptáci, ale neumí létat."
- ➜ "kouzelní tučňáci jsou tučňáci, kteří umí létat."
- ➜ kdo umí létat:
  - – "Tweety je pták."
  - – "Petřík je tučnák."
  - – "Penelope je kouzelný tučnák."
- ➜ všimněte si, že víra v hodnotu vlastnosti objektu se může měnit s příchodem nových informací
  o klasifikaci objektu

APLIKACE SÉMANTICKÝCH SÍTÍ

(Princeton) **WordNet** – `http://wordnet.princeton.edu/`

➜ sémantická síť 100.000 (anglických) pojmů, zachycuje:
- synonyma, antonyma (významově stejná/opačná)
- hyperonyma, hyponyma (podtřídy)
- odvozenost a další jazykové vztahy

➜ tvoří se **národní wordnety** (navázané na anglický WN)
český wordnet – cca 30.000 pojmů

➜ nástroj na editaci národních wordnetů – DEBVisDic/VisDic, vyvinutý na FI MU – `http://deb.fi.muni.cz/`

➜ VisualBrowser – `http://nlp.fi.muni.cz/projekty/visualbrowser/`
nástroj na vizualizaci (sémantických) sítí, vznikl jako DP na FI MU

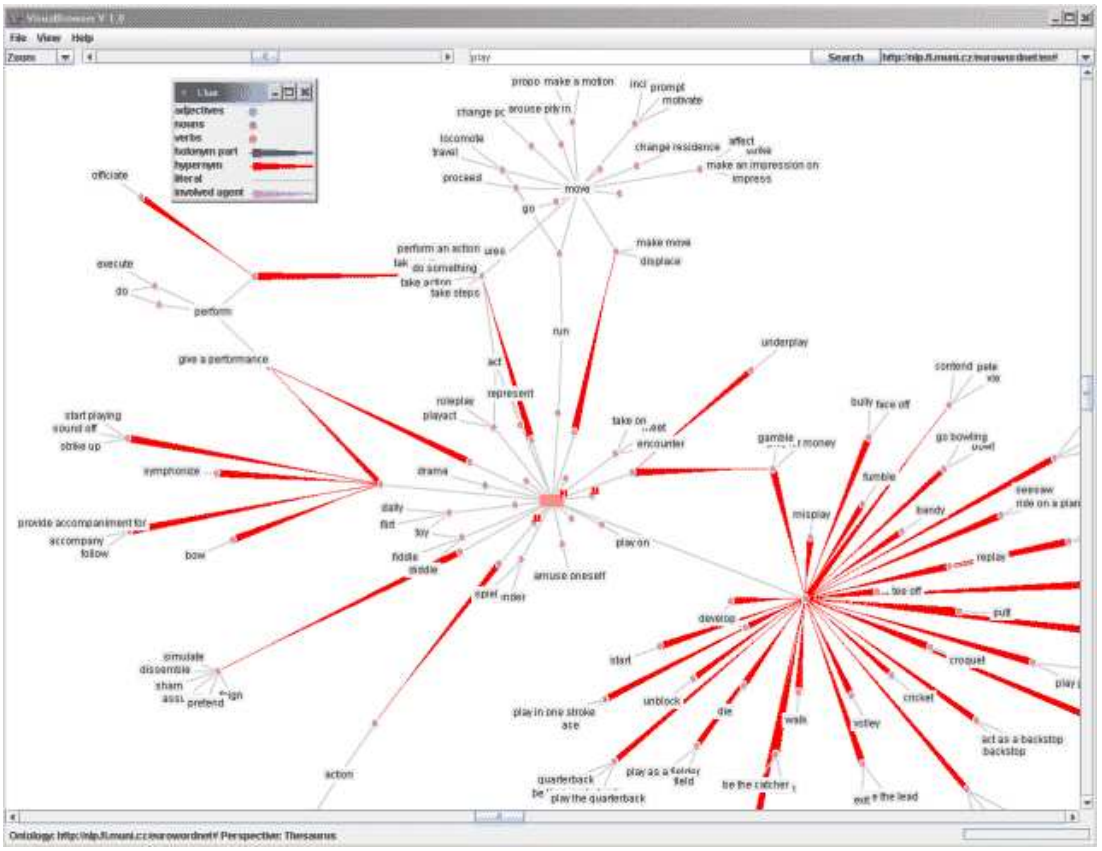

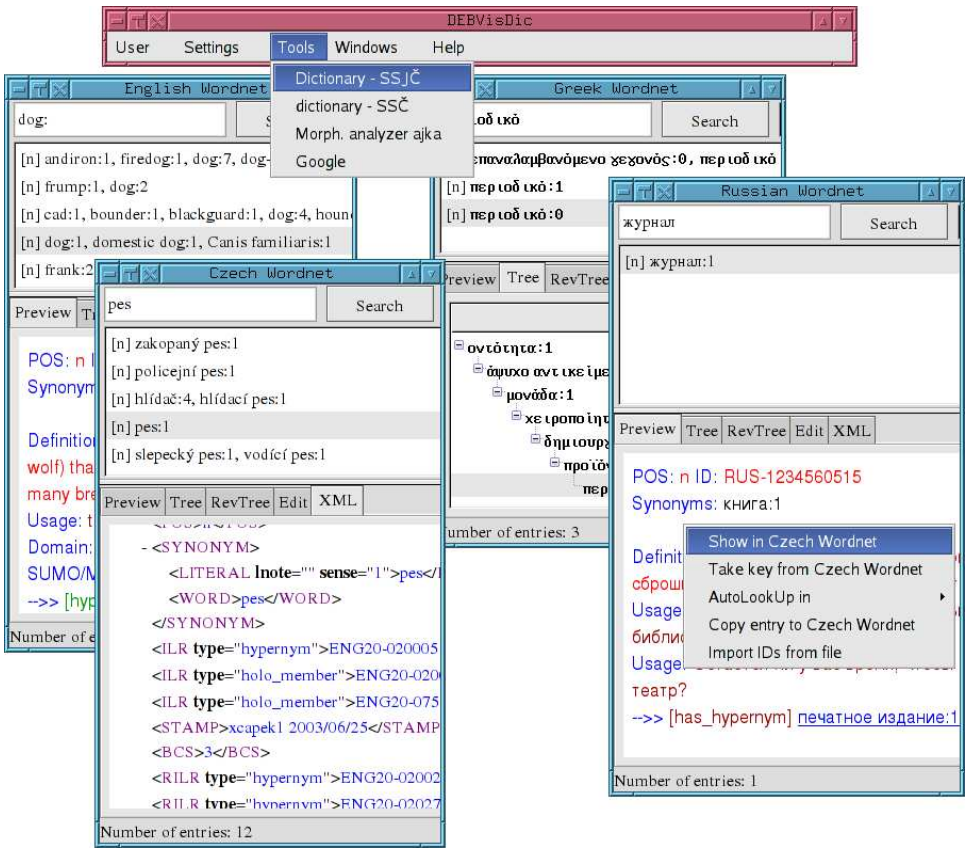

RÁMCE

Rámce (*frames*):

- ➜ varianta sémantických sítí
- ➜ velice populární pro reprezentaci znalostí v expertních systémech
- ➜ všechny informace relevantní pro daný pojem se ukládají do univerzálních struktur – **rámců**
- ➜ stejně jako sémantické sítě, rámce podporují dědičnost
- ➜ OO programovací jazyky vycházejí z teorie rámců

