

České vysoké učení technické
Fakulta dopravní

Czech Technical University
Faculty of Transportation Sciences

Využití mentálních modelů v modelování dopravy

The application of mental models in transportation modelling

Summary

The presentation deals with problems of mental models of transportation processes and especially with novel tools, methods and theories applicable within this field; which were published by author within the last years. The need of novel approaches to modelling of transportation processes is discussed in introducing chapter; especially with respect to credible description of error reactions in critical situations.

The following chapters introduce particular methods, which were developed especially with respect to following needs:

- Problem of composition of multiple experts knowledge and translation between their personal systems of terms.
- Algebraic operations with linguistic variables – peoples usually reason in terms of linguistic variables; nevertheless a number of exact relations described algebraically exist within the area of technique. Transcription of these relations into rule-based representation is strained and unpractical.
- Problems of credibility determining of our conclusions on the base of operations with inaccurate data.
- Theory of membership interval fuzzy sets with unknown shape of membership function described only by upper and lower limit function. This theory can e.g. help in area of modelling of conclusions of decision processes on the base of inaccurate knowledge.

The following methods are introduced for these problems solution: PP2 and AOFULV for algebraic operations with fuzzy linguistic variables. Within the frame of the presentation is discussed problem of heterogeneous data (crisp data, fuzzy numbers and fuzzy linguistic variables) and knowledge (algebraic operations and rules with linguistic variables) description in complex models. Such complex models can be also models of transportation using expert knowledge and modelling also mental processes of particular participants. On the end problem of interval valued fuzzy sets will be outlined.

Souhrn

Přednáška se zabývá problematikou mentálních modelů dopravních procesů a především pak novými nástroji, postupy a teoriemi uplatnitelnými v této oblasti, které autor v uplynulých letech publikoval. V úvodní části je diskutována potřeba nových přístupů k modelování dopravních procesů, především s ohledem na věrné zachycení chybných reakcí v krizových situacích.

Další kapitoly představují jednotlivé metody, které byly vytvářeny především s ohledem na následující potřeby:

- Problém skládání znalostí jednotlivých expertů a převodů mezi jejich personálními soustavami pojmů.
- Algebraické operace s jazykovými proměnnými – lidé obvykle myslí v jazykových proměnných a přitom v oblasti techniky existuje mnoho exaktních vztahů popsaných algebraicky. Převod takovýchto vztahů do podoby pravidel bývá násilný a nepraktický.
- Problematika určování věrohodnosti našich závěrů na základě operací s nepřesnými daty.
- Teorie fuzzy množin s intervalově vymezenou polohou funkce příslušnosti. Tento aparát může např. napomoci v oblasti modelování důsledků rozhodovacích procesů na základě nepřesných znalostí.

Pro řešení uvedených problémů jsou postupně představeny metody PP2 a AOFULV pro algebraické operace s jazykovými proměnnými. V rámci přednášky je diskutována problematika heterogenních popisů dat (crisp data, fuzzy čísla a fuzzy jazykové proměnné) a znalostí (algebraické operace a pravidla nad jazykovými proměnnými) ve složitých modelech. Takovými složitými modely mohou být i modely dopravy využívající expertních znalostí a modelující i mentální pochody jednotlivých účastníků. Na závěr bude načrtnuta problematika intervalově ohodnocených fuzzy množin.

Klíčová slova

Umělá inteligence, fuzzy množiny, mentální modely

Keywords

Artificial intelligence, fuzzy sets, mental models

(C)2003, ISBN

Obsah

1. Modelování dopravy nemůže být nikdy zcela věrohodné bez modelování projevů „lidského faktoru“	6
1.1. Co jsou mentální modely	6
1.2. Jak lidé uvažují o problémech	7
2. Numerické operace nad jazykovými proměnnými	8
2.1. Výpočetní metoda 'Per partes'	8
2.2. Princip algebraických operací s fuzzy lingvistickými proměnnými (AOFULV)	9
2.2.1. Dekompozice vstupních jazykových proměnných	10
2.2.2. Transformace lingvistických hodnot na fuzzy čísla	11
2.2.3. Řešení algebraických operací s fuzzy čísly	12
2.2.4. Agregace výsledných fuzzy čísel (výsledků algebraických operací)	13
2.2.5. Zpětná transformace do lingvistických proměnných	13
2.3. Stručné srovnání metod PP2 a AOFULV	13
3. Heterogenní reprezentace dat a znalostí	15
3.1. Heterogenní popisy	15
3.2. Heterogenní fuzzy modely	16
4. Fuzzy logika intervalů příslušnosti – Membership interval fuzzy logic	18
4.1. Fuzzy problémy	18
4.2. Fuzzy logika intervalů příslušnosti	19
4.3. Některé další vlastnosti fuzzy množin s intervalově vymezenou příslušností	21
4.3.1. Základní vlastnosti fuzzy množin s intervalově vymezenou příslušností	21
5. Na závěr	24

