

# Reprezentace znalostí

Jiří Ivánek

e-mail: ivanek@vse.cz

# Umělá inteligence (Artificial Intelligence)

- ▶ Alan Turing (1950): Computing Machinery and Intelligence.  
Mind 59, s.433-460
- ▶ Turingův test: úkolem stroje bude v komunikaci (pomocí dálnopisu) s experimentátorem předstírat, že je člověk
- ▶ Marvin Minsky: Umělá inteligence je věda, jejímž úkolem je naučit stroje, aby dělaly věci, které vyžadují inteligenci, jsou-li prováděny člověkem
- ▶ psychologický směr - vytvoření umělých modelů lidských intelektuálních činností
- ▶ inženýrský směr - vytvoření inteligentních systémů a technik, které jsou k tomu potřebné (neomezuje se tedy pouze na simulaci lidských postupů řešení úloh)
- ▶ filosoficko-matematický směr - obecné studium a formalizace intelektuálních mechanismů nezávisle na jejich realizaci

# Milníky výzkumu umělé inteligence

- ▶ 1943 – model neuronu (McCulloch, Pitts)
- ▶ 1950 – Turingův test
- ▶ 1956 – Dartmouthská konference (Minsky, McCarthy, Simon,..)
- ▶ 1957 – perceptron (Rosenblatt), GPS – General Problem Solver (Newell, Simon, Shaw), formální gramatiky (Chomsky)
- ▶ 1958 – LISP (McCarthy)
- ▶ 1965 – DENDRAL (Feigenbaum, Buchanan), fuzzy logika (Zadeh), rezoluční princip (Robinson)
- ▶ 1968 – sémantické sítě (Quillian), SHRDLU (Winograd)
- ▶ 1970 – PROLOG (Colmerauer, Roussell)
- ▶ 1973 – MYCIN (Shortliffe, Buchanan)
- ▶ 1975 – teorie rámců (Minsky)
- ▶ 1976 – PROSPECTOR (Duda, Hart), teorie Dempster-Shafer
- ▶ 1978 – R1/XCON (McDermot)
- ▶ 1981 – japonský projekt počítačů 5.generace
- ▶ 1982 – neuronová síť (Hopfield)

# Paradigmata a etapy výzkumu umělé inteligence

- ▶ hledání univerzálního řešícího postupu (50. léta 20. století)
  - ▶ Newell, Shaw a Simon sestrojili v roce 1956 Logic Theorist, který automaticky dokázal část vět v Principia Mathematica
  - ▶ General Problem Solver (1957-59) – po řadu let nejsložitější a nejpodrobnější model lidského myšlení
  - ▶ Simonovy práce o rozhodování a řešení problémů oceněny Nobelovou cenou (1978)
- ▶ důraz na reprezentaci znalostí (60.-70. léta 20. století)
  - ▶ obecné programy nestačí pro řešení skutečně reálných úloh
  - ▶ stroj k řešení úlohy potřebuje znát to, co o problému ví člověk
  - ▶ člověka expertem nedělá jen vysoké IQ, ale hlavně specializované znalosti, „know-how“
  - ▶ expertní systémy
- ▶ získávání znalostí, strojové učení (70.-80. léta 20. století)
  - ▶ zpracování přirozeného jazyka – komunikace
  - ▶ robotika – manipulace a rozpoznávání
  - ▶ znalostní inženýrství – řešení problémů (usuzování)
- ▶ síť, kooperativní inteligence (90. léta 20. století)

# Oblasti výzkumu umělé inteligence

- ▶ dokazování teorémů
- ▶ hraní her
- ▶ zpracování přirozeného jazyka
- ▶ robotika
- ▶ rozpoznávání obrazů
- ▶ znalostní inženýrství
- ▶ strojové učení

# Expertní systémy

- ▶ Podle E. Feigenbauma je expertní systém inteligentní počítačový program, který užívá znalosti a inferenční procedury k řešení problémů, které jsou natolik obtížné, že pro své řešení vyžadují významnou lidskou expertízu.
- ▶ Expertní systém je počítačový program simulující rozhodovací činnost lidského expertsa při řešení složitých úloh a využívající vhodně zakódovaných speciálních znalostí převzatých od expertsa s cílem dosáhnout ve zvolené problémové oblasti kvality rozhodování na úrovni expertsa.
- ▶ Expertní systém je systém na řešení takových problémů, který by lidský expert v dané oblasti dokázal vyřešit po telefonu

# ES MYCIN

- ▶ Diagnóza druhů infekcí ve složitých pooperačních stavech a doporučení pro jejich medikamentózní léčbu (90procentní shoda s rozhodnutími odborných lékařů)
- ▶ Báze znalostí: 451 pravidel tvaru  
Jestliže (konjunkce podmínek), pak (závěr) s jistotou (číslo)
- ▶ Jistota je číslo z jednotkového intervalu, které udává expert jako stupeň potvrzení závěru, jsou-li pravdivé podmínky
- ▶ Ukázka pravidla systému MYCIN – Rule 85  
IF

*The site of the culture is blood*

*The gramstain of the organism is gramneg*

*The morphology of the organism is a compromised host*

THEN

*The identity of the organism is pseudomonas aeruginosa*

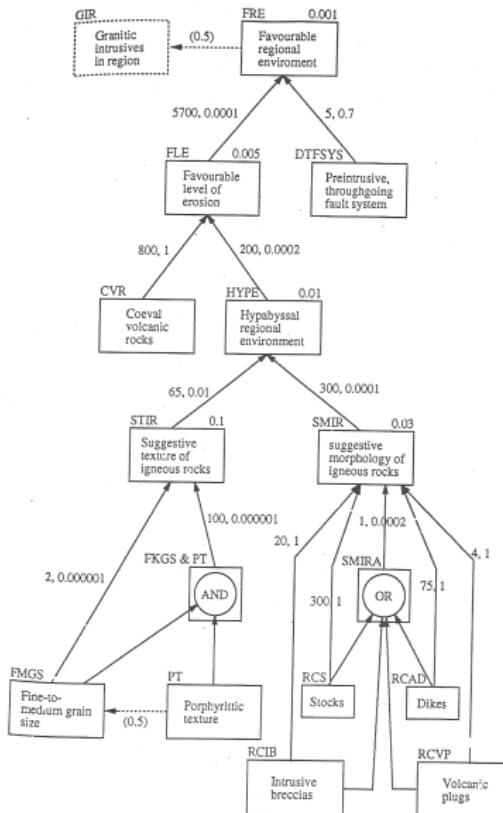
WITH CERTAINTY 0.6

- ▶ Inferenční mechanismus: zpětné řetězení a interpretace stupně jistoty jako tzv. míry důvěry
- ▶ Základ „prázdného“ systému EMYCIN

# ES PROSPECTOR

- ▶ Odhad, že se na daném místě vyskytuje rudné ložisko typu reprezentovaného zadaným modelem
- ▶ Typická báze znalostí (o geologických charakteristikách měděných ložisek) je tvořena inferenční sítí o 94 vrcholech a 105 pravidlech
- ▶ Inferenční mechanismus systému PROSPECTOR je založen na zpětném řetězení s modifikovaným Bayesovským schématem zpracování nejistoty (pseudopravděpodobnostní model)
- ▶ Průměrný rozdíl mezi odhady pořízenými systémem a expertem byl kolem deseti procent
- ▶ Systém PROSPECTOR se proslavil tím, že brzy po svém nasazení pomohl objevit cenné ložisko molybdenových rud

# BZ PROSPECTOR



Portion of a PROSPECTOR model for porphyry copper deposits ([Duda, Gaschnig, and Hart 1981], [Gaschnig 1982]).

# Charakteristické rysy expertních systémů

- ▶ oddělení znalostí a mechanismu pro jejich využívání
- ▶ neurčitost v bázi znalostí
- ▶ neurčitost v datech
- ▶ dialogový režim
- ▶ vysvětlovací činnost
- ▶ modularita a transparentnost báze znalostí

# Typy expertních systémů

## Diagnostické systémy

- slouží k výběru z předem daného seznamu variant
  - ▶ diagnóza (MYCIN, INTERNIST)
  - ▶ interpretace (DENDRAL, PROSPECTOR)
  - ▶ monitorování (VM)

## Generativní systémy

- slouží k vytváření přijatelných řešení: generuje a testuje
  - ▶ návrh (R1/XCON)
  - ▶ plánování (MOLGEN)
  - ▶ predikce (GLAUKOMA)

## Vhodnost aplikace expertního systému

- ▶ jde o úzce vymezený problém výběru jedné či více variant z předem daného souboru
- ▶ používají se termíny jako předpoklady, zákonitosti, vztahy, pravidla
- ▶ není dostupné plné numerické řešení problému
- ▶ existují kvalifikovaní experti s empirickými zkušenostmi
- ▶ expert odchází a je třeba zaškolit zástupce
- ▶ používané informace a postupy se mohou vyznačovat různým stupněm nejistoty
- ▶ snaha zajistit standardizaci způsobu rozhodování
- ▶ problém lze řešit konzultací na dálku

# Ekonomické aplikace expertních systémů

- ▶ Expertní systém FAST pro hodnocení bonity klienta
  - ▶ základní analýza finančních charakteristik pomocí jednoduchého tabulkového kalkulátoru
  - ▶ databáze kritérií vyjadřujících úvěrovou politiku konkrétní banky (preference, rizikové faktory, ...)
  - ▶ vlastní znalostní systém pro výsledné hodnocení založený na bázi cca 900 pravidel
- ▶ Expertní systém CLASS (Commercial Loan Analysis Support System)
- ▶ Expertní systém PLANET pro podporu auditorů - automatická tvorba plánu auditu
- ▶ ESTA (Expert System for Technical Analysis)
  - ▶ vyhodnocuje klouzavé průměry cen akcií za 10, 20, 40 a 75 dnů
  - ▶ využívá heuristických expertních pravidel
- ▶ Expertní systém CARMA (Computer-Assisted Real Estate Market Analysis) - vyhodnocuje zaměstnanost, vývoj populace, situaci domácností atd.

## FAIS (FinCEN Artificial Intelligence System)

- ▶ kontroluje všechny finanční transakce nad 10 tis. dolarů (v roce 1995 cca 200 tis. transakcí týdně)
- ▶ zkoumané základní entity: transakce, subjekty a účty
- ▶ zpracovávaný formulář obsahuje přibližně 120 polí
- ▶ podobné identifikační údaje se přiřazují do "klastrů".
- ▶ rozšíření databáze - odvozené atributy nezbytné pro hodnocení podezřelosti
- ▶ hledání skrytých struktur - statistické a jiné metody dolování dat (zejména nalezení a charakterizace množin podobných případů – shlukování)
- ▶ hledání relevantních subjektů a vztahů - velmi důležité je uplatnit doménově specifické znalosti, např. o rodinách, firemní subjekty apod.
- ▶ modul k hodnocení podezření v systému FAIS obsahuje hlavní expertní znalosti (cca 2000 pravidel a rámců) - aplikace Neuron Data NEXPERT Object
- ▶ nově rozvíjen systém detekce podvodů sledováním zlomů v datech popisujících finanční aktivity (Break Detection System)

# Význam expertních systémů

Role expertního systému:

- ▶ expert
- ▶ kolega
- ▶ asistent

Výhody expertního systému:

- ▶ zvýšená dostupnost expertízy
- ▶ snížené náklady na provedení expertízy
- ▶ trvalost expertízy
- ▶ opakovatelnost expertízy
- ▶ rychlá odezva

# Struktura expertního systému

- ▶ Báze znalostí experta z dané oblasti
- ▶ Data k řešenému případu
- ▶ Inferenční (odvozovací) mechanismus – umožňuje znalosti a data využívat pro konkrétní případ
  - ▶ Prohledávání báze znalostí – nalezení aplikovatelných znalostí
  - ▶ Dedukce – základem je modus ponens

$$\frac{A, A \Rightarrow B}{B}$$

- ▶ Práce s neurčitostí
- ▶ Vysvětlovací modul umožňující (do jisté míry) zdůvodnit postup systému při odvozování
  - ▶ why (proč systém klade tento dotaz)
  - ▶ how (jak systém odvodil své doporučení)
- ▶ Modul pro komunikaci s uživatelem

# Charakteristické rysy znalostí

- ▶ znalosti umožňují odvodit nové informace
- ▶ znalosti ukazují zákonitosti, vztahy, pravidla
- ▶ prakticky používané při řešení problémů
- ▶ zobecnění empirických zkušeností
- ▶ heuristická, intuitivní povaha (tacitní znalosti)
- ▶ neúplné, měnící se
- ▶ nepřesné, neurčité, nejisté, vágní
- ▶ spojené se způsobem usuzování
- ▶ úzce specializované

Znalosti v rámci logiky usuzování a inferenčního mechanismu, který ji prakticky realizuje:

Nová znalost je taková, která není daným inferenčním mechanismem odvoditelná z již dostupných znalostí

# Informace a znalosti

Rozhodovací proces – expert vybavený znalostmi zvažuje data relevantní pro daný problém a činí rozhodnutí

- ▶ Znalosti expert získal vzděláním a zkušeností
- ▶ Vybraná data představují informace

Zdroj znalostí (expert) a zdroj informací (sebraná data) se liší

- ▶ Jestliže se můžeme spolehnout při sběru na automatický proces nebo úředníka, hovoříme o datech, resp. informacích. Správnost dat může být objektivně verifikována.
- ▶ Jestliže hledáme experta, potom hovoříme o znalostech obsahujících abstrakce a generalizace.

Hiearchie znalostí:

- ▶ moudrost
- ▶ znalost
- ▶ informace
- ▶ data
- ▶ šum

# Formy reprezentace znalostí

- ▶ Predikátová logika, speciálně deskripční logika
- ▶ Rámce
  - datové struktury reprezentující stereotypní situace
  - postupné vyplňování stránek, předdefinované hodnoty
  - dědičnost v hierarchii rámců (generalizace – specifikace)
  - teorii vytvořil M. Minsky
  - na jejím základě vzniklo objektově orientované programování
- ▶ Sémantické sítě
  - grafová reprezentace objektů a relací mezi nimi formou orientovaných spojení
- ▶ Konceptuální grafy - zobecnění rámců a sémantických sítí
  - J.F.Sowa: Knowledge Representation: Logical, Philosophical, and Computational Foundations. 2000, 594 str.
- ▶ Reprezentace znalostí pravidly

# Rámce

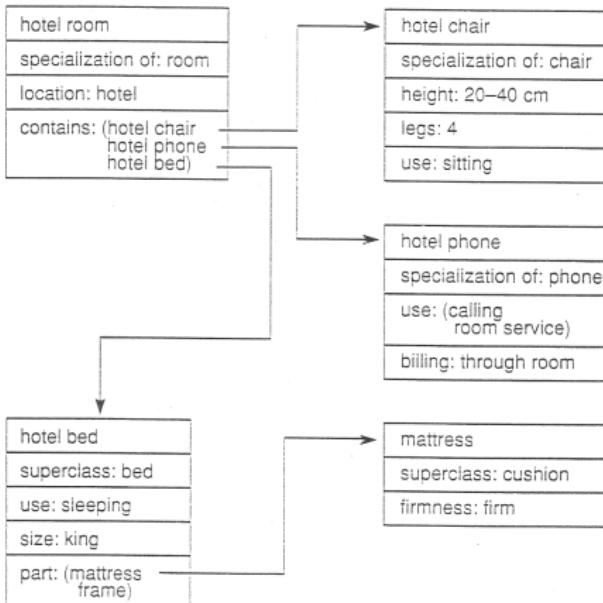
## Rámce

**Auto**  
is-a: Vozidlo  
pohon: motor  
...

**Osobní auto**  
is-a: Auto  
pohon: motor  
účel: přeprava osob  
...

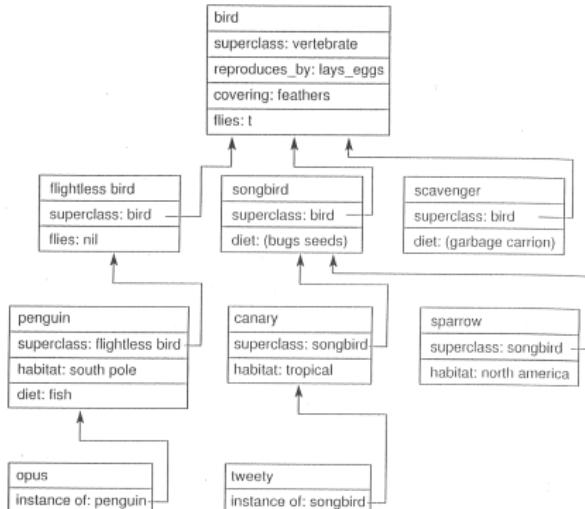
**Nákladní auto**  
is-a: Auto  
pohon: motor  
účel: přeprava nákladu  
...

**Ford**  
is-a: Osobní auto  
pohon: motor  
účel: přeprava osob  
výrobce: Ford  
...



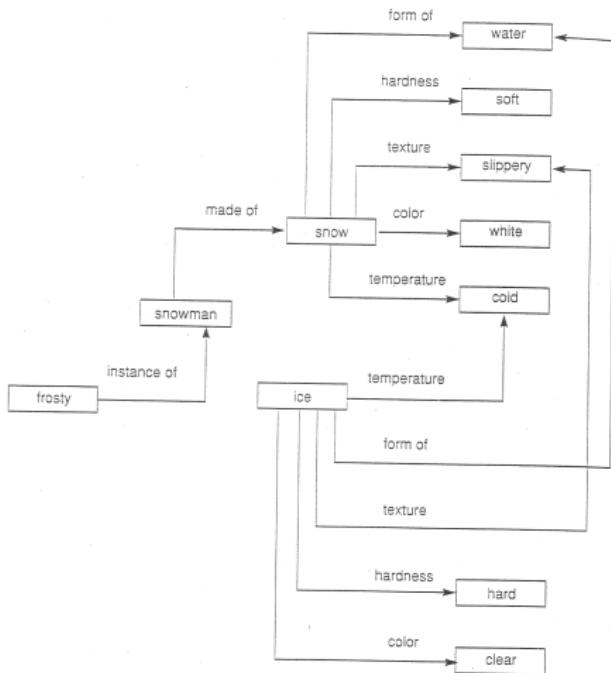
Portion of the frame description of a hotel room.

# Příklad reprezentace znalostí rámci

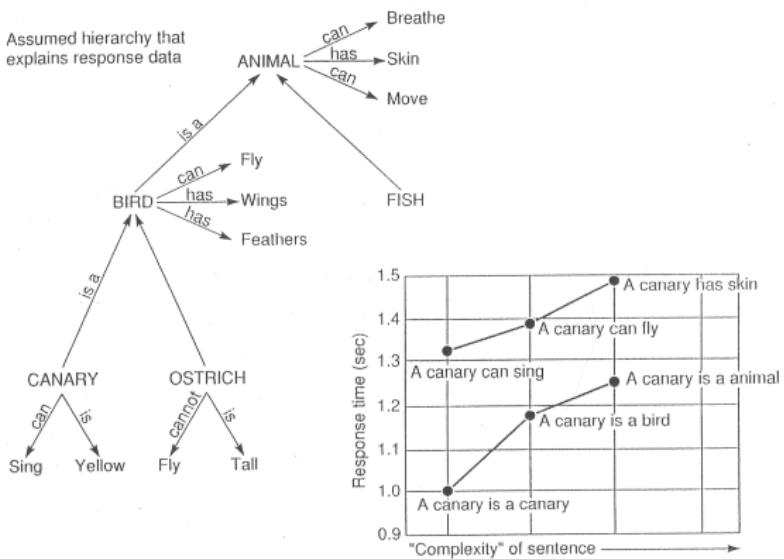


Inheritance system description of birds.

# Sítě

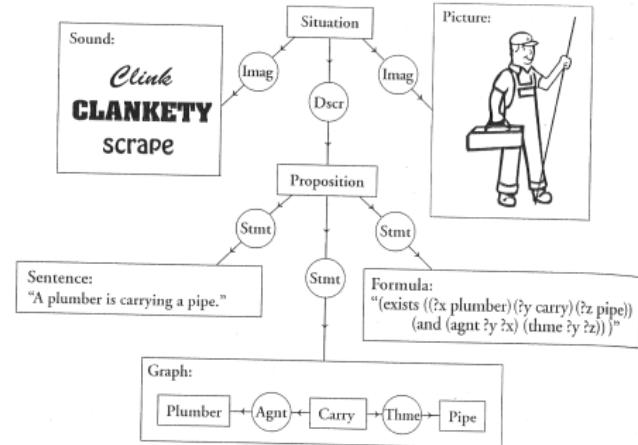


Network representation of properties of snow and ice.

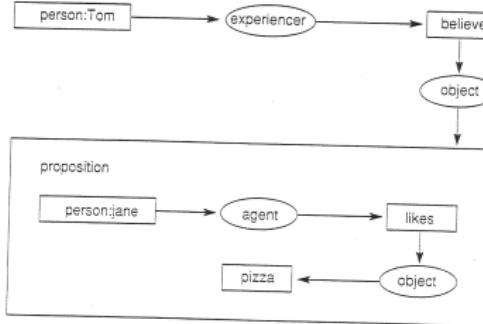


Semantic network developed by Collins and Quillian in their research on human information storage and response times

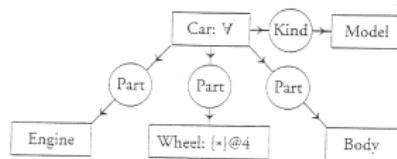
# Konceptuální grafy



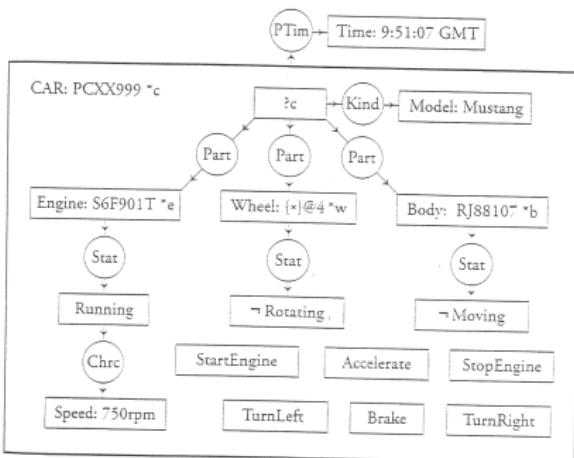
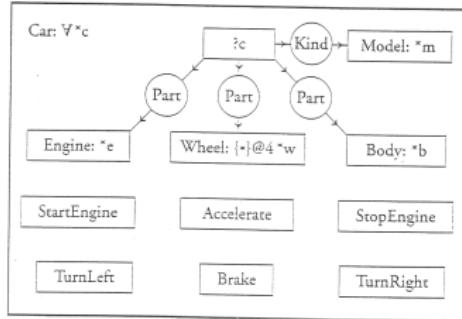
A CG representing a situation of a plumber carrying a pipe

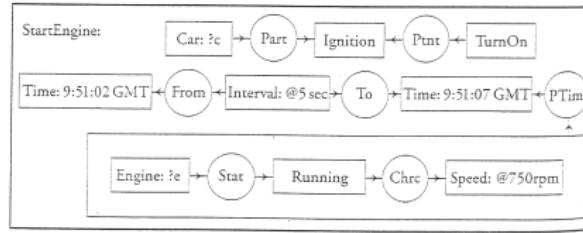
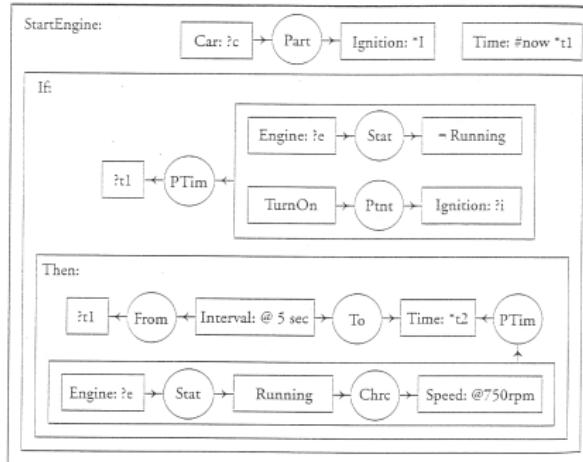


Conceptual graph of the statement "Tom thinks that Jane likes pizza," showing the use of a propositional concept.



A conceptual graph that describes cars





# Pravidla tvaru $A_1 \wedge A_2 \wedge \dots \wedge A_k \Rightarrow S$

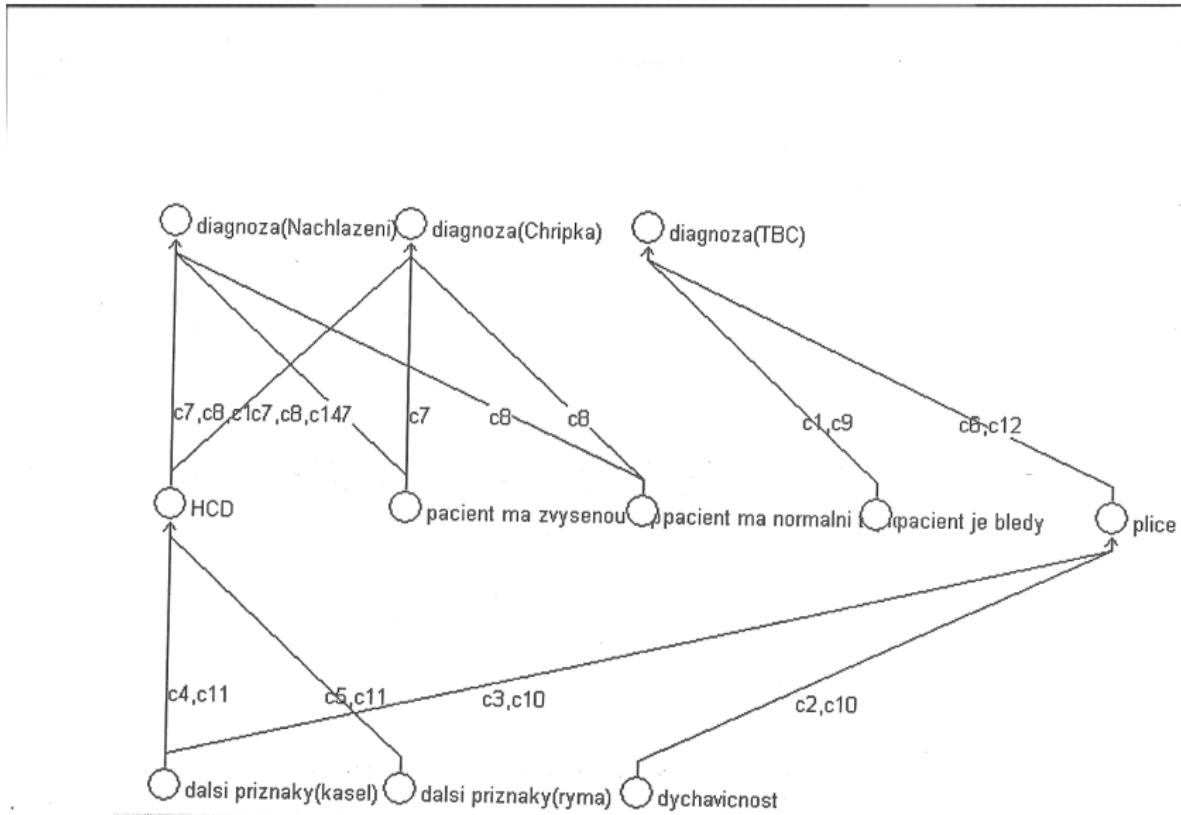
- ▶ procedurální sémantika  
JESTLIŽE situace PAK akce
- ▶ deklarativní sémantika  
JESTLIŽE předpoklad PAK závěr

Situace, předpoklad a závěr jsou kombinace tvrzení - výroků

- ▶ výrok (auto má červenou barvu)
- ▶ atribut, hodnota (barva auta = červená)
- ▶ objekt, atribut, hodnota (auto: barva = červená)

Typy atributů:

- ▶ kategoriální
  - ▶ binární
  - ▶ nominální
  - ▶ ordinální
- ▶ numerické



# Strategie prohledávání báze znalostí

## Báze znalostí – síť pravidel

- ▶ Přímé řetězení (forward chaining, bottom-up)
  - vyhledávají se pravidla, jejichž situační předpoklady jsou v datech splněny, a hned se provádějí
- ▶ Zpětné řetězení (backward chaining, top-down)
  - vyhledávají se pravidla s vytčeným závěrem, k jejich předpokladům se opět hledají pravidla, která by je mohla potvrdit atd., až se dojde k prověřitelným pravidlům
- ▶ Agendové řízení
  - používají se funkce, které oceňují výhodnost vyvolání pravidel nebo jejich skupin podle zajímavosti, ceny apod.

# Metody inference

- ▶ Dedukce — logické usuzování, při kterém závěr musí vyplývat z předpokladů
- ▶ Abdukce — usuzování z platných závěrů na předpoklady, které mohly tyto závěry způsobit
- ▶ Indukce — odvozování ze speciálních případů na obecný
- ▶ Generování a testování — metoda pokusů a omylů
- ▶ Analogie — odvození závěru na základě podobnosti s jinou situací
- ▶ Default — pokud chybějí speciální znalosti, usuzuje se na základě obecných

# Neurčitost

- ▶ Neurčitost v expertních znalostech
  - jednotlivým pravidlům bývají přiřazeny stupně neurčitosti
- ▶ obvykle se používají intervaly  $[-1; 1]$ ,  $[0; 1]$ ,  $[0; \infty]$ , nebo škály  $[-k; k]$ , např.  $(-3; -2; -1; 0; 1; 2; 3)$
- ▶ Příklad pravidla s neurčitostí:

*IF „rozumný záměr“ AND „seriozní klient“  
THEN „půjčit“ WITH WEIGHT (0.8)*

kde váha 0.8 vyjadřuje, do jaké míry je expert přesvědčen, že o závěru (výrok „půjčit“), je-li si jist, že je splněn předpoklad (tj. současně splněny výroky „rozumný záměr“ a „seriozní klient“)

- ▶ Neurčitost ve vstupních informacích
  - přirozená nejistota uživatele při odpovědi na otázku
- ▶ Příklad výroku s neurčitostí:  
*„rozumný záměr“ WITH WEIGHT (0.9)*  
kde váha 0.9 vyjadřuje poměrně velké přesvědčení uživatele o platnosti tohoto výroku (nikoli však jistotu)

# Přístupy ke zpracování neurčitosti

- ▶ Míry důvěry  
MYCIN, EMYCIN
- ▶ Pseudopravděpodobnostní přístup  
PROSPECTOR, FEL-EXPERT
- ▶ Algebraická teorie  
EQUANT
- ▶ Fuzzy logika  
SAK, NEST
- ▶ Neuronové sítě – váhy spojení mezi neurony
- ▶ Pravděpodobnostní bayesovské sítě – grafová reprezentace pravděpodobnostních závislostí

# Míry důvěry pro pravidlo $E \Rightarrow H$

"Ad hoc" teorie:

pravděpodobnost hypotézy  $P(H)$

podmíněná pravděpodobnost  $P(H|E)$  při splněné evidenci  $E$

- ▶ Míra důvěry – jak evidence  $E$  potvrzuje hypotézu  $H$

$$MB(H, E) = \frac{P(H|E) - P(H)}{1 - P(H)}$$

- ▶ Míra nedůvěry – jak evidence  $E$  vyvrací hypotézu  $H$

$$MD(H, E) = \frac{P(H) - P(H|E)}{P(H)}$$

- ▶ Faktor jistoty:  $CF(H, E) = MB(H, E) - MD(H, E)$ , případně

$$CF(H, E) = \frac{MB(H, E) - MD(H, E)}{1 - \min(MB(H, E), MD(H, E))}$$

Expert zadává faktor jistoty, že  $E$  potvrzuje/vyvrací hypotézu  $H$

## Pseudopravděpodobnostní přístup pro pravidlo $E \Rightarrow H$

Teorie – z Bayesovy věty o podmíněných pravděpodobnostech pro hypotézu  $H$  a její negaci  $\bar{H}$  plyne

$$P(H|E) = \frac{P(E|H).P(H)}{P(E)}, \quad P(\bar{H}|E) = \frac{P(E|\bar{H}).P(\bar{H})}{P(E)}$$

$$O(H|E) = \frac{P(H|E)}{P(\bar{H}|E)} = \frac{P(E|H)}{P(E|\bar{H})} \cdot \frac{P(H)}{P(\bar{H})} = L.O(H)$$

$O(H) = \frac{P(H)}{P(\bar{H})}$  je apriorní šance

$L = \frac{P(E|H)}{P(E|\bar{H})}$  je míra postačitelnosti

$O(H|E) = \frac{P(H|E)}{P(\bar{H}|E)}$  je aposteriorní šance

Expert zadává

- ▶ míru postačitelnosti  $L$ : kolikrát  $E$  zvyšuje šanci hypotézy  $H$

$$O(H|E) = L.O(H)$$

- ▶ obdobně míru nezbytnosti  $\bar{L}$ : pro nepřítomnost evidence  $E$

$$O(H|\bar{E}) = \bar{L}.O(H)$$

# Algebraická teorie neurčitosti

- ▶ zobecnění formulované P. Hájkem
- ▶ neurčitosti jsou reprezentovány při odvozování váhami na intervalu  $[-1; 1]$ , kde 1 znamená „jistě ano“,  $-1$  znamená „jistě ne“
- ▶ algebraická teorie skládání vah

Kombinační funkce určují výsledné váhy v jednotlivých krocích zpracování neurčitosti:

- ▶ Funkce  $NEG(w)$  – váha negace výroku s váhou  $w$
- ▶ Funkce  $CONJ(v, w)$  – váha konjunkce výroků s váhami  $v, w$
- ▶ Funkce  $DISJ(v, w)$  – váha disjunkce výroků s váhami  $v, w$
- ▶ Funkce  $CTR(a, w)$  – příspěvek pravidla s váhou  $w$ , je-li váha jeho předpokladu  $a$
- ▶ Funkce  $GLOB(v, w)$  – váha složení příspěvků  $v, w$  pravidel

## „Standardní inferenční mechanismus“

Vychází zejména ze systémů MYCIN a PROSPECTOR

Funkce  $NEG$ ,  $CONJ$ ,  $DISJ$ ,  $CTR$ ,  $GLOB$  pro kladné váhy:

- ▶  $NEG$  pro výpočet váhy negace výroku s váhou  $w$ :

$$NEG(w) = -w$$

- ▶  $CONJ$  pro výpočet váhy konjunkce výroků s váhami  $v, w$ :

$$CONJ(v, w) = \min(v, w)$$

- ▶  $DISJ$  pro výpočet váhy disjunkce výroků s váhami  $v, w$ :

$$DISJ(v, w) = \max(v, w)$$

- ▶  $CTR$  pro výpočet příspěvku pravidla s váhou  $w$ ,  
je-li váha jeho předpokladu  $a$ :

$$CTR(a, w) = a.w$$

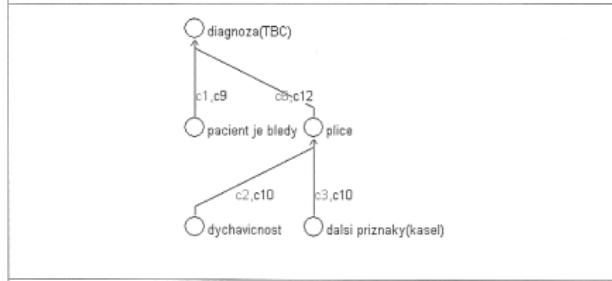
- ▶  $GLOB$  pro výpočet váhy složení příspěvků  $v, w$  dvou pravidel:

$$GLOB(v, w) = (v + w)/(1 + v.w)$$

# Konzultace

Atribut	Výrok	Odpověď
Pacient je bledý	Pacient je bledý	1
Dýchavičnost	Dýchavičnost	1
Teplota		37
Další příznaky	Kašel	3
Další příznaky	Rýma	1

Cílové výroky	váha
diagnoza(TBC)	1,779
diagnoza(Nachlazení)	1,285
diagnoza(Chripka)	-0,857



Znalosti, které mají vliv při výpočtu konečné váhy cílového výroku TBC:

- c1 IF bledost THEN diagnoza(TBC) [1]: 0,333
- c2 IF dychaviciost THEN plice[2]: 0,667
- c3 IF priznaky(kasel) THEN plice[2]: 2,000
- c6 IF plice THEN diagnoza(TBC) [2]: 1,548

# Fuzzy logika

- ▶ Zobecnění klasické dvouhodnotové logiky
- ▶ Formule mají pravdivostní hodnoty z intervalu  $[0; 1]$ , kde 0 znamená „ne“, 1 znamená „ano“
- ▶ **Pravdivostní funkce logických spojek** rozšiřují klasické dvouhodnotové pravdivostní tabulky na interval pravdivostních hodnot  $[0; 1]$
- ▶ Volbou konkrétních pravdivostních funkcí vznikají různé fuzzy logiky (Gödelova minimaxová, součinová, Hamacherova, Łukasiewiczova, ...)
- ▶ Łukasiewiczova logika je stejně jako klasická dvouhodnotová logika úplná - existuje pro ni dedukční soustava, v níž je stupeň dokazatelnosti formule roven stupni její pravdivosti
- ▶ Dedukční pravidlo modus ponens v Łukasiewiczově logice:

$$\frac{A, A \Rightarrow B}{B} \quad \left( \frac{a, w}{\max(0, a + w - 1)} \right)$$

# Fuzzy konjunkce a disjunkce

**Pravdivostní funkce fuzzy konjunkce**  $x \otimes y$  rozšiřuje klasickou dvouhodnotovou pravdivostní tabulku konjunkce na interval pravdivostních hodnot  $[0; 1]$  tak, že mj. platí

$$x \otimes y \leq \min(x, y); \text{ když } \uparrow x \text{ a } \uparrow y, \text{ pak } \uparrow(x \otimes y)$$

Příklady:

- ▶ **Minimová:**  $x \otimes_M y = \min(x, y)$
- ▶ **Součinová:**  $x \otimes_P y = x \cdot y$
- ▶ **Hamacherova:**  $x \otimes_B y = \frac{x \cdot y}{x + y - x \cdot y}$
- ▶ **Łukasiewiczova:**  $x \otimes_L y = \max(0, x + y - 1)$

**Fuzzy disjunkce** jsou definovány duálně k fuzzy konjunkcím (maximová, součinová, Hamacherova, Łukasiewiczova, ...)

# Fuzzy implikace

**Pravdivostní funkce fuzzy implikace**  $I(x, y)$  zobecňují klasickou pravdivostní tabulku implikace  $\varphi \Rightarrow \psi$  na interval pravdivostních hodnot  $[0; 1]$  tak, aby platilo:

když  $\downarrow x$  (pravdivost  $\varphi$ ) a  $\uparrow y$  (pravdivost  $\psi$ ), pak  $\uparrow I(x, y)$   
Příklady:

- ▶ **Gödelova implikace:**

$$I_M(x, y) = \begin{cases} y & \text{pro } x > y, \\ 1 & \text{jinak} \end{cases}$$

- ▶ **Goguenova implikace:**

$$I_P(x, y) = \begin{cases} y/x & \text{pro } x > y, \\ 1 & \text{jinak} \end{cases}$$

- ▶ **Lukasiewiczova implikace:**  $I_L(x, y) = \min(1, 1 - x + y)$
- ▶ **Kleene-Dienesova implikace:**  $I_K(x, y) = \max(1 - x, y)$
- ▶ **Reichenbachova implikace:**  $I_R(x, y) = 1 - x + xy$

# Zpracování neurčitosti v úplné fuzzy logice

- ▶ Neurčitost informace/znalosti je chápána jako stupeň jistoty, že jde o „axiom“
- ▶ Formule reprezentující bázi znalostí a vstupní informace se stupni jistoty z  $[0; 1]$  tak tvoří fuzzy axiomatickou teorii
- ▶ V úplné fuzzy logice je stupeň dokazatelnosti formule ve fuzzy axiomatické teorii roven stupni její pravdivosti v této teorii
- ▶ Inferenční mechanismus je pak dokazovací procedura, která určí stupně logického vyplývání všech cílových formulí z fuzzy teorie reprezentující bázi znalostí a vstupní informace
- ▶ Realizace logického inferenčního mechanismu je tedy založena na úplné Łukasiewiczově logice s tím, že každý výrok je reprezentován svou pozitivní verzí (pro kladnou váhu) a negativní verzí (pro zápornou váhu)
- ▶ Z pravdivostních funkcí logických spojek a z dedukčního pravidla modus ponens v Łukasiewiczově výrokové logice byly pak odvozeny kombinační funkce pro váhy na intervalu  $[-1; 1]$

## „Logický inferenční mechanismus“

Vychází zejména z Łukasiewiczovy fuzzy logiky

Funkce  $NEG$ ,  $CONJ$ ,  $DISJ$ ,  $CTR$ ,  $GLOB$  pro kladné váhy:

- ▶  $NEG$  pro výpočet váhy negace výroku s váhou  $w$ :

$$NEG(w) = -w$$

- ▶  $CONJ$  pro výpočet váhy konjunkce výroků s váhami  $v, w$ :

$$CONJ(v, w) = \min(v, w)$$

- ▶  $DISJ$  pro výpočet váhy disjunkce výroků s váhami  $v, w$ :

$$DISJ(v, w) = \max(v, w)$$

- ▶  $CTR$  pro výpočet příspěvku pravidla s váhou  $w$ ,  
je-li váha jeho předpokladu  $a$ :

$$CTR(a, w) = \max(0, a + w - 1)$$

- ▶  $GLOB$  pro výpočet váhy složení příspěvků  $v, w$  pravidel:

$$GLOB(v, w) = \min(1, v + w)$$

# Metody získávání znalostí

## 1. od experta

- ▶ verbální techniky
- ▶ tabulky, schémata, grafy
- ▶ systémy na podporu získávání znalostí

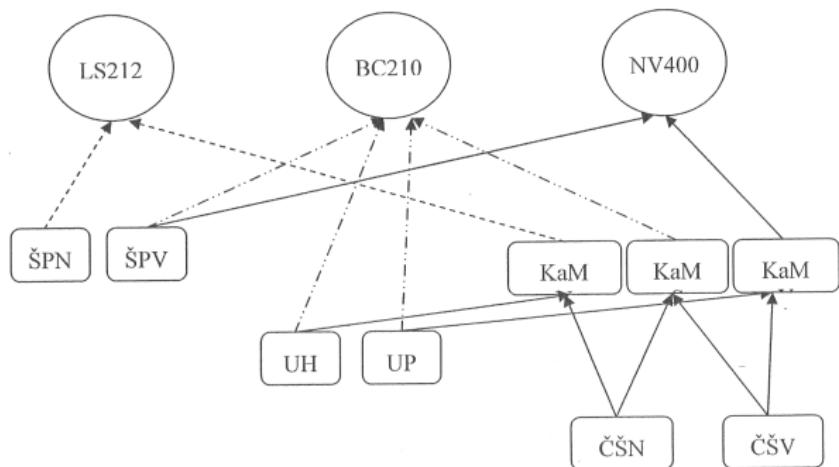
## 2. z odborných textů

- ▶ „hlavoruční“ získávání znalostí
- ▶ automatické vyhledání znalostí vyjádřených v přirozeném jazyce a jejich převedení do symbolické podoby
- ▶ využití znalostních ontologií

## 3. z databází

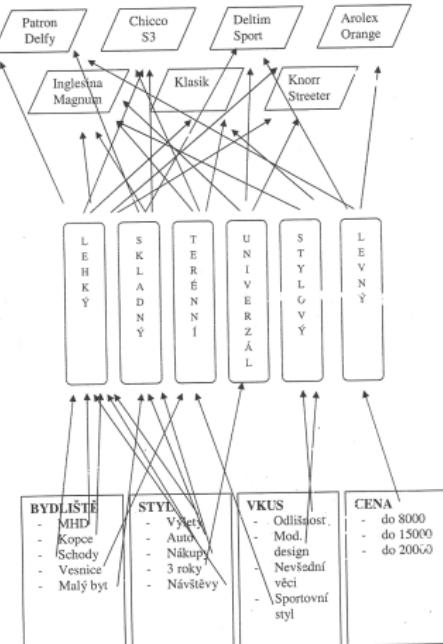
- ▶ usuzování na základě souboru reprezentativních příkladů (Case Based Reasoning)
- ▶ analýza observačních dat (Data Mining)

# Náčrt BZ



První náčrt budoucí báze znalostí a vztahů mezi některými jejími prvky.

# BZ Výběr kočárku



# Systém ETS na podporu získávání znalostí

Artificial Intelligence Center, BCS

Ambiguities / Conflicts

## Expertise Transfer System Ver. 3.2

Artificial Intelligence Center  
Boeing Computer Services

(c) 1985, The Boeing Company.  
All Rights Reserved.

### Rating Grid

1 2 3 4 5

5 2 5 2 4    1: MORE EXPENSIVE TO VISIT / LESS EXPENSIVE TO VISIT

2 5 2 5 1    2: WARMER / COLDER

5 2 4 1 4    3: GOOD MUSEUMS / SO-SO MUSEUMS

City 1: PARIS

City 2: LOS-ANGELES

City 3: LONDON

City 4: MIAMI

City 5: NEW-YORK