RÁMCE – PŘÍKLAD

rámec obsahuje **objekty**, *sloty* a hodnoty slotů

příklady rámců:

savec:

podtřída:	zvíře
část:	hlava
**má_kožich*:	ano

slon:

podtřída:	savec
**barva*:	šedá
**velikost*:	velký

Nellie:

instance:	slon
mít_rád:	jablka

'*' označuje **vzorové hodnoty**, které mohou měnit hodnoty u podtříd a instancí

SÉMANTICKÉ SÍTĚ × RÁMCE

sémantické sítě	**rámce**
uzly	objekty
spoje	sloty
uzel na druhém konci spoje	hodnota slotu

deskripční logika – logický systém, který manipuluje přímo s rámci

Pravidlové systémy

➜ snaha zachytit **produkčními pravidly** znalosti, které má expert

➜ obecná forma pravidel

IF podmínka

THEN akce

- podmínky – booleovské výrazy, dotazy na hodnoty **proměnných**
- akce – nastavení hodnot proměnných, příznaků, . . .

➜ důležité vlastnosti:

- znalosti mohou být strukturovány do modulů
- systém může být snadno rozšířen přidáním nových pravidel beze změny zbytku systému

Pravidlová báze znalostí – příklad

pravidla pro **oblékání**:

pravidlo 1 IF X je seriózní
AND X bydlí ve městě
THEN X by měl nosit sako

pravidlo 2 IF X je akademik
AND X je společensky aktivní
AND X je seriózní
THEN X by měl nosit sako a kravatu

pravidlo 3 IF X bydlí ve městě
AND X je akademik
THEN X by měl nosit kravatu

pravidlo 4 IF X je podnikatel
AND X je společensky aktivní
AND X je seriózní
THEN X by měl nosit sako, ale ne kravatu

společenská pravidla:

pravidlo 5 IF X je podnikatel
AND X je ženatý
THEN X je společensky aktivní

pravidlo 6 IF X je akademik
AND X je ženatý
THEN X je seriózní

profesní pravidla:

pravidlo 7 IF X učí na univerzitě
OR X učí na vysoké škole
THEN X je akademik

pravidlo 8 IF X vlastní firmu
OR X je OSVČ
THEN X je podnikatel

EXPERTNÍ SYSTÉMY

- ➜ aplikace pravidlových systémů
- ➜ zaměřeny na specifické oblasti – medicínská diagnóza, návrh konfigurace počítače, expertíza pro těžbu nafty, . . .
- ➜ snaha zachytit **znalosti experta** pomocí pravidel
  ale znalosti experta zahrnují – postupy, strategie, odhady, . . .
- ➜ expertní systém musí pracovat s procedurami, nejistými znalostmi, různými formami vstupu
- ➜ vhodné oblasti pro nasazení expertního systému:
  - **diagnóza** – hledání řešení podle symptomů
  - **návrh konfigurace** – složení prvků splňujících podmínky
  - **plánování** – posloupnost akcí splňujících podmínky
  - **monitorování** – porovnání chování s očekávaným chování, reakce na změny
  - **řízení** – ovládání složitého komplexu
  - **předpovědi** – projekce pravěpodobných závěrů z daných skutečností
  - **instruktáž** – inteligentní vyučování a zkoušení studentů

NEJISTOTA

definujme akci A_t jako "Vyrazit na letiště t hodin před odletem letadla."
jak najít odpověď na otázku "*Dostanu se akcí A_t na letiště včas k odletu letadla?*"

problémy:

1. částečná pozorovatelnost (stav vozovky, záměry ostatních řidičů, . . .)
2. šum v senzorech (hlášení o dopravní situaci)
3. nejistota výsledků akcí (píchnutí kola, . . .)
4. obrovská složitost modelování a předpovědi dopravní situace

čistě logický přístup tedy:

- riskuje chybu – "A_5 mě tam dostane včas."
- vede k závěrům, které jsou příliš slabé pro rozhodování: "A_5 mě tam dostane včas, pokud nebude na dálnici nehoda a pokud nebude pršet a jestli nepíchnu kolo a jestli nebude fronta na odbavovacích přepážkách a jestli nebudou problémy při kontrole zavazadel . . . "

METODY PRO PRÁCI S NEJISTOTOU

defaultní/nemonotónní logika

Předpokládejme, že nepíchnu cestou kolo.