1. Modelování dopravy nemůže být nikdy zcela věrohodné bez modelování projevů „lidského faktoru“

Nadpis této kapitoly shrnuje zásadní problém věrohodného modelování všech typů dopravy a silniční dopravy zvláště. Není možno vytvářet věrohodné modely dopravy bez adekvátních modelů chování jednotlivých lidských účastníků – jejich rozhodovacích procesů, reakcí na situace vznikající v reálném provozu. Popisem mentálních pochodů a rozhodovacích procesů lidských operátorů (především složitých technologických procesů s extrémními bezpečnostními požadavky) se zabývá oblast kognitivních věd zvaná mentální modely. V poslední době se objevilo i mnoho zajímavých výsledků v jiné oblasti kognitivních věd, která se zabývá vznikem programátorských chyb, především pak model procesní kapacity. Tyto dva přístupy, pokud budou vhodně spojeny, mohou napomoci věrohodně modelovat vznik chybných rozhodnutí operátorů – řidičů jako důsledku konkrétní dopravní situace, nikoli předem dané pravděpodobnosti pro konkrétní vozidlo či úsek silnice, jako je tomu dnes. Faktem ale zůstává, že takto vznešené cíle si tento skromný příspěvek neklade. Hlavním cílem předkládané práce je předložit aparát vhodný pro formulaci mentálních modelů nikoli v homogenní podobě (jak bývají tyto modely obvykle formulovány – např. pomocí fuzzy pravidel), ale v podobě heterogenní, mísící vágní i precisní vztahy, která se mnohem více blíží skutečnému lidskému uvažování.

1.1. Co jsou mentální modely

Existuje mnoho oblastí techniky, kde potřebujeme zachytit či popsat, jak uvažují lidští operátoři. Tyto oblasti se nedají shrnout jen pod problematiku modelování rozhraní člověk stroj. Popis mentálních modelů lidských operátorů potřebujeme i v takových oblastech, jako je modelování myšlenkových pochodů operátorů složitých technologických a technických systémů (např. operátorů chemických výroby, jaderných elektráren, ale i složitých dopravních systémů) za účelem analýzy jejich modelů řízeného systému a odhadu rizika vzniku chybných rozhodnutí, odstraňování podmínek, které vznik chybných rozhodnutí umožňují. Někdy ani není jiné cesty jak modelovat složité systémy, než využívat znalostí jejich obsluh o chování těchto systémů – expertních znalostí. Zvláště v modelování silničních dopravních systémů se neobejdeme bez modelování rozhodovacích procesů řidičů. Nejvěrnějším modelem silniční dopravy je totiž tzv. mikroskopická simulace, tedy simulace dopravy jako modelu pohybu jednotlivých vozidel po silniční síti a interakcí mezi nimi. Tím se odlišuje od

makroskopické simulace, která simuluje dopravu na základě hydrodynamické analogie dopravního proudu, tedy bez zohledňování pohybu jednotlivých konkrétních vozidel. Při známé skladbě dopravního proudu a znalosti technických parametrů jednotlivých vozidel je zásadním problémem mikroskopické simulace věrné modelování rozhodovacích procesů jednotlivých řidičů včetně věrohodné produkce chybných rozhodnutí, která vedle psychologických vlastností řidiče (cholerik, sangvinik,...) záleží i na konkrétní dopravní situaci.

Oblast analýzy a získávání mentálních modelů má hlubokou souvislost s mnoha oblastmi umělé inteligence, kognitivních věd, psychologie, nebo třeba i semiotiky a je z tohoto důvodu poměrně obtížně uchopitelná. Už jen proto, že uvedené disciplíny dosud nenalezly společnou řeč, společné termíny a přístupy. Protože oblast mentálních modelů má velký význam pro praxi, bývá i poměrně často studována. Namátkou lze zmínit práci (Schryver).

