

## Obsah

1	Expertní systémy .....	2
1.1	Základní informace .....	2
1.2	Výstupy z učení .....	2
1.3	Expertní systém (ES) .....	2
1.4	Části ES .....	2
1.5	Pravidlové ES .....	3
1.5.1	Reprezentace znalostí .....	3
1.5.2	.....	3
1.5.3	Inference, dopředné a zpětné řetězení .....	3
1.5.4	Výhody a nevýhody pravidlových ES .....	5
1.6	Nepravidlové ES .....	6
1.6.1	Sémantické sítě .....	6
1.6.2	Rámce a objekty .....	7
1.7	.....	9
1.8	Neurčitost v ES .....	9
1.8.1	Podmíněná pravděpodobnost .....	9
1.8.2	Damsterova-Shaferova teorie .....	10
1.8.3	Fuzzy množiny .....	11
1.9	Seznam použité literatury .....	13

# 1 Expertní systémy

## 1.1 Základní informace

Následující text je součástí učebních textů předmětu Umělá inteligence a je určen hlavně pro studenty Matematické biologie. Poskytuje základní informace o oblasti umělé inteligence, která se zabývá expertními systémy (ES). Jsou stručně popsány principy ES a jsou zmíněny metody, kterými je možné řešit zahrnutí neurčitosti do rozhodovacích mechanismů ES.

## 1.2 Výstupy z učení

Zvládnutí učebního textu umožní studentům:

- Porozumět základním pojmům jako
  - Expertní systém
  - Pravidlové a nepravidlové expertní systémy
  - Dopředné a zpětné řetězení v ES
- Osvojit si inferenci v ES pomocí výrokové logiky a modus ponens
- Seznámit se a porozumět metodám nakládání s neurčitostí v ES pomocí
  - Bayesovské podmíněné pravděpodobnosti
  - Faktorů určitosti
  - Fuzzy logiky


## 1.3 Expertní systém (ES)

Expertní systémy řadíme do metod a modelů umělé inteligence. Expertní systém představuje počítačový model, který má nahradit rozhodování lidského odborníka. Jedná se tedy v souladu s definicí umělé inteligence o tvorbu inteligentních strojů, které emulují rozhodování člověka. Expertní systémy jsou vytvářeny jako specializované modely, tedy modely cílené do dané oblasti (medicína, řízení procesů, obchodování...) lidské činnosti. Snahou expertních systému je emulovat co možná nejlépe rozhodování experta, tedy odborníka, který je v dané oblasti specializován a který je na základě svých znalostí a zkušeností schopen řešit problémy v dané oblasti lépe, než ostatní lidé.

Úspěšné vytvoření expertního systému má oproti lidskému expertovi řadu výhod. Je levnější na provoz, systém je vždy dostupný, jeho rozhodování je stabilní v čase, dokáže exaktně popsat rozhodovací proces. Problematická samozřejmě může být tvorba takového systému, kdy nebývá snadné převést rozhodování lidského experta na systém fungující podle pravidel. Lidský expert totiž není často schopen definovat postup, kterým ke správnému rozhodnutí došel, využívá svoji intuici.

## 1.4 Komponenty expertních systémů

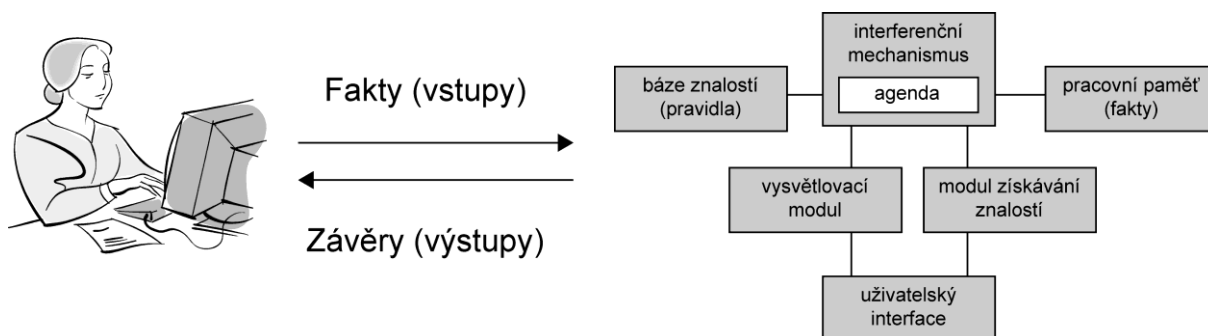
Základní představa o expertním systému bez ohledu na jeho konkrétní implementaci je taková, že ES obsahuje bázi znalostí a vnitřní inferenční mechanismus, který provádí vlastní usuzování ES. ES jsou tedy předkládány proměnné vstupy, ES provede vlastní rozhodování a odpoví svými závěry – výstupy.



Obr. 1 Expertní systém (podle [1]).

Podrobněji lze v ES identifikovat mimo báze znalostí, kterou můžeme chápat jako databázi rozhodovacích pravidel a vlastního inferenčního mechanismu obvykle další specializované moduly:

- pracovní paměť pro uložení aktuálních faktů
- modul pro získávání znalostí, který zajišťuje aktualizaci báze znalostí
- vysvětlovací modul, který dokáže uživateli zobrazit proces, kterým ES k závěrům došel
- uživatelské rozhraní pro interakci s uživatelem ES



Obr. 2 Blokové schéma expertního systému (podle [1]).

## 1.5 Pravidlové expertní systémy

### 1.5.1 Reprezentace znalostí

V pravidlových ES jsou znalosti reprezentovány databází pravidel. Pravidlové ES jsou založeny na principu splnění platnosti nějakého předpokladu a generování z něj plynoucích závěrů. Aplikují tedy pravidla typu *jestliže -> pak*, *předpoklad -> konsekvence* (akce, závěr, důsledek). Tyto ES nazýváme také produkčními ES. Formálně lze rozhodovací pravidlo zapsat jako „IF platí předpoklad(y) THEN platí závěr(y)“, nebo „IF p THEN q“, nebo také jako  $p \Rightarrow q$ , kde p může být složeným výrazem spojeným logickými spojkami AND, OR a q může být výrazem spojeným logickými spojkami AND. Výraz p představuje vlastně pozorování, které za předpokladu že nastalo, vede na hypotézu q.

Příkladem mohou být jednoduchá pravidla typu „IF (zvysena\_teplota\_nad\_38 OR bolest\_hlavy) THEN (uzij\_500mg\_paralen AND jdi\_do\_postele)“

### 1.5.2 Inference, dopředné a zpětné řetězení

Inferenční mechanismus v produkčních ES je založen na opakované aplikaci pravidla modus ponens.

$$\frac{p, p \Rightarrow q}{q}$$

(1)

Pravidlo modus ponens vyjadřuje skutečnost, že pokud platí předpoklad  $p$  a současně platí pravidlo  $p \Rightarrow q$ , pak platí i hypotéza  $q$ .

$p$	$q$	$p \rightarrow q$	$(p \rightarrow q) \wedge p$	$((p \rightarrow q) \wedge p) \rightarrow q$
T	T	T	T	T
T	F	F	F	T
F	T	T	F	T
F	F	T	F	T

**Tab. 1** Modus ponens (podle [1]).

Z tabulky 1 je zřejmé, že modus ponens je Tautologií, tedy výrokem platným pro všechny kombinace  $p$  a  $q$ .

Předpokládejme například existenci pravidla ve formě výroku  $(p \Rightarrow q)$  „Jestliže bude svítit slunce, půjdu na plovárnu“. Co nám tento výrok říká v případě, že  $p =$  „Slunce svítí“? V takovém případě je zřejmé, že půjdu na plovárnu a platí tedy i výrok  $q =$  „půjdu na plovárnu“. Odvodili jsme tedy jednoznačně platnost výroku  $q$ . Musíme jít na plovárnu.

Jaké je ale situace v případě, že slunce svítit nebude, tedy  $p =$  „Slunce nesvítí“? V takovém případě nelze o výroku  $q$  nic říci, protože v případě, že slunce nesvítí, nic neslibuji, na plovárnu mohu jít i přesto, že slunce svítit nebude. Stejně tak mohu zůstat doma. Pro tuto situaci nemáme tedy jednoznačné pravidlo definované. Podobně v případě, kdy budeme předpokládat stejné pravidlo  $(p \Rightarrow q)$ . Někdo nás uvidí na plovárně a je tedy schopen definovat splnění výroku  $q =$  „půjdu na plovárnu“. I když se tento výrok podobá modus ponens, na základě této pozorované skutečnosti nelze usoudit, zda slunce opravdu svítilo. Z platnosti výroku  $q$  tedy nejsme schopni odvodit platnost žádné platné tvrzení  $p$ .

Expertní systém se snaží opakovaným odvozováním vytvořit inferenční řetězec, který směřuje od vstupních faktů k závěrům ES. Jedná se tedy o nalezení takové uspořádané posloupnosti pravidel ES, jejichž postupná aplikace vytváří cestu od počátečních faktů k závěrům produkovaným ES.

Inferenční řetězec může být ES vytvořen v zásadě dvěma způsoby – na základě principu dopředného, nebo zpětného řetězení.

Mějme pravidla:

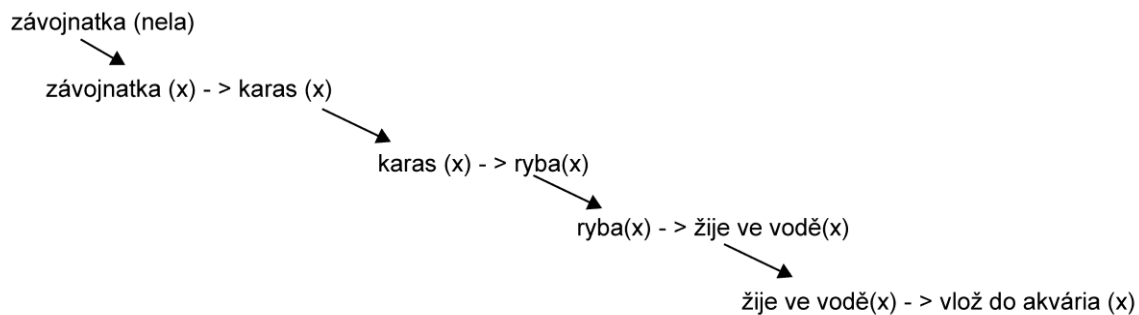
závojnátka(x)  $\rightarrow$  karas(x)

karas(x)  $\rightarrow$  ryba(x)

ryba(x)  $\rightarrow$  žije ve vodě(x)

žije ve vodě(x)  $\rightarrow$  vlož do akvaria (x)

V krabici jsme dostali dárek, nové zvíře Nelu. Nemáme k ní žádný návod, nevíme, co s ní. Víme jen, že jde o závojnatku. Snažíme se zjistit, co s ní máme udělat. Ve velmi zjednodušeném případě naší báze pravidel se snažíme spárovat dostupné fakty, tedy závojnatka(Nela) se známými pravidly a dospět k závěru. Můžeme tedy provést odvození dle následujícího schématu a dospějeme k závěru, že Nelu bude nejlépe vložit do akvária.



**Obr. 3** Jednoduchá inference v ES

Typické kroky dopředného řetězení jsou

- Porovnání - párujeme dodané fakty a zjišťujeme, která pravidla jsou splnitelná
- Řešení konfliktu - v množině splněných pravidel musíme některé zvolit (náhodně, dle priorit...) a to provést
- Provedení - výsledkem provedení může být vznik nového faktu, odstranění faktu, zavedení nového pravidla...

Uvedený postup odpovídá dopřednému řetězení (řízené daty), kdy vycházíme ze známých faktů a z nich odvozujeme možné závěry. Tento postup se hodí na úlohy, které vycházejí z přítomnosti a na základě její znalosti odvozují, co se stane či co se má stát v budoucnosti.

Povšimněme si analogie mezi prohledáváním stavového prostoru, kdy musíme volit strategii postupného provádění jednotlivých splnitelných pravidel. Nová splnitelná pravidla tedy vkládáme na konec či začátek fronty, určujeme jejich prioritu. Dopředné řetězení je zpravidla realizováno jako prohledávání stavového prostoru do šířky. Typickou oblastí aplikace je plánování a řízení.

Zpětné řetězení (řízené cíly) oproti tomu prověřuje všechny dostupné závěry a pokouší se prokázat jejich platnost vybudováním zpětného inferenčního řetězce. Vychází tedy z výstupů, které byly generovány v minulosti předešlými procesy a snaží se tyto procesy detekovat a popsat. Zpětné řetězení je použitelné jen pro úlohy s relativně omezeným počtem možných závěrů. Zpravidla je realizováno jako prohledávání prostoru do hloubky. Typickými úlohami jsou diagnostické úlohy.

### 1.5.3 Výhody a nevýhody pravidlových ES

Mezi základní výhody pravidlových ES patří zejména:

- Modularita – Jednoznačné vyjádření dané znalosti pravidlem a možnost snadného rozšiřování této sady pravidel. Modul pro získávání znalostí je jednoduchý.
- Jednoduchá interpretace - díky jednoznačně danému algoritmu a posloupnosti prováděných pravidel je snadné vytvořit vysvětlovací modul a předložit tak srozumitelný popis rozhodovacího procesu reprezentovaného inferencím řetězcem
- Podobnost usuzování s člověkem – Jestliže něco vidím a něco znám, tak se podle toho zachovám. Pravidlové ES postupují analogicky.

Nevýhodami pravidlových ES je zejména jejich použitelnost jen pro jednodušší problémy, které jsou snadno převoditelné do přijatelného množství pravidel.

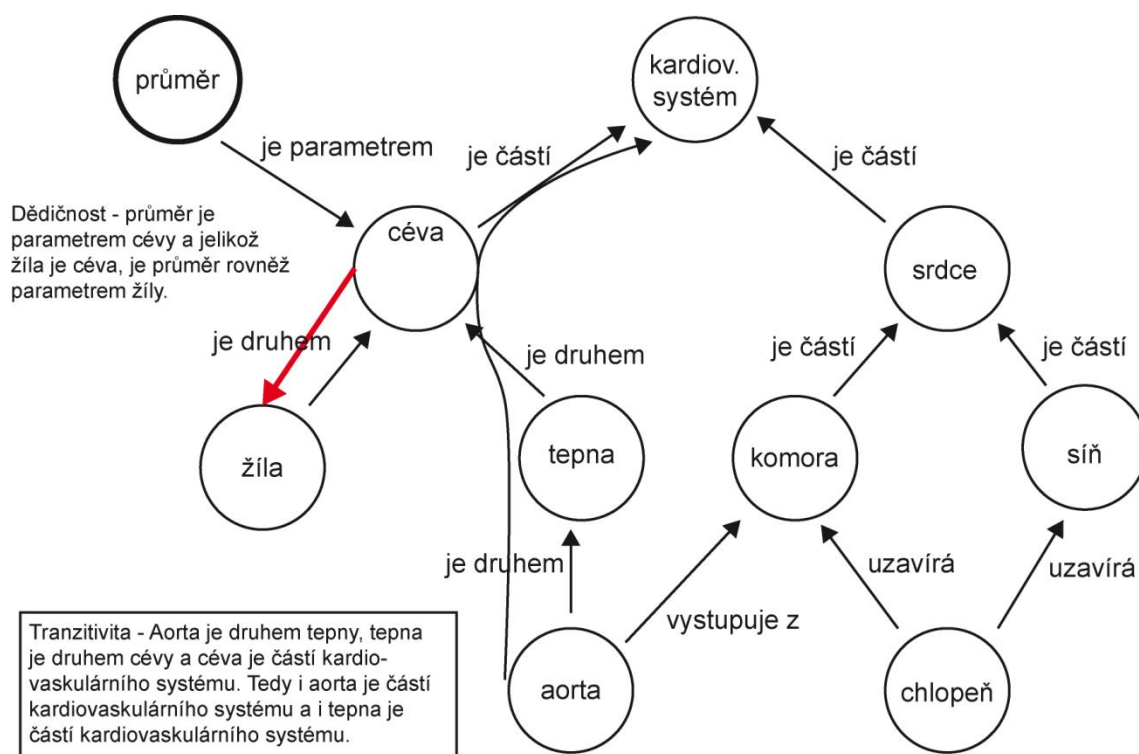
- Nepříliš efektivní algoritmy pro srovnávání pravidel a prohledávání prostoru
- Nebezpečí cyklů
- Neschopnost zachytit komplexní problémy přijatelným množstvím jednoznačných pravidel

## 1.6 Nepravidlové expertní systémy

V nepravidlových ES nejsou znalosti reprezentovány sadou pravidel, ale jsou uloženy v jiné podobě. Nejčastěji se jedná o reprezentaci znalostí pomocí sémantických sítí či rámců a vztahů mezi nimi.

### 1.6.1 Sémantické sítě

Sémantická síť je reprezentována obousměrně orientovaným grafem, který reprezentuje znalosti ES. Uzly reprezentují jednotlivé objekty modelu a hrany reprezentují relace mezi nimi. Veškeré znalosti jsou tedy rozprostřeny do jedné síťové úrovně - mělké znalostní struktury. Nejčastěji používanými relacemi mezi objekty jsou vztahy typu je, je částí, má. Sémantické sítě podporují tranzitivitu a dědičnost. Je ale nutné poznamenat, že tyto vztahy stejně jako sémantické sítě nejsou standardizovány, každý ES tedy může přicházet s vlastními definicemi či jejich modifikacemi.



**Obr. 4** Sémantická síť kardiovaskulárního systému (upraveno podle [1]).

Hlavní výhodou sémantických sítí je jejich přehledné vyjádření a snadné vyhledávání. Nevýhodou jsou naopak nestandardizované vztahy mezi objekty, které mohou vést na různé způsoby jejich interpretace.

### 1.6.2 Rámce a objekty

Reprezentace znalostí pomocí rámců a objektů nachází svoji analogii ve strukturovaných datových typech procedurálních jazyků, respektive k objektově orientovanému programování.

Rámce vycházejí z představy, že lidé pro řešení nové situace využívají podobnosti s již známými schémata, tedy hledají na základě analogie stereotypní řešení situace pouze s pozměněnými vstupními podmínkami. Rámce lze reprezentovat analogicky k datovému typu záznam procedurálních jazyků, kde jednotlivá pole záznamu se u rámců nazývají sloty a hodnoty těchto polí pak náplně. Náplně mohou být i další rámce či speciální procedury, které jsou volány například při změně hodnoty nějakého slotu rámce, podobně jako ošetření událostí například v Javascriptu. Rámce jsou pak vzájemně uspořádány do schémat.

- Rámec **rodinná vozidla**
  - **Jméno:** vozidla
  - **Typ:** rozsah (osobní automobily, dodávky, motocykly)
  - **Majitel:** if needed (pocedure najdi\_majitele\_)
  - **Umístění:** rozsah (garáž, kůlna, parkoviště)
- Rámec **automobil**

- **Jméno:** auto
- **Specializace:** rodinná vozidla
- **Typ:** osobní automobily
- **Umístění:** garáž
- Rámec **Petrovo auto**
  - **Jméno:** petrovo\_auto
  - **Specializace:** automobil
  - **Majitel:** Petr Nový

Rámce mohou být obecné i konkrétní, podporují definici vzájemných vztahů mezi rámci. Oproti sémantickým sítím je možné pomocí schémat vytvářet složitější znalostní struktury. Problematické může být přizpůsobení se nové úloze v případě, kdy schéma nebo definice i jednotlivých rámců neodpovídají vstupní úloze. Rámce jsou tedy velmi blízké objektům, které představují další stupeň v reprezentaci znalostí ES.

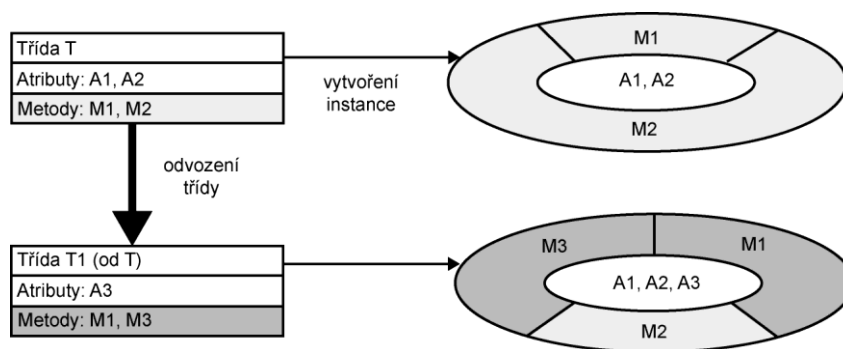
Definice znalostí pomocí objektů je blízká objektově orientovanému programování. Základními pojmy jsou zde třída a objekt. Třída představuje šablonu, obecnou definici struktury a chování budoucích objektů. Třídy navíc mohou být vzájemně hierarchicky uspořádány, reprezentují tak vztahy mezi budoucími objekty. Struktura budoucích objektů je ve třídě definována proměnnými, které deklarace objektu obsahuje a chování objektu je dáno deklarovanými metodami objektu. Snahou tedy je mapovat třídy objektů reálného světa a jejich vztahy na jejich zjednodušené počítačové modely.

Objekt je unikátní instancí dané konkrétní třídy, existuje samostatně v paměti a nese si konkrétní hodnoty svých atributů. Objektů stejné třídy může v paměti existovat více a každá má svůj vlastní prostor.

Základními vlastnostmi objektů jsou:

- **Abstrakce** od detailů světa a vnitřní implementace objektu. Objekt zachycuje jen ty rysy reality, které jsou podstatné pro řešení úlohy.
- **Zapouzdření** vnitřních atributů a metod. Objekt představuje černou skříňkou. Navenek poskytuje bez ohledu na vnitřní implementaci jen jasně definované rozhraní. To zajišťuje stabilní chování objektu, které je závislé jen na vstupních proměnných.
- **Dědičnost** objekty (potomci) dědí své vlastnosti (atributy, metody) od svého rodiče nebo i více rodičů současně. Mohou je doplňovat, nebo i transformovat, například změnit vnitřní implementaci dané metody. Hierarchie objektů je dána uspořádáním jejich vzorů - tříd.
- **Polymorfismus** pro různé potomky téže třídy může být vnitřní implementace a provádění metod různé, byť navenek se objekty různých tříd tváří stejně v relaci ke svým předkům. Potomek umí minimálně totéž, co jeho rodič.





*Obr. 5 Třída a její instance (podle [2]).*

## 1.7 Neurčitost v ES

Často se nacházíme v situaci, kdy chceme řešit nějakou úlohu přesto, že nemáme k dispozici absolutně korektní informace. Informace je nedostatečná, nepřesná, zkreslená, víceznačná či je z principu zatížena nějakou chybou. Ani rozhodovací pravidla v bázi znalostí ES nemusejí být zcela jednoznačná. Přesto tyto handicapity chceme usuzovat pomocí ES. Uvedené skutečnosti jsou důvodem k zavedení neurčitosti do rozhodování ES. Nejčastěji je neurčitost modelována číselným parametrem, který představuje míru příslušnosti k tomu kterému objektu, či pravděpodobnost provedení toho kterého přechodu, pravidla.

### 1.7.1 Podmíněná pravděpodobnost

Klasickou metodou pro zpracování neurčitosti v úplném systému jevů, které se ovlivňují, je Bayesovská pravděpodobnost. Pravidlo dle vyjádřené vztahem (1) a používané v produkčních ES říká, že v případě pozorování jevu  $p$  (tedy výrok je pravdivý,  $p$  nastalo) platí  $q$ . Podmíněná pravděpodobnost umožňuje definovat pravděpodobnost  $P(q|p)$ , která říká, že pravděpodobnost platnosti  $q$  za předpokladu platnosti  $p$  není absolutní. Pozorování jevu  $p$  tedy pouze podporuje hypotézu  $q$  s mírou pravděpodobnosti  $P(q|p)$  v intervalu  $\langle 0, 1 \rangle$ .

Předpokládejme úplný systém jevů, kde mohou nastat jevy  $p_1, p_2, \dots, p_i$ .

Platí, že

$$0 \leq P(p_i) \leq 1.$$

(2)

Dále platí, že

$$\sum_i P(p_i) = 1.$$

(3)

Pravděpodobnost, že nastanou dva nezávislé jevy, tedy  $p_1$  nebo  $p_2$  je rovna součtu pravděpodobností obou jevů.

Podmíněná pravděpodobnost  $i$ -té hypotézy  $q_i$  za předpokladu pozorování konkrétního jevu  $p$  může být vyjádřena Bayesovým vztahem pro podmíněnou pravděpodobnost:

$$P(q_i|p) = \frac{P(p|q_i) * P(q_i)}{P(p)}$$

(4)

### 1.7.2 Dempsterova-Shaferova teorie

Další metodou pro vypořádání se z neurčitostí v ES je Dempsterova-Shaferova teorie. Ta pracuje s pojmem prostředí vzájemně disjunktních jevů, hypotéz  $q_i$ .

Prostředí je definováno jako

$$\Theta = \{q_1, q_2, \dots, q_i\}.$$

(5)

Všechny kombinace těchto hypotéz, které mohou nastat, pak tvoří podmnožiny prostředí, tedy například pro tři hypotézy  $q_1, q_2, q_3$

$$\Omega(\Theta) = \{\emptyset, \{q_1\}, \{q_2\}, \{q_1, q_2\}, \{q_1, q_3\}, \{q_2, q_3\}, \{q_1, q_2, q_3\}\}$$

(6)

Dále definujeme pojem množství případu  $m$ , který podporuje věrohodnost výskytu té které kombinace hypotéz, tedy té které podmnožiny  $X$ . Platí, že

$$m: \Omega(\Theta) \in \langle 0, 1 \rangle$$

(7)

$$m(\emptyset) = 0$$

(8)

$$\sum_{X \in \Omega(\Theta)} m(X) = 1$$

(9)

Postupným pozorováním, tedy výskytem jevu, které podporuje danou podmnožinu prostředí  $X$ , dochází ke zpřesňování množství případu  $m(X)$  dané podmnožiny prostředí v intervalu  $\langle 0, 1 \rangle$ . Doplněk věrohodnosti dané podmnožiny  $1 - m(X)$  je nazýván nevěrohodností a je přiřazen věrohodnosti prostředí. Není tedy přiřazen žádné konkrétní podmnožině.

Při evidenci více jevů podporujících věrohodnost podmnožin postupujeme podle Dempsterova kombinačního pravidla, které definuje kombinované množství případu pro danou podmnožinu  $X_i$ .

$$m_3(X_3) = \sum_{X_1 \cap X_2} m_1(X_1) m_2(X_2)$$

(10)

Jedná se tedy o součet součinů množství případů podmnožin přes všechny konjunkce  $X_i$ .

Aplikaci Dempsterova pravidla si ukážeme na příkladu. Předpokládejme opět, že máme prostředí obsahující tři hypotézy  $q_1, q_2, q_3$ . Pak všechny podmnožiny jsou dle (6)

$$\Omega(\Theta) = \{\emptyset, \{q_1\}, \{q_2\}, \{q_1, q_2\}, \{q_1, q_3\}, \{q_2, q_3\}, \{q_1, q_2, q_3\}\}$$

Označme  $X_1 = \{q_1\}$  a  $X_2 = \{q_1, q_2\}$ .

Dále jsme evidovali dva jevy. První jev podporuje věrohodnost podmnožiny  $X_1$ , například  $m_1(X_1) = 0.6$ , pozorování druhého jevu podporuje věrohodnost podmnožiny  $X_2$   $m_2(X_2) = 0.9$ .

Kombinované množství případu pro obě podmnožiny je tedy složeno ze dvou pozorování, tedy

$$m(X_1) = m_1(X_1) m_2(X_2) + m_1(X_1) m_2(\Theta) = 0.6 * 0.9 + 0.6 * 0.1 = 0.6$$

$$m(X_2) = m_2(X_2) m_1(\Theta) = 0.9 * 0.4 = 0.36$$

$$m(\{\Theta\}) = m_1(\{\Theta\}) m_2(\{\Theta\}) = 0.4 * 0.1 = 0.04$$

Pozorované jevy tedy zvýšili naši znalost o prostředí, zpřesnili odhady podmnožin  $X_1$  a  $X_2$ , jejichž věrohodnost pozorované jevy podporují. Neznalost ale stále není nulová.

V Dempsterově-Shaferově teorii tedy nacházíme v pojmu množství případu analogii s podmíněnou pravděpodobností, nicméně uvedená teorie je obecnější. Podmíněná pravděpodobnost přiřazuje každé hypotéze nějakou pravděpodobnost a to i v případě, že nemáme k dispozici žádnou apriorní informaci. V takovém případě považujeme všechny hypotézy za stejně pravděpodobné a platí pro ně, že

$$\sum_i P(q_i) = 1$$

(11)

Pro dichotomii pak pro pravděpodobnost hypotézy  $q_i$  dostaneme

$$P(q_i) = 1 - P(\sim q_i)$$

(12)

Dempsterova-Shaferova teorie tyto v praxi často omezující podmínky nevyžaduje a umožňuje tak pracovat i s neznalostí.

### 1.7.3 Fuzzy množiny

V reálném světě se často snažíme vyjádřit příslušnost daného objektu k nějaké třídě. Uvažujme například člověka. Často použijeme výraz, že tento člověk je například velmi malý, velký, vysoký nebo velmi tlustý. Určitě může být člověk malý a současně spíše tlustý, tedy patřit do více tříd s různou třídou příslušnosti. Nedefinujeme přesně, kolik centimetrů představuje výraz malý, kolik kilogramů tlustý.

Fuzzy množiny řeší přiřazení objektu  $x$  do dané třídy tzv. mírou (funkcí) příslušností  $A(x)$  do té které množiny  $A$  (například tlustých lidí), obvykle v intervalu  $\langle 0,1 \rangle$ .

Fuzzy množina  $A$  je tedy v univerzu  $U = \{x\}$  rovna množině dvojic

$$A = \{(A(x_1), x_1), (A(x_2), x_2), \dots, (A(x_n), x_n)\}$$

(13)

Nad fuzzy množinami  $A$  a  $B$  jsou definovány operace, které s nimi umožňují pracovat. Mezi základní patří

Doplněk	$A'(x) = 1 - A(x)$
Sjednocení	$(A \cup B)(x) = \max(A(x), B(x)) = A(x) \vee B(x)$
Odvážné sjednocení	$(A \sqcup B)(x) = 1 \wedge (A(x) + B(x)) = A(x) \oplus B(x)$
Průnik	$(A \cap B)(x) = \min(A(x), B(x)) = A(x) \wedge B(x)$
Odvážný průnik	$(A \sqcap B)(x) = 0 \vee \max(A(x) + B(x) - 1) = A(x) \otimes B(x)$
Koncentrace	$\text{con}(A)(x) = A^2(x)$
Dilatace	$\text{dil}(A)(x) = 2A(x) - (A(x))^2$

**Tab. 2** Operace nad fuzzy množinami (podle [1]).

Operace slouží k vytváření nových fuzzy množin. Je tedy možné získat například novou fuzzy množinu malých tlustých lidí tak, že vypočteme průnik těchto množin. Použití operátorů koncentrace a dilatace na fuzzy množinu vysokých lidí lze zase chápat jako vytváření množiny skutečně vysokých lidí (con), případně lidí spíše vysokých (dil).

Fuzzy logika nám tedy pomocí operací a fuzzy množin umožňuje deklarovat pravidla mlhavě.

Opět zopakujme pravidlo platné v produkčních ES systémech (1), tedy

$$\frac{p, p \Rightarrow q}{q}$$

Jak předpoklady  $p$ , tak závěry  $q$  můžeme modelovat jako fuzzy množiny. Předpokládejme, že nastal nějaký jev, který jsme pozorovali a vložili konkrétní hodnotu popisující tento jev do ES jako nový fakt. Tento fakt může patřit do několika předpokladů  $p$  a to vždy s různou mírou příslušnosti k danému faktu. Tedy i platnost různých závěrů  $q$  je mlhavá, definovaná různou mírou příslušnosti k dané hypotéze. Tedy v případě, že máme například teplotu zvýšenou na 38 °C, ES nám může poradit užít paralen s vysokou mírou příslušnosti, ale stejně tak nám může doporučit, snad s nižší mírou příslušnosti, odcestovat na severní pól.

V konečné fázi rozhodování tak expertní systém využívající fuzzy logiku dospěje do fáze, kdy musí provést defuzzifikaci, tedy převod mlhavých závěrů na konkrétní akci. Může se jednat o výběr jedné nejpravděpodobnější hypotézy (např. dle maxima míry příslušnosti). Může se také jednat o odvození konkrétní hodnoty z nejasných závěrů, kdy například po zvážení všech odlišných faktů dospěje autopilot letadla k závěrům, že má současně spíše (konkrétně dáno funkcí příslušnosti) ubrat plyn, nejlépe ponechat plyn beze změny a současně i plyn velmi silně přidat. Výsledkem ale musí být jedna hodnota, tedy například změň plyn o daný počet procent. V tomto případě je možné postupovat

například pomocí výpočtu těžiště plochy pod funkcemi příslušností splněných závěrů. Zde by tedy výsledkem defuzzifikace bylo pravděpodobně částečné přidání plynu, například o 10%.

## 1.8 Seznam použité literatury

- [1] Provazník, I., Kozumplík, J. (1999): "Expert Systems", VUT Brno, 101 p., ISBN 80-214-1486-3.
- [2] Dvořák, J. Expertní systémy. Učební text VUT v Brně, fakulta strojního inženýrství.  
[URL:http://www.uai.fme.vutbr.cz/~jdvorak/Opory/ExpertniSystemy.pdf](http://www.uai.fme.vutbr.cz/~jdvorak/Opory/ExpertniSystemy.pdf).
- [3] Berka, P. a kol. Expertní systémy. Skripta. Praha, VŠE 1998.
- [4] ZVÁROVÁ, J. Základy statistiky pro biomedicínské obory I. Praha: Karolinum, 1998. 218 s. ISBN 80-7184-786-0.