Předpokládejme, že A_5 bude OK, pokud se nenajde protipříklad.

pravidla s faktory nejistoty

$A_5 \mapsto_{0.3}$ dostat se na letiště včas.

zalévání $\mapsto_{0.99}$ mokrý trávník

mokrý trávník $\mapsto_{0.7}$ déšť

pravděpodobnost

Vzhledem k dostupným informacím, A_3 mě tam dostane včas s pravděpodobností 0.05.

poznámka: fuzzy logika se zabývá **mírou pravdivosti**, NE nejistotou

PRAVDĚPODOBNOST

tvrzení o pravděpodobnosti **shrnují** následky

- **lenosti** – nepodařilo se vypočítat všechny výjimky, podmínky, ...
- **neznalosti** – nedostatek relevantních údajů, počátečních podmínek, ...

(takže přesně popisují běžnou práci v IT ☺)

subjektivní × **Bayesovská** pravděpodobnost:

- pravděpodobnostní vztah mezi tvrzením a jeho pravdivosti vzhledem k podmínkám:

  $P(A_4|\text{žádné hlášené nehody}) = 0.5$

  nejedná se o vyjádření **pravděpodobnostní tendence** (ale může se získat ze znalostí podobných případů v minulosti)
- pravděpodobnost tvrzení se může měnit s novými (vstupními) podmínkami:

  $P(A_4|\text{žádné hlášené nehody, je 4:00 ráno}) = 0.63$

VYVOZOVÁNÍ Z NEJISTÝCH ZNALOSTÍ

➜ použití **náhodných proměnných** (*random variables*) – funkce, která vzorkům přiřazuje hodnoty → vrací výsledky měření sledovaného jevu
distribuce pravděpodobností náhodné proměnné = (vektor) pravděpodobnost(í), že daná náhodná proměnná bude mít určitou konkrétní hodnotu
např.: náhodná proměnná Odd vyjadřující, že výsledek hodu kostkou bude lichý
náhodná proměnná $Weather$ vyjadřující, jaké bude počasí (slunce, déšť, mraky, sníh)

$$Odd(1) = true \qquad Weather(\text{21.11.2005}) = \text{déšť}$$

distribuce pravděpodobností proměnných Odd a $Weather$

$$P(Odd = true) = 1/6 + 1/6 + 1/6 = 1/2$$
$$P(Odd) =< 1/2, 1/2 >$$
$$P(Weather) =< 0.72, 0.1, 0.08, 0.1 >$$

➜ pravidla pro výpočet pravděpodobnosti logicky souvisejících událostí

$$P(a \vee b) = P(a) + P(b) - P(a \wedge b)$$

BAYESOVSKÉ PRAVIDLO PRO VYVOZOVÁNÍ

pravidlo pro **podmíněnou pravděpodobnost** – $P(a|b) = \frac{P(a \wedge b)}{P(b)}$ if $P(b) \neq 0$

z toho lze odvodit **Bayesovské pravidlo** pro určení **diagnostické** pravděpodobnosti ze znalosti **příčinné** pravděpodobnosti:

$$P(\text{Příčina}|\text{Následek}) = \frac{P(\text{Následek}|\text{Příčina})P(\text{Příčina})}{P(\text{Následek})}$$

např. ZMB zánět mozkových blan, ZK ztuhlý krk:

$$P(zmb|zk) = \frac{P(zk|zmb)P(zmb)}{P(zk)} = \frac{0.8 \times 0.0001}{0.1} = 0.0008$$

vyvozování =
1. rozdělení akce na **atomické události**
2. zjištění pravděpodobností atomických událostí
3. výpočet/odvození pravděpodobností pomocí **složených distribucí pravděpodobností** (*joint probability distribution*)