1.2. Jak lidé uvažují o problémech

V této stati je zapotřebí na prvním místě analyzovat jakého typu jsou úlohy řešené řidiči, strojvedoucími, piloty (nebo kapitány plavidel). Pokud pomineme exekutivní úroveň založenou na stereotypech, je možné rozdělit jejich činnost do dvou základních skupin. V první skupině jsou úlohy operativního řízení, tedy činnosti spojené s udržením vozidla v požadovaném směru a pod. Můžeme také hovořit o taktickém rozhodování. V druhé skupině jsou takové operace jako je výběr dalšího směru jízdy na křižovatkách. Ještě komplexnějšími jsou v této druhé kategorii úlohy z oblasti strategického řízení, například plánování cesty, složité scénáře činností a komplexní rozhodovací problémy.

Problémem prezentované kategorizace je jeho relativnost daná mechanismem lidského učení. Úlohy, které zkušený řidič řeší aktivací stereotypů, taktického řízení, spadají u nováčků do druhé skupiny a musejí být řešeny pomocí komplexnějších a pomalejších mechanismů, typicky pomocí abstraktního myšlení. Například. navigace ve městě je pro zkušeného řidiče, který jím projíždí pravidelně otázkou příslušných stereotypů.

Pokud analyzujeme vlastnosti lidských řidičů a pilotů, tak také musíme hovořit o problému horizontu, a to hned ve dvou smyslech. První horizont je fyzikální. Je dán limitací lidských sensorů a okolním prostředím (viditelnost, zastínění budovami a terénními překážkami atd.). Druhý horizont je v lidské mysli. Nejde jen o problematiku zužování zorného pole s rostoucí rychlostí pohybu. Možná ještě závažnějším omezením lidského mozku je omezení procesní kapacity, které vedle notoricky známého omezení krátkodobé paměti (na němž jsou založeny snad všechny tzv. metriky software) také omezuje počet paralelně sledovaných dějů a tudíž vede i fatálním důsledkům např. v hustém provozu, kdy řidiči již nejsou schopni registrovat veškeré paralelní podněty a adekvátně na ně reagovat (Halford and McCaredden).

Při vytváření mentálních modelů účastníků dopravního procesu si musíme uvědomit, že se na těchto procesech podílí (především v případě silniční dopravy) značná část populace, jejíž výcvik, znalosti, povahové vlastnosti a další parametry chování nejsou zdaleka tak uniformní, jako v případě např. pilotů, nebo operátorů jaderných elektráren (nejčastěji modelovaných subjektů). To znamená, že na jedné straně hrozí nebezpečí příliš rozsáhlých a komplikovaných modelů, které bude nákladné a obtížné vytvářet, spravovat a používat, na druhé straně pak jakékoli zevšeobecňování a průměrování s sebou nese riziko ztráty vypovídací hodnoty (především ve vztahu věrně mapovat kritické situace). Rozsáhlost modelů mentálních procesů účastníků dopravy nás rovněž staví před problém slučování znalostí více expertů. Je si třeba uvědomit, že doprava má v mnoha aspektech charakter tzv. měkkého systému a tedy chápání mnoha termínů bývá subjektivní. Z uvedeného také vyplývá, že v oblasti modelování dopravních procesů bývá vedle predikované hodnoty podstatná i znalost její věrohodnosti, možné odchylky skutečné situace od této predikované hodnoty. Je tedy třeba používat takový aparát, který dovolí popsat neurčitost hodnot odvozených z našich (mentálních) modelů.

Ve své práci se pokouším představit některé netradiční přístupy vhodné pro popis mentálních modelů a zohledňující nejen výše popsané požadavky, ale i např. problém heterogenních popisů modelů, kdy jsou kombinována pravidla s algebraickými vztahy a data s různým typem popisu fuzzy neurčitosti (crisp, fuzzy čísla, lingvistické fuzzy proměnné).

2. Numerické operace nad jazykovými proměnnými

Vzhledem k omezené upotřebitelnosti fuzzy čísel pro účely simulace heterogenních systémů a pravidlových systémů všeobecně je nutno nalézt metodu, která by dovolila provádět numerické operace (jako to dovolují fuzzy čísla), ovšem nad jazykovými proměnnými. Tyto operace by dovolily vedle vlastního výpočtu nejjistější hodnoty výsledku i mapovat narůstající neurčitost určení správného výsledku a v případě simulačního programu by dovolily i odhadnout dobu predikce, po kterou má smysl důvěřovat výsledkům simulace. Předkládanou metodu jsme společně s Prof. Bílou představil v (Bíla, Brandejský 1995) a podrobněji jsem ji rozvedl v (Brandejský 1997).

2.1. Výpočetní metoda 'Per partes'

Představená metoda je založena na klasických operacích s jazykovými proměnnými a hodnotami. Její název Per partes není odvozen od metody algebraického řešení integrálů, ale je narážkou na rozklad, který tato metoda využívá.

Základem metody je následující dekompozice jazykové proměnné:

Věta 1: Necht' je jazyková proměnná A definována jako $A = \left\{ \frac{\mu_i}{U_i} \right\}$ a

$U = \bigcup U_i$ je konečná množina fuzzy množin U_i . Pak rozklad /1/ je korektní:

$$A = \left\{ \frac{\mu_1}{U_1}, \mathbf{K}, \frac{\mu_n}{U_n} \right\} = \left\{ \frac{\mu_1}{U_1}, \frac{\mu_2}{U_2}, \frac{0}{U_3}, \mathbf{K}, \frac{0}{U_n} \right\} \mathbf{YK} \mathbf{Y} \left\{ \frac{0}{U_1}, \mathbf{K}, \frac{0}{U_{n-2}}, \frac{\mu_{n-1}}{U_{n-1}}, \frac{\mu_n}{U_n} \right\} /1/$$

Rovněž tuto ekvivalenci můžeme zapsat jako /2/:

$$A = \mathbf{Y}_{k=2}^n \left\{ \frac{0}{U_1}, \mathbf{K}, \frac{0}{U_{k-2}}, \frac{\mu_{k-1}}{U_{k-1}}, \frac{\mu_k}{U_k}, \frac{0}{U_{k+1}}, \mathbf{K}, \frac{0}{U_n} \right\} /2/$$

Tato dekompozice je evidentně zcela korektní a můžeme ji bez obav využít. Podstatou metody je pak předpoklad, že můžeme vypočítat jazykovou proměnnou A z jazykových proměnných B a C svázaných algebraickou operací Θ (tedy například $A = B \Theta C$) pomocí vzorce /9/. Tento vztah je postaven na předpokladu, že budeme daleko blíže správnému výsledku, když na místo defuzzifikace argumentů a následné fuzzifikace výsledku reálné operace použijeme uvedený rozklad /7/ a defuzzifikaci, reálnou operaci a fuzzifikaci použijeme na každý element kartézského součinu uvedených rozkládá argumentů. Je zřejmé, že produktem defuzzifikace a dané operace již nemůže být reálné číslo, ale musí jim být singleton, jehož reálná složka je rovna produktu dané reálné operace a příslušnost je rovna menší z příslušností k uvažovaným prvkům rozkladů jazykových proměnných. Příslušnost k danému prvku rozkladu (dvojici jazykových hodnot) je hodnota příslušnosti té jazykové hodnoty z uvažovaného páru, která má vyšší hodnotu příslušnosti. Toto dosti pesimistické pravidlo (bylo by možno definovat i optimističtější, avšak výpočetně náročnější) plyne ze známého kompozičního pravidla.

$$A = \mathbf{Y}_j \mathbf{Y}_k F_A \left(\frac{(\mu(B_{j-1}) \vee \mu(B_j)) \wedge (\mu(C_{k-1}) \vee \mu(C_k))}{D(B_j) \Theta D(C_k)} \right) /3/$$

Je samozřejmé, že se tato metoda může použít i pro obecně n -rozměrný případ, kde $n \geq 1$, ne jen striktně $n=2$, jak je zachyceno v /9/. Případ $n=1$ je výhodný pro transformace mezi odlišně definovanými jazykovými hodnotami nesoucími tentýž fyzikální význam. Ostatní pro řešení vícerozměrných algebraických operací.

2.2. Princip algebraických operací s fuzzy lingvistickými proměnnými (AOFULV)

Základní myšlenkou algebraických operací s fuzzy lingvistickými proměnnými je, že pokud nemůžeme provádět tyto operace s celými jazykovými

proměnnými (pokud neuvažujeme v kapitole 2.1 popsanou metodu per-partes), můžeme nicméně uskutečnit tyto operace s jednotlivými jazykovými hodnotami. To je dáno tím, že unifikace jednotlivých lingvistických hodnot tvoří nekonvexní fuzzy číslo (obecně), ale jednotlivé dílčí funkce příslušnosti (popisující význam jednotlivých jazykových hodnot) jsou obvykle konvexní a tudíž akceptovatelné pro uskutečňování numerických operací ve smyslu operací s fuzzy čísly.

Metoda AOFULV se skládá z následujících kroků:

- Dekompozice vstupních (nezávislých) lingvistických proměnných na Kartézský součin lingvistických hodnot těchto vstupních proměnných.
- Transformace jednotlivých lingvistických hodnot na fuzzy čísla.
- Výpočet algebraických operací s těmito fuzzy čísly.
- Agregace výsledných fuzzy čísel (výsledků algebraických operací s jednotlivými prvky kartézského součinu).
- Zpětná transformace do výstupních (závislých) lingvistických proměnných.

Tyto kroky můžeme sumarizovat do rovnice /4/

$$\mu_k^R = \max \left\{ f_k^R \cap \left[\Theta \left(f \left(K(e_1, \dots, e_m) \right) \right) \right] * \min \left\{ \mu \left[K(e_1, \dots, e_m) \right] \right\} \right\} \quad /4/$$

kde

μ_k^R je míra příslušnosti výsledku ke k-té lingvistické hodnotě výsledné proměnné R

f_k^R je funkce příslušnosti k-té lingvistické hodnoty proměnné R

Θ je vykonávaná algebraická operace

$K(e_1, \dots, e_n)$ je kartézský součin $e_1 \times \dots \times e_n$

e_k je e-tá lingvistická hodnota k-té lingvistické proměnné

μ je příslušnost pozorování k odpovídajícím lingvistickým hodnotám

2.2.1. Dekompozice vstupních jazykových proměnných

Tato část popisuje první dva kroky představované metody: dekompozici vstupních lingvistických proměnných a vytvoření kartézského součinu jednotlivých lingvistických hodnot vstupních proměnných.

Definice.2: Nechť je dána funkce q s argumenty $q(a_1, \dots, a_n)$. Argumenty a_i jsou lingvistické proměnné s příslušnými lingvistickými hodnotami a_i^j . Tudíž kartézský součin C je n-dimenzionální a my můžeme psát $C = a_1 \times \dots \times a_n$ a prvek C je $\{a_1^{j_1}, \dots, a_n^{j_n}\}$.

Vysvětlení 3: Kartézský součin C obsahuje $j_1 * \dots * j_n$ vzájemně různých prvků. Lingvistické hodnoty daných lingvistických proměnných dávají

$j_1 * \dots * j_n$ kombinací, pokud každá kombinace obsahuje pouze jednu jazykovou hodnotu z každé proměnné. Tudíž kartézský součin C obsahuje všechny a jen všechny kombinace lingvistických hodnot argumentů (lingvistických proměnných).

Příklad 1: Uvažujme trojrozměrný případ $z = f(x, y)$. Lingvistické proměnné x, y, z jsou dány jako /5/, /6/, /7/:

$$X = \left\{ \frac{\mu_1^X}{V_1^X}, \frac{\mu_2^X}{V_2^X}, \frac{\mu_3^X}{V_3^X} \right\} \quad /5/$$

$$Y = \left\{ \frac{\mu_1^Y}{V_1^Y}, \frac{\mu_2^Y}{V_2^Y}, \frac{\mu_3^Y}{V_3^Y}, \frac{\mu_4^Y}{V_4^Y} \right\} \quad /6/$$

$$Z = \left\{ \frac{\mu_1^Z}{V_1^Z}, \frac{\mu_2^Z}{V_2^Z}, \frac{\mu_3^Z}{V_3^Z}, \frac{\mu_4^Z}{V_4^Z}, \frac{\mu_5^Z}{V_5^Z} \right\} \quad /7/$$

Kartézský součin C je z definice.2:

$$C = X \times Y = \left(\left(\frac{\mu_1^X}{V_1^X}, \frac{\mu_1^Y}{V_1^Y} \right), \dots, \left(\frac{\mu_3^X}{V_3^X}, \frac{\mu_4^Y}{V_4^Y} \right) \right) \quad /8/$$

2.2.2. Transformace lingvistických hodnot na fuzzy čísla

Existuje mnoho metod provádění výpočtů s lingvistickými proměnnými. Základní, či spíše nejjednodušší, je založena na defuzzifikaci, provedení požadovaných algebraických operací s takto získanými reálnými čísly a zpětné fuzzifikaci. Hlavní nevýhodou této metody je úplná ztráta informace o distribuci neurčitosti. Tudíž tato metoda je vhodná (a jednoduchá v použití) v situacích, kde lingvistické proměnné zobrazují tzv. crisp data – reálná čísla.

Naopak v situacích, kde je zapotřebí zachovat informaci o distribuci neurčitosti, existují přinejmenším tři možné cesty. Především z řídicích aplikací je dobře známa metoda založená na přepisu algebraických relací do fuzzy pravidel. Hlavní nevýhodou této metody je závislost systému pravidel na definici lingvistických proměnných a hodnot (argumentů) a potřeba navrhnout strukturu výsledné lingvistické proměnné na základě struktury fuzzy pravidel (požadované algebraické operace). Tedy pokud měníte operaci, musíte také změnit vedle vlastních pravidel i strukturu výsledné proměnné.

Druhou možností je jednoduchá metoda počítání s lingvistickými proměnnými, kterou jsem navrhl, a která je popsána v předchozí kapitole.

V této kapitole prezentovaná metoda užívá transformaci funkcí příslušnosti jazykových hodnot a odpovídajících příslušností k této lingvistické hodnotě do fuzzy čísla. Fuzzy čísla jsou nejlepším způsobem provádění algebraických

operací z hlediska uchování informace o distribuci neurčitosti. Agregace informace ve funkci příslušnosti a v příslušnosti k jazykové hodnotě je založena na aplikaci T-normy. Ve všech uvedených příkladech je užitá T-norma ve tvaru multiplikace, tedy /9/:

$$\forall x \in U : \mu_n(x) = \mu_f(x) * \mu, \quad /9/$$

kde

μ_n je funkce příslušnosti vytvářeného fuzzy čísla

μ_f je funkce příslušnosti transformované lingvistické hodnoty

μ je příslušnost k transformované lingvistické hodnotě

2.2.3. Řešení algebraických operací s fuzzy čísly

Metody založené na aplikaci fuzzy čísel mívají určitá omezení. Především dokáží pracovat pouze s konvexními fuzzy čísly, tedy funkce příslušnosti vytvořená v předchozím kroku výpočtu musí být za všech okolností konvexní!

Věta 4: Necht' je dána funkce příslušnosti lingvistické hodnoty μ_f , příslušnost k této lingvistické hodnotě μ a T-norma T . Pak funkce příslušnosti μ_n vyjádřená vztahem /21/ je konvexní, pokud funkce příslušnosti μ_f je konvexní.

Důkaz 5: Necht' je T-norma definována jako /10/ až /14/:

$$t(0,0) = 0 \quad /10/$$

$$t(a,1) = t(1,a) = a \quad /11/$$

$$t(a,b) \leq t(c,d) \text{ pro } a \leq b; c \leq d; a \leq c \quad /12/$$

$$t(a,b) = t(b,a) \quad /13/$$

$$t(a,t(b,c)) = t(t(a,b),c) \quad /14/$$

a konvexní fuzzy funkce příslušnosti je popsána jako:

$$\forall \lambda \in \langle 0,1 \rangle : A(\lambda x + (1-\lambda)y) \geq A(x) \wedge A(y) \quad /15/$$

Pak pokud T transformuje konvexní funkci příslušnosti μ_f na nekonvexní funkci příslušnosti μ_n , tak T musí splňovat podmínku $\exists k,l,m : k < l < m, K(k,\mu) > K(l,\mu), K(l,\mu) < K(m,\mu)$. Tento předpoklad je v rozporu s podmínkou monotónnosti /11/. Výsledná množina je tedy konvexní.

Použití fuzzy čísel v představované metodě přináší určitá omezení na množinu přijatelných operací, shodná s omezeními při klasických operacích s fuzzy čísly.

Věta 6: Necht' symbol Θ představuje ve zkoumané metodě násobení. Pak existuje jednotkový prvek ve tvaru lingvistické proměnné s jedinou lingvistickou hodnotou s nenulovou příslušností, jejíž funkce příslušnosti je definována jako singleton v bodě 1 s příslušností 1.

Věta 7: Necht' symbol Θ představuje ve zkoumané metodě sčítání. Pak existuje nulový prvek ve tvaru lingvistické proměnné s jedinou lingvistickou hodnotou s nenulovou příslušností, jejíž funkce příslušnosti je definována jako singleton v bodě 0 s příslušností 1.

2.2.4. Agregace výsledných fuzzy čísel (výsledků algebraických operací)

Následujícím krokem metody AOFULV je agregace dílčích výsledků. Metoda užívá agregaci před projekcí do výsledné proměnné (Brandejský a kol.1999). To je v protikladu k předchozí metodě (Bíla a Brandejský 1995) a k metodám založeným na přepisu algebraických operací do soustavy fuzzy pravidel, které užívají opačné pořadí. Užití agregace dílčích výsledků před závěrečnou projekcí je lepší, protože některé dílčí výsledky se mohou navzájem podpořit a tudíž snížit informační ztráty způsobené konečnou retransformací do vyjádření pomocí lingvistických proměnných (granularizací).

2.2.5. Zpětná transformace do lingvistických proměnných

Metoda AOFULV užívá zpětné transformace ve formě lingvistické podobnosti funkce příslušnosti lingvistické hodnoty, jejíž příslušnost je počítána, a průniku této funkce s agregovanou funkcí příslušnosti vypočítanou v předchozím kroku. Existuje velké množství metod výpočtu lingvistické podobnosti. Představovaná metoda užívá výpočet podobnosti ve tvaru

$$\mu : \max(\mu_u \cap \mu_r) , \quad /16/$$

kde

μ představuje výsledná příslušnost dílčí lingvistické hodnoty

μ_n označuje funkci příslušnosti dané lingvistické hodnoty

μ_r je unifikace dílčích výsledků algebraických operací – fuzzy čísel

Aplikace definované metody AOFULV zlepšuje výpočetní efektivitu v případě problémů které by mohly být popsány pomocí rozsáhlých soustav pravidel.

2.3. Stručné srovnání metod PP2 a AOFULV

Obě právě vyvíjené metody slouží k uskutečňování algebraických operací s fuzzy lingvistickými proměnnými. Návrh obou metod jsem byl veden snahou o maximálně věrohodné mapování distribuce neurčitosti. Metoda PP2 je historicky starší a vychází z přístupu dalo by se říci Sugenovského, přesněji je založena na aplikaci singletonů. Tato metoda je výpočetně nenáročná a snadno aplikovatelná.

Později navržená metoda AOFULV vychází z teorie fuzzy čísel, která není z objektivních důvodů možno přímo použít pro uskutečňování algebraických operací s fuzzy lingvistickými proměnnými. Tato metoda je výpočetně náročnější, vzhledem k nezbytnosti použití míry podobnosti fuzzy množin je i méně přehledná. Na druhé straně nabízí zřejmě nejlepší možné zachování informace o distribuci neurčitosti ve svých argumentech.

Z hlediska simulačních aplikací bývá zásadní otázkou stabilita metody. Pro takováto použití je třeba předeslat, že ani metoda PP2, ani AOFULV nemají implementováno ošetření integrace proměnných s omezeným rozsahem. To znamená, že v takových případech, jako je hromada kamení z příkladu 2 nelze očekávat, že by se výsledek mohl ustálit na nenulové příslušnosti k jazykové hodnotě malá při nulových příslušnostech ke zbývajícím hodnotám střední a velká. Naopak výsledek bude vždy směřovat do situace, kdy všechny příslušnosti budou nulové.

Klesání celkového množství informace o systému má i druhý důvod. Tím jsou chyby způsobené granulací informace, viz (Pedrycz1999a). Při každém převodu výsledku algebraické operace do vyjádření pomocí jazykových proměnných v metodě AOFULV, nebo dokonce již při vytváření singletonů v metodě PP2 je ztracena určitá část informace o distribuci neurčitosti, což se projevuje v těchto metodách postupným poklