



ÚSTAV INFORMAČNÍCH STUDIÍ A KNIHOVNICTVÍ
FF UK V PRAZE

Jiří Ivánek

Stručně o zpracování znalostí v expertních systémech

Verze 1.0

Praha

2014

Obsah

| | | |
|----------|----------------------------------------------------|-----------|
| 1 | Úvod | 2 |
| 2 | Expertní systémy | 5 |
| 2.1 | Charakteristické rysy expertních systémů | 7 |
| 2.2 | Aplikace expertních systémů | 9 |
| 2.3 | Struktura expertního systému | 13 |
| 3 | Zpracování znalostí | 15 |
| 3.1 | Reprezentace znalostí | 17 |
| 3.2 | Pravidla | 18 |
| 3.3 | Infereční mechanismus | 20 |
| 3.4 | Neurčitost | 22 |
| 3.4.1 | Míry důvěry | 23 |
| 3.4.2 | Pseudopravděpodobnostní přístup | 23 |
| 3.4.3 | Algebraická teorie neurčitosti | 24 |
| 3.4.4 | Standardní inferenční mechanismus | 25 |
| 3.4.5 | Využití fuzzy logiky | 25 |

Kapitola 1

Úvod

Tento studijní text započneme krátkým historickým exkurzem a uvedením milníků spjatých se zrodem a vývojem zpracování znalostí. Dále definujeme expertní systémy a uvedeme jejich nejdůležitější vlastnosti a principy, které je odlišují od klasických informačních systémů. Objasníme si, které typy úloh je vhodné řešit nasazením expertního systému. Vysvětlíme si pojem inference, inferenční mechanismus a s tím spjatou práci se znalostmi, které, jak si ukážeme, můžeme reprezentovat pomocí produkčních pravidel. Nakonec si objasníme pojem neurčitosti, jenž je se znalostmi a expertními systémy fundamentálně spjatý.

Zpracování znalostí a rozvoj expertních systémů byl vyústěním jistých procesů ve **výzkumu umělé inteligence**, která se jako samostatný vědní obor začala formovat v padesátých letech dvacátého století. Za počátek lze pokládat práci A. M. Turinga z roku 1950, v níž jsou blíže vymezeny prostředky a cíle umělé inteligence (artificial intelligence, AI). Inteligenci stroje navrhuje Turing testovat imitační hrou: úkolem stroje bude v komunikaci s experimentátorem (pomocí dálkopisu) předstírat, že je člověk. Odtud vychází známá Minského definice, v níž je umělá inteligence vymezena jako věda, jejímž úkolem je naučit stroje, aby dělaly věci, které vyžadují inteligenci, jsou-li prováděny člověkem.

První výsledky výzkumu v 50. letech 20. století vedly k velkému nadšení a optimismu. Newell, Shaw a Simon sestrojili v roce 1956 Logic Theorist, program, který automaticky dokázal převážnou část vět v Principia Mathematica. Jejich General Problem Solver (1957-59) byl po řadu let nejsložitějším a nejpodrobnějším modelem lidského myšlení, který kdy byl zkonstruován a ověřován. Simonovy práce z této doby, týkající se racionality, rozhodování

a řešení problémů (adresované zejména ekonomům a psychologům), byly později (v roce 1978) oceněny Nobelovou cenou. Zdálo se, že větší a rychlejší počítače brzy umožní již vyvinutými obecnými postupy simulovat většinu mentálních aktivit člověka.

V šedesátých letech 20. století došlo ke zpomalení vývoje a ke zjištění, že obecné programy nestačí pro řešení skutečně reálných úloh. Postupně se ukázalo, že stroj k řešení úlohy potřebuje znát to, co o problému ví člověk, který jej řeší. V kostce řečeno, člověka expertem nedělá jen vysoké IQ, ale hlavně specializované znalosti, „know-how“. Zde je možno sledovat počátek linie, která vedla ke vzniku znalostního inženýrství.

Motivace a zaměření výzkumníků v umělé inteligenci jsou často velmi odlišné. První, **inženýrský směr**, se orientuje na vytvoření inteligentních systémů či metod a technik, které jsou k tomu potřebné. Neomezuje se tedy pouze na simulaci lidských technik řešení úloh. Druhý, **psychologický směr**, se orientuje na vytvoření umělých modelů lidských intelektuálních činností. Obecné studium a formalizaci intelektuálních mechanismů nezávisle na jejich realizaci lze chápat zvláště jako třetí, **filosoficko-matematický směr**.

První velkou aplikací umělé inteligence na problémy jiné než hraní her a řešení hlavolamů byl program DENDRAL (1971). Systém DENDRAL byl určen pro identifikaci struktury molekul. Byl vyvíjen déle než deset let za účasti řady odborníků a v oblasti své specializace překonal své tvůrce a další specialisty.

Během vývoje systému DENDRAL se v polovině 60. let stal zjevným význam, který pro konstrukci prakticky použitelných inteligentních systémů, má zabudování speciálních znalostí z oboru jejich aplikace. V prvním souhrnu výsledků projektu DENDRAL bylo zdůrazněno, že člověk je schopen dobře řešit pouze úlohy z oblasti, v nichž je specialistou – v ostatních oblastech mu chybí příslušné znalosti. Z tohoto hlediska je expert člověk se znalostmi specialisty v daném oboru a se speciálními metodami a heuristikami.

Postupně došlo k **posunu v paradigmatu výzkumu umělé inteligence**: za hlavní začala být považována speciální, problémově orientovaná znalost a pozornost se soustředila na hledání metod a technik, jak tuto znalost reprezentovat tak, aby mohla být efektivně využívána. Během 70. let dvacátého století byla na tomto principu vybudována řada úspěšných aplikací, tzv. expertních systémů a posléze se pro tento směr výzkumů a aplikací umělé inteligence začal používat název znalostní inženýrství. V sedmdesátých letech 20. století se tak v oboru umělé inteligence výrazně odlišily tři podoby:

- zpracování přirozeného jazyka
- robotika
- znalostní inženýrství

Toto rozdělení odpovídá třem typů lidských inteligentních aktivit: komunikace, manipulace (a rozpoznávání), řešení problémů (usuzování). Názvy podoborů a větší specializace výzkumu v umělé inteligenci odpovídají také nové situaci, do níž se výzkum umělé inteligence propracoval: stal se předmětem komerčních a státních projektů.

Kapitola 2

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 tedy počítačový program simulující rozhodovací činnost lidského experta při řešení složitých úloh a využívající vhodně zakódovaných speciálních znalostí převzatých od experta s cílem dosáhnout ve zvolené problémové oblasti kvality rozhodování na úrovni experta. Zjednodušeně řečeno, expertní systém je systém na řešení takových problémů, který by lidský expert v dané oblasti dokázal vyřešit při konzultaci na dálku.

Expertní systémy se objevily v 70. letech 20. století, kdy se vývoj umělé inteligence zaměřoval převážně na reprezentování a zpracování znalostí získaných od experta. Jsou tedy jedním z oborů umělé inteligence, kde kromě nich můžeme nalézt robotiku, porozumění přirozenému jazyku a mluvené řeči, neuronové sítě a další. Dnes již mnoho lidí považuje expertní systémy za zastaralé a překonané. Toto tvrzení vychází především z vědeckých kruhů, neboť principy expertních systémů byly již natolik důkladně prozkoumány, že nový objev v tomto směru je jen velmi málo pravděpodobný a úsilí vědy se proto obrací jiným směrem.

V praxi jsou expertní systémy využívány spíše jako aplikace pomocného charakteru. Nejsou určeny pro „nahrazení“ experta v dané oblasti, ale jako „pomocník“ experta či manažera. Expertní systémy často slouží pro nalezení rozhodnutí, ke kterému by uživatel dospěl sám za delší čas, nebo jako „návrh“ navazujících procesů, aby uživatel na něco nezapomněl. Upřednostňování expertních systémů před jinými, mnohdy i „inteligentnějšími“ systémy, může být způsobeno tím, že jsou často „průhlednější“ než většina jiných „inteli-

gentních“ systémů. To znamená, že uživatel ví, proč se systém rozhodl právě takto (buďto uživatel sám naplnil systém příslušnými znalostmi, nebo si od systému vyžádal příslušné vysvětlení) a navíc má možnost si systém upravit dle svých představ.

Expertní systémy můžeme považovat za informační systémy, které podle zadání automaticky usuzují na základě formalizovaných znalostí v konkrétní problémové oblasti a poskytují své závěry – nové informace týkající se daného problému. Obecněji můžeme definovat **znalostní systém** jako programový systém, který se od běžných programů liší způsobem, jakým jsou v něm znalosti organizovány, začleněny a využívány a způsobem interakce s uživatelem. Na rozdíl od většiny konvenčních programů, ve kterých jsou znalosti implicitně roztroušeny v programu, je rozhodující většina znalostí důležitých pro řešení problémů daného typu v rámci znalostního systému soustředěna explicitně v samostatně modulární struktuře – **bázi znalostí**.

Nejdůležitějším principem expertních systémů je tak **oddělení modelu znalostí od způsobu jejich používání**. Což znamená, že při doplňování a modifikacích báze znalostí není nutno modifikovat ostatní části znalostního systému. Báze znalostí obsahuje faktické a heuristické znalosti o dané oblasti. **Inferenční mechanismus** pak pracuje s bází znalostí při řešení konkrétní úlohy.

Faktické znalosti jsou různé údaje, poznatky, výsledky ... Tyto znalosti obvykle expert předává veřejnosti pomocí odborných publikací a vystoupení. S jádrem faktických znalostí některého oboru jsou seznamováni studenti v klasické výuce.

Heuristické znalosti jsou různé pracovní postupy, pravidla úsudků a odhadů, způsoby odhadů, způsoby odhalování a vynalézání nového ... Heuristické znalosti jsou zpravidla zkušenostní povahy, jsou nejisté. Vzhledem k tomu zůstávají soukromé a jen zřídka je umí expert formulovat a předat veřejnosti.

Báze znalostí určuje do značné míry kvalitu celého expertního systému. Potvrdilo se, že většina podstatných znalostí je heuristické povahy a expert sám často není schopen tyto znalosti explicitně vyjádřit. Pro získání znalostí je proto nutná zdlouhavá práce znalostního inženýra s dotyčným expertem. Východiskem je obvykle pečlivá analýza mnoha řešených problémů. Týmovou prací experta a znalostního inženýra lze extrahovat reálné znalosti, které nejsou součástí učebnic, ale jsou přitom rozhodující pro činnost experta. Explikace těchto heuristických znalostí je sama o sobě významným výsledkem aplikace znalostního inženýrství.

Pro **reprezentaci znalostí** byla v umělé inteligenci vytvořena řada prostředků. Kromě logických kalkulů se používají např. sémantické sítě, tzv. rámce, gramatiky atd. V expertních systémech bývá báze znalostí vyjádřena nejčastěji systémem pravidel typu situace – akce. Situace je vystižena kombinací podmínek na okamžitý stav údajů a poznatků o řešené úloze, akce pak tyto poznatky doplňuje a mění. Vyjádření podmínek akcí se musí opírat o jistou datovou strukturu odpovídající základním pojmům a poznatkům v dané oblasti. Pravidla pak vedou od rozpoznání stavu této databáze k její modifikaci.

Jednotlivá pravidla jsou vyjádřením jakýchsi atomických (na zvolené úrovni modelování) znalostí. Granularita báze znalostí musí odpovídat dané problémové oblasti: příliš rozdrobená znalost je těžko programově zvládnutelná a špatně pochopitelná, v opačném případě velká agregace systému nedovoluje dostatečnou diskriminaci jevů.

Reprezentace báze znalostí jako systému jednoduchých heuristik má výhodu ve snadné interpretaci a modifikaci. Při ladění systému lze pružně bázi znalostí doplňovat, vypouštět některá pravidla nebo je měnit.

2.1 Charakteristické rysy expertních systémů

Expertní systém je tedy tvořen konkrétní **bází znalostí a inferenčním mechanismem**. Tento mechanismus a použitá reprezentace znalostí musí být založeny na některé teorii usuzování a řešení úloh dané problémové oblasti (daným expertem). Jedině tak může expertní systém simulovat příslušnou expertní činnost. Aby bylo možno přijmout závěry expertního systému, je nutné vědět, jak byly získány. Expertní systémy jsou proto vybaveny možnostmi informovat o průběhu inference a jednotlivé kroky podrobně objasnit. Vysvětlení předkládají ve formě vhodné pro uživatele a v rozsahu, který si uživatel určí. Vysvětlovací schopnost systému je nezbytná též při ladění a modifikacích báze znalostí.

Za charakteristické rysy expertních systémů se tedy považují:

- Oddělení znalostí a mechanismu pro jejich využívání.

Znalosti experta jsou uloženy v bázi znalostí odděleně od inferenčního mechanismu. To umožňuje vytvářet problémově nezávislé (prázdné) expertní systémy (expert system shells), kde jeden inferenční mechanismus může pracovat s různými bázemi znalostí.

- Neurčitost v bázi znalostí.

V bázi znalostí jsou uloženy nejen exaktně dokázané znalosti, ale i nejrozumnější heuristiky, které se např. expertovi osvědčily při rozhodování za dlouhou dobu jeho praxe. Zde se pak objevují pojmy jako „často“, „většinou“, které je potřeba kvantifikovat (např. v nějaké škále od „určitě ano“ přes „nevím“ až k „určitě ne“). Takovou znalostí s neurčitostí může například být „jestliže má pacient teplotu, obvykle je mu předepsán acylpyrin“; pacient totiž „často“ má teplotu v důsledku chřipky, ale „někdy“ může mít teplotu, protože je v poúrazovém šoku.

- Neurčitost v datech.

Konkrétní data o daném případě bývají zatížena neurčitostí způsobenou nepřesně určenými hodnotami nebo subjektivním pohledem uživatele (odpovědi na míru jistoty v nějakém tvrzení). Může to být například odpověď „snad ano“ na dotaz, zda má pacient teplotu.

- Dialogový režim.

Expertní systémy jsou nejčastěji konstruovány jako tzv. konzultační systémy. Uživatel komunikuje se systémem způsobem „dotaz systému – odpověď uživatele“ obdobně, jako s lidským expertem. Tento systém práce byl do značné míry usnadněn nástupem osobních počítačů a s tím souvisejícím přechodem od dávkového zpracování na sálech výpočetních středisek k interaktivnímu zpracování přímo na pracovním stole uživatele.

- Vysvětlovací činnost.

Aby se zvýšila důvěra uživatelů v závěry a doporučení expertního systému, měl by systém poskytovat vysvětlení svého uvažování. Obvykle systém vysvětluje právě položený dotaz, znalosti relevantní k nějakému tvrzení, právě zkoumanou cílovou hypotézu, právě probíhající odvozování.

- Modularita a transparentnost báze znalostí.

Pro účinnost expertního systému je rozhodující kvalita báze znalostí. Modularita umožňuje snadnou aktualizaci báze znalostí, transparentnost umožňuje její snadnou čitelnost, srozumitelnost a kontrolu. Samotné vytváření báze znalostí probíhá iterativním způsobem při opakovaných konzultacích experta z dané problémové oblasti s odborníkem

na tvorbu bází, tzv. znalostním inženýrem, kdy je báze znalostí postupně „laděna“, až chování expertního systému (alespoň při konzultaci pro vzorové příklady) odpovídá představám experta.

Jiné druhy charakteristik, které bychom mohli spíše označit jako požadavky:

- Vysoká spolehlivost – systém musí být schopen odpovědět na stejné nebo vyšší úrovni než lidský expert.
- Přiměřená doba odezvy – systém musí odpovídat v přijatelném čase. Vyřeší-li expert problém za hodinu, je systém podávající stejnou odpověď za rok nepoužitelný.
- Stabilita – systém musí být stabilní a nehroutit se, jinak nebude používán.
- Srozumitelnost – systém musí být schopný podávat vysvětlení o jednotlivých krocích odvozování, jinak bude nesrozumitelný a stane se z něj „černá skříňka“.
- Flexibilita – systém musí jednoduše umožňovat přidávání, měnění a mazání znalostí.

2.2 Aplikace expertních systémů

Podle charakteru řešených úloh se aplikace dají rozdělit na:

- diagnózu – proces nalezení chyb či chybných funkcí systému (živého nebo neživého);
- interpretaci – analýza dat s cílem určení jejich významu;
- monitorování – průběžná (on line) interpretace signálů a dat a určení okamžiku, kdy je nutná intervence;
- plánování – nalezení posloupnosti akcí k dosažení cíle;
- návrh (design) – vytváření konfigurací objektů vyhovujících daným podmínkám;
- predikce – předpověď běhu budoucích událostí na základě modelu minulosti a současnosti.

Celkově lze expertní systémy (ES) rozdělit na dvě základní skupiny: diagnostické a generativní.

- **Diagnostické expertní systémy** zahrnují systémy, které slouží výběru jedné z předem daného pevného seznamu možností. Historicky prvními a stále základními příklady diagnostických expertních systémů jsou MYCIN pro diagnostiku jistých infekčních onemocnění a PROSPECTOR pomáhající při hledání nalezišť rud. Mezi současnými ekonomickými aplikacemi diagnostických expertních systémů je např. řada systémů odhadujících bonitu klienta, nebo vyhodnocujících investiční příležitosti. Zajímavý je systém FinCEN pomáhající při odhalování podezřelých transakcí.
- **Generativní expertní systémy** nevedou k výběru jedné z několika variant řešení, ale slouží k tvorbě návrhů přijatelných řešení. Možných řešení lze přitom potenciálně zkonstruovat nepřeberné množství. Systém jich ovšem generuje pouze omezený počet a vyhodnocuje je testováním. Kromě již zmíněného prvního expertního systému DENDRAL do této skupiny patří třeba i známý systém XCON pro konfiguraci počítačů podle uživatelských přání zákazníků.

Expertní systém MYCIN

Úkolem expertního systému MYCIN je diagnóza jistých druhů infekcí ve složitých pooperačních stavech a doporučení pro jejich medikamentózní léčbu. Uživatelem je lékař - chirurg, který nemusí být nutně expertem na infekční choroby (na rozdíl od experta, který byl zdrojem báze znalostí systému MYCIN). Během dialogu se systém MYCIN ptá ošetřujícího lékaře na stav, zdravotní historii pacienta a výsledky laboratorních testů. Na závěr systém MYCIN vydá diagnózu a doporučí vhodnou terapii. Báze znalostí systému MYCIN obsahuje 451 pravidel tvaru:

- Jestliže (konjunkce podmínek),
- pak (závěr)
- s jistotou (číslo).

Každá podmínka nebo závěr je **výrok tvaru (atribut) (objekt) (hodnota)**.

Jistota je číslo z jednotkového intervalu, které udává stupeň potvrzení závěru, jsou-li potvrzeny (pravdivé) podmínky pravidla. Stupeň jistoty je pravidlům subjektivně připisován expertem.

Následuje 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 pseudomona aeruginosa
- With certainty 0.6.

Inferenční mechanismus systému MYCIN je založen na zpětném řetězení a modelu zpracování nejistoty, který interpretuje stupně jistoty jako tzv. míry důvěry. Systém MYCIN vysvětluje své chování jak během konzultace (uživatel se může zeptat systému, proč položil některou otázku), tak po jejím skončení (uživatel se může zeptat systému, jak dospěl k některému závěru). Výsledky expertního systému MYCIN se při hodnocení v devadesáti procentech shodovaly nebo byly stejně dobré jako rozhodnutí odborných lékařů.

Ze systému MYCIN byl separován inferenční mechanismus, který se stal základem „prázdného“ systému EMYCIN, jehož naplněním jinou bází znalostí vzniká nový expertní systém. Tak byl vyvinut např. systém PUFF pro interpretaci výsledků plicního vyšetření spirometrem a systém SACON doporučující vhodnou strategii strukturní analýzy pevnosti konstrukce metodou konečných prvků.

Expertní systém PROSPECTOR

Úkolem expertního systému PROSPECTOR je odhad věrohodnosti toho, že se na daném místě vyskytuje rudné ložisko typu reprezentovaného zadaným modelem. Uživatel pracuje s expertním systémem v dialogu, během něhož předkládá svá pozorování a je žádán o další informace. 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).

U systému PROSPECTOR bylo provedeno srovnání jeho závěrů s usuzováním geologa, který byl zdrojem expertních znalostí. 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.

Expertní systém FinCEN

Úkolem expertního systému FinCEN (Financial Crimes Enforcement Network) je odhad podezřelosti finanční transakce z hlediska praní špinavých peněz. Provozuje jej stejnojmenný úřad při americkém ministerstvu financí, který kontroluje všechny transakce hlášené finančními institucemi. Expertní znalosti o podezřelosti transakcí jsou reprezentovány ve formě cca 2000 pravidel a tzv. rámců zachycujících stereotypní situace, což je výhodné při používání formulářů, na nichž jsou zprávy o jednotlivých transakcích zasílány a vkládány do databáze.

Vhodnost aplikace diagnostického expertního systému

Na závěr budeme v bodech charakterizovat, pro které úlohy je možné uvažovat o vytvoření diagnostického expertního systému k jejich řešení:

- 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

2.3 Struktura expertního systému

Stručně můžeme strukturu expertního systému popsat takto:

- 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

Expertní systém je tvořen dvěma základními částmi: bází znalostí a inferenčním mechanismem. V bázi znalostí jsou uloženy znalosti experta z dané oblasti, inferenční (odvozovací) mechanismus umožňuje tyto znalosti využívat při konzultaci pro konkrétní případ. Dalšími komponentami jsou báze znalostí, data ke konzultovanému případu, vysvětlovací modul umožňující (do jisté míry) zdůvodnit postup systému při odvozování a modul pro komunikaci s uživatelem. Toto schéma odpovídá „klasickému“ systému, který pracuje v dialogu s uživatelem.

Klíčovou složkou znalostního systému je inferenční mechanismus (odvozovací mechanismus). Je to programový modul, jehož úlohou je vybírat z báze znalostí ty znalosti, které jsou právě potřebné, interpretovat je a na jejich základě a v závislosti na okamžitém stavu řešení problému odvozovat nové, případně modifikovat už existující informace. Jeho dalším úkolem je řídit

případný dialog s uživatelem – požadovat od něj podle potřeby a v závislosti na řídicí strategii data potřebná pro další postup řešení.

Pojem znalosti je vhodné chápat právě v rámci logiky usuzování a inferenčního mechanismu, který ji prakticky realizuje: za novou znalost považujeme tu informaci, která není daným inferenčním mechanismem odvoditelná z jemu již dostupných znalostí.

Důležitou komponentou znalostního systému je pracovní paměť, „tabule“. Jde o dočasnou pracovní databázi, ve které jsou v průběhu řešení udržována všechna data, která systém získal zvenku (od uživatele, jiných systémů nebo měřících přístrojů) nebo která odvodil z jiných dat na základě znalostí v bázi znalostí. U složitějších a pokročilejších systémů bývá její součástí i záznam posloupnosti všech důležitých aktivit systému, označovaný obvykle jako protokol.

Báze znalostí, inferenční mechanismus a pracovní paměť tvoří jádro znalostního systému. Při řešení úlohy jsou znalosti pomocí inferenčního mechanismu aplikovány na údaje v pracovní paměti.

Vyčlenění báze znalostí jako samostatné struktury a s tím spojená explicitní, symbolická a kompaktní reprezentace znalostí umožňuje zvýšit pohodlí uživatele při práci se systémy tohoto typu. Formalismy mohou být navrženy tak, aby byly srozumitelné a přijatelné i pro neprogramátora. Významnou roli přitom hraje vysvětlovací modul umožňující systému podat uživateli na požádání vysvětlení k danému případu, zdůvodnit dosažené výsledky, ke kterým systém dospěl, i postup, jakým k nim dospěl.

Kapitola 3

Zpracování znalostí

Jak již bylo výše řečeno, znalosti (resp. báze znalostí) tvoří jednu ze dvou základních složek expertních systémů (druhou je inferenční mechanismus). Definovat pojem „znalost“ je velmi obtížné, navíc pro různé lidské činnosti se hodí jiná definice tohoto pojmu. Proto se často vychází z předpokladu, že znalost je základním pojmem, který je každému jasný a srozumitelný, a že jej není třeba definovat. ([JIR95]) Představu o pojmu znalosti, jak mu rozumíme v kontextu expertních systémů, naznačuje následující hierarchie:

- moudrost
- znalost
- informace
- data
- šum

Pojmy data, informace a znalost jsou mnohdy používána jako synonyma. Všimněme si jednoho přístupu k rozlišení a definování těchto pojmů.

Wiederhold (1986) definuje znalosti a data z hlediska budoucích informačních systémů jako komplementární pojmy. Vychází z rozboru rozhodovacího procesu, v němž expert vybavený znalostmi zvažuje data relevantní pro daný problém a činí rozhodnutí. Znalosti expert získal vzděláním a zkušeností. Vybraná data představují informace.

Data obecně můžeme chápat jako zachycení vlastností okolní objektivní reality — popisují okolní svět (tzn. charakteristiky, míry, váhy, vlastnosti

mohou být kvantitativní i kvalitativní). Pokud data vstoupí do rozhodovacího procesu a poslouží nám v tomto procesu (přispějí k snížení míry neupořádanosti systému – subjektu, který se rozhoduje), pak tato data můžeme označit za informace.

Typické je, že zdroj znalostí (expert) a zdroj informací (sebraná data) jsou odlišné – zvláště v hospodářských aplikacích nemá expert čas sbírat a ověřovat data. Rozlišení dat a znalostí pro účely automatizace rozhodovacích procesů je proto následující:

- Jestliže se můžeme spolehnout při sběru materiálu na automatický proces nebo úředníka, hovoříme o datech. Správnost dat vzhledem k reálnému světu může být objektivně verifikována srovnáním s jeho opakovaným pozorováním.
- Jestliže hledáme experta, který by poskytl materiál, potom hovoříme o znalostech. Znalosti obsahují abstrakce a generalizace zkušeností experta. Vesměs nemohou být objektivně verifikovány. Mnohé definice, nutné k organizaci systému, jsou také znalostmi.

Data odrážejí současný stav světa na úrovni instancí, takže obsahují mnoho detailů, jsou objemná a často se rychle mění. Znalosti se tak často nemění. Pojednávají o generalizacích, a proto se vztahují spíše k typům entit než k jejich instancím. Rozdíl mezi daty a znalostmi se jeví podstatný v úvahách o aktualizaci, chybách v datech a nejistotě znalostí.

Nově získaná data mohou být v rozporu s existujícími znalostmi. Ve velkých databázích se vždy vyskytují chybné údaje, a proto je nutné rozpory pečlivě prověřovat. Avšak ani správná data, která jsou v rozporu se znalostmi, nemusí ihned vést k revizi znalostí. Jsou-li znalosti vybaveny faktory jistoty, je třeba spíše tyto faktory za pomoci automatické učící se procedury aktualizovat. Někdy konflikt mezi daty a znalostmi ukazuje na neúplnost báze znalostí a lze jej vyřešit doplněním dalších znalostí, které pokrývají nové případy.

Jeden z problémů vztahu dat a znalostí spočívá v tom, že data na vyšší úrovni zpracování (např. již agregovaná nebo jinak odvozená) se mohou jevit jako znalost vůči nižší úrovni zpracování.

Charakteristické rysy znalostí můžeme shrnout takto:

- znalosti umožňují odvodit nové informace
- znalosti ukazují zákonitosti, vztahy, pravidla

- prakticky používané při řešení problému
- zobecnění empirických zkušeností
- heuristická, intuitivní povaha (tacitní znalosti)
- neúplné, měnící se
- nepřesné, neurčité, nejisté, vágní
- spojené se způsobem usuzování
- úzce specializované

3.1 Reprezentace znalostí

Reprezentace znalostí je spojena s hledáním modelů a datových struktur, které by umožnily reprezentovat významnou část znalostí a řešení daného problému v podobě báze znalostí, a potom takto reprezentované znalosti efektivně využívat při řešení problému počítačem.

Účelem vhodné reprezentace znalostí je kromě snadného vyhledávání a modifikace uložených znalostí hlavně možnost odvozovat z nich pomocí inferenčního mechanismu potřebné závěry. Zejména v tom se znalostní systémy liší od databázových, které se soustřeďují především na otázku vyhledávání. Další odlišnost spočívá v neurčitosti a neúplnosti, které jsou pro soustavy znalostí typické a musí na ně být při jejich reprezentaci brán zřetel. Reprezentace znalostí je někdy považována za centrum zájmu výzkumu v umělé inteligenci, domníváme se však, že prvořadá je otázka způsobu odvozování, jemuž se musí reprezentace znalostí podřídit.

Na reprezentaci znalostí jsou kladeny často různé i protichůdné požadavky. Všimněme si například požadavku modularity báze znalostí, který je pro získávání znalostí zvláště významný. Při vytváření báze znalostí je důležité, aby použitá reprezentace dovolovala jednoduše upřesňovat znalosti, zejména je inkrementálně rozšiřovat. Báze znalostí bude zřejmě modulární, bude-li složena z nezávislých, jednoduchých částí, které vyjadřují jakési atomické (na zvolené úrovni modelování dále nedělitelné) znalosti.

Na druhé straně však existují důvody proti takovému uspořádání znalostí. Jednotlivé znalosti totiž vyjadřují rozmanité závislosti, které mohou být od sebe svojí formou značně odlišné, avšak významově si mohou být blízké.

Proto je vhodné použít neuniformní reprezentaci, postihující co nejlépe podstatu znalostí, a doplnit ji o možnost vyjádřit vazby mezi znalostmi. Požadavek volného sdružování příbuzných znalostí vychází z potřeby rychle vyvolávat jednotlivé znalosti. Jak je zřejmé, v konkrétních případech je nutno přistoupit k vhodnému kompromisu.

V expertních systémech jsou znalosti reprezentovány nejrůznějšími způsoby. Za „klasické“ lze považovat logiku (ať již výrokovou či predikátovou), pravidla, rámce (v programování známé spíše pod názvem objekty), sémantické sítě a báze pravidel.

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 (viz [9] J.F.Sowa: Knowledge Representation: Logical, Philosophical, and Computational Foundations)
- Reprezentace znalostí pravidly

Zmíníme se zde stručně pouze o pravidlech, o jiných způsobech reprezentace znalostí se můžete více dozvědět např. v [1] či [2].

3.2 Pravidla

Soustava pravidel tvaru

$$A_1 \wedge A_2 \wedge \dots \wedge A_k \Rightarrow S$$

je jedním z nejčastěji užívaných způsobů vyjádření báze znalostí. Lze je chápat dvojím způsobem:

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

Pravidlo je vyvoláno tehdy, nastala-li podmínka v jeho situační části. Obecně není tvar a obsah pravidla nijak omezen, většinou jsou však v konkrétních realizacích dodrženy tyto zásady:

- vyhodnocení situační části spočívá ve srovnání podmínky se stavem pracovní paměti, která při tom nesmí být měněna;
- akční část představuje vykonání jednoduchých zásahů do pracovní paměti, a to na úrovni pojmů v ní používaných.

Pravidla tedy představují elementární akce systému. Vhodná volba těchto akcí usnadňuje práci inferenčního i vysvětlovacího mechanismu. Výhodou této reprezentace báze znalostí je její značná modularita a přirozená deklarativní sémantika pravidel.

Pravidla na sebe prostřednictvím použitých výroků navazují: závěr jednoho pravidla může být předpokladem jiného pravidla. Síť pravidel (neobsahující cyklus) představuje bázi znalostí, v níž

- výroky, které nejsou v závěru žádného pravidla, reprezentují vstupní informace, **dotazy**
- výroky, které nejsou v předpokladu žádného pravidla, reprezentují výstupní informace, **závěry, cílové výroky**
- **mezilehlé** výroky reprezentují jednotlivé uzly odvozování závěrů

Pravidla jsou zřejmě nejpoužívanější způsob reprezentace znalostí a jsou zároveň nejlépe pochopitelná pro lidské myšlení. Lidé často sami při řešení problémů používají pravidla jako například „JESTLIŽE prší, PAK si vezmu deštník“. Pravidla v expertních systémech mají právě takovou podobu. Dalším důvodem pro „oblíbenost“ pravidel může být v tom, že tyto struktury se často používají v oborech, které mají blízko k expertním systémům. V programovacích jazycích se IF THEN struktura vyskytuje jako jeden z nejčastěji používaných příkazů, v logice to je výraz pro implikaci (a jako implikace jsou pravidla většinou vyhodnocována).

IF THEN struktura může být samozřejmě rozšířena do podoby IF THEN ELSE. Toto rozšíření slouží především pro zvýšení pohodlí uživatele při tvorbě báze. Je snadno vidět, že pravidlo

- IF a THEN b ELSE c
lze zapsat jako dvě pravidla
- IF a THEN b
- IF NOT a THEN c.

Situace, předpoklad a závěr jsou nejčastěji kombinace tvrzení - výroků, jejichž základem je tzv. **objekt-atribut-hodnotové schéma**:

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

Typy atributů mohou být:

- kategoriální
 - binární
 - nominální
 - ordinální
- numerické

3.3 Infereční mechanismus

Zatímco u lidských expertů mluvíme spíše o usuzování, u expertních systémů pro získávání nových znalostí či informací používáme výraz inference nebo odvozování.

Metody inference, jak je popisuje [2], jsou:

- Dedukce – logické usuzování, při kterém závěr musí vyplývat z předpokladů.
- Indukce – odvozování ze speciálního případu na obecný.
- Intuice – bez teorie. Expertní systémy tento druh inference zatím neimplementují.

- Heuristika – pravidla „vycucaná z prstu“ založená na zkušenosti.
- Generování a testování – pokus a omyl, často používané pro efektivní plánování.
- Abdukce – usuzování z platných závěrů na předpoklady, které mohly tyto závěry způsobit.
- Default – pokud chybějí speciální znalosti, usuzuje se na základě obecných či běžných znalostí.
- Vlastní znalosti.
- Nemonotónní usuzování – předchozí znalosti mohou být chybné po získání nových poznatků.
- Analogie – odvození závěru na základě podobnosti s jinou situací.

Inferenční mechanismus organizuje používání báze znalostí při řešení zadané úlohy a komunikaci s uživatelem. Například prohledávání pravidlové báze znalostí může být řízeno mnoha strategiemi. Základní typy jsou:

- **Přímé řetězení** (forward chaining, bottom-up). Vyhledávají se pravidla, jejichž antecedent (situační předpoklady) je v datech splněn. Tato pravidla se okamžitě provádějí a tím se data modifikují, doplňují o nové poznatky.
- **Zpětné řetězení** (backward chaining, top-down). Vyhledávají se pravidla s vytčeným sukcedentem (akcí, konsekventem). K jejich antecedentům se opět hledají pravidla, která by je mohla potvrdit atd., až se dojde k prověřitelným pravidlům.
- **Agendové řízení**. Používají se váhové funkce, které neustále oceňují výhodnost vyvolání pravidel nebo jejich skupin.

Důsledkem použití některých pravidel může být dotaz na uživatele či sdělení uživateli. Po průchodu bázi znalostí vyhodnocuje inferenční mechanismus závěry.

3.4 Neurčitost

Neurčitost můžeme chápat jako nedostatek znalostí (nebo nepřesné znalosti) při řešení rozhodovacího problému. „Neurčitost je problém, neboť nám zabraňuje ve výběru nejlepšího řešení a může způsobit výběr špatného řešení.“ [2] Neurčitost může způsobit nejrůznější typy chyb. Na druhou stranu, téměř veškeré znalosti a informace v našem světě jsou zatíženy nějakou dávkou neurčitosti. Lidé jsou zvyklí s neurčitostí pracovat a rozhodovat se i při nepřesných informacích, je tedy na místě zabývat se otázkou, jak přenést neurčitost do expertních systémů.

V expertních systémech může být neurčitost dvojího druhu. Je to jednak neurčitost v expertních znalostech a jednak neurčitost v datech.

Neurčitost v expertních znalostech se v těchto systémech modeluje tak, že jednotlivým pravidlům bývají přiřazeny prvky z nějaké (alespoň částečně uspořádané) struktury. Obvykle se používá interval $[-1,1]$ nebo $[0,1]$. Pravidla potom mají tvar např.:

- IF rozumný záměr AND seriózní klient THEN půjčit WITH WEIGHT (0.8)

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

Naproti tomu **neurčitost v datech** přiřazuje určitou váhu počátečním uzlům, tj. např.

- rozumný záměr WITH WEIGHT (0.9)

vyjadřuje poměrně velké přesvědčení uživatele o platnosti tohoto výroku (nikoli však jistotu).

K práci s neurčitostí jsou využívány různé přístupy, např.

- pseudopravděpodobností přístup,
- míry důvěry a nedůvěry,
- fuzzy logika,
- zobecňující algebraické pojetí.

Jejich podrobný popis můžete nalézt např. v [1] či [2].

3.4.1 Míry důvěry

”Ad hoc”teorie měr důvěry pro zpracování neurčitosti pravidla $E \Rightarrow H$ vychází z následujících principů:

Označíme pravděpodobnost **hypotézy** $P(H)$ a podmíněnou pravděpodobnost $P(H|E)$ (při splnění **evidenci** E).

- **Míra důvěry** vyjadřuje, jak evidence E potvrzuje hypotézu H

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

- **Míra nedůvěry** vyjadřuje, 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 evidence E potvrzuje/vyvrací hypotézu H .

3.4.2 Pseudopravděpodobnostní přístup

Pro pravidlo $E \Rightarrow H$ z **Bayesovy věty o podmíněných pravděpodobnostech** pro hypotézu H a její negaci \bar{H} plyne

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

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

kde

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

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 vyjadřuje neurčitost pravidla tím, že zadává

- **míru postačitelnosti** L : kolikrát E zvyšuje šanci hypotézy H

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

- **míru nezbytnosti** \bar{L} : pro nepřítomnost evidence E

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

3.4.3 Algebraická teorie neurčitosti

Jedná se o zobecnění různých přístupů ke zpracování neurčitosti v expertních systémech formulované P. Hájkem. Neurčitosti jsou reprezentovány při odvozování **váhami** na intervalu $[-1; 1]$, kde 1 znamená „jistě ano“, -1 znamená „jistě ne“.

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 předpokladu a
- Funkce $GLOB(v, w)$ – váha složení příspěvků v, w pravidel

3.4.4 Standardní inferenční mechanismus

V rámci algebraické teorie skládání vah lze zadávat různé způsoby práce s neurčitostí. Standardní inferenční mechanismus vychází zejména ze systémů MYCIN a PROSPECTOR, tj. z měr důvěry a pravděpodobnosti.

Kombinační funkce *NEG*, *CONJ*, *DISJ*, *CTR*, *GLOB* jsou zde pro kladné váhy definovány takto:

- *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:

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

3.4.5 Využití fuzzy logiky

Fuzzy logika je 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, součinnová, 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 je v Łukasiewiczově

logice doplněno o výpočet stupně, v němž závěr vyplývá z předpokladů platných ve stupních a, w :

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

Pravdivostní funkce **fuzzy konjunkce** $x \otimes y$ rozšiřuje klasickou dvouhodnotovou pravdivostní tabulku konjunkce na interval pravdivostních hodnot $[0; 1]$. Příklady takových rozšíření jsou:

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

Fuzzy disjunkce jsou definovány duálně k fuzzy konjunkcím jako následující pravdivostní funkce:

- Maximová: $x \oplus_M y = \max(x, y)$.
- Součinnová: $x \oplus_P y = x + y - x \cdot y$.
- Hamacherova: $x \oplus_H y = \frac{x \cdot (1-y) + (1-x) \cdot y}{1 - x \cdot y}$, $1 \oplus_H 1 = 1$.
- Lukasiewiczova: $x \oplus_L y = \min(1, x + y)$.

Využití úplné fuzzy logiky pro zpracování neurčitosti v expertních systémech je založeno na těchto principech:

- 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 stupeň 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 jsou pak odvozeny kombinační funkce pro váhy na intervalu $[-1; 1]$.

Logický inferenční mechanismus, který vychází z Łukasiewiczovy fuzzy logiky, je dán touto definicí kombinačních funkcí $NEG, CONJ, DISJ, CTR, GLOB$ 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:

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

Literatura

- [1] Berka, P. – Jirků, P. – Vejnarová, J.: *Expertní systémy*. 1. vyd. Praha, VŠE 1998. 160 s.
- [2] Giarratano, J. - Riley, G.: *Expert Systems – Principles and Programming*. PWS Publishing Company, Boston 1993. ISBN: 0-534-95053-1.
- [3] Ivánek, J. - Ferjenčík, J. - Stejskal, B. - Švenda, J.: *Základy matematické informatiky - III. Znalostní inženýrství*. Praha, VŠE 1987, 114s.
- [4] Ivánek, J.: An expert system recommending suitable mathematical decision method. *Computers and Artificial Intelligence*, 5, 1986, s.241-251.
- [5] Ivánek, J. - Švenda, J. - Ferjenčík, J.: Inference in Expert Systems Based on Complete Multivalued Logic. *Kybernetika*, 25, 1989, s.25-32.
- [6] Ivánek, J.: Representation of expert knowledge as a fuzzy axiomatical theory. *International Journal of General Systems*, 20, 1991, s.55-58.
- [7] Jiroušek, R.: *Metody reprezentace a zpracování znalostí v umělé inteligenci*. Praha, VŠE, 1995, 103s.
- [8] Sklenák, V. a kol.: *Data, informace, znalosti a Internet*. C. H. Beck 2001, xvii + 507s.
- [9] Sowa, J.F.: *Knowledge Representation: Logical, Philosophical, and Computational Foundations*. Brooks/Cole 2000, xiv + 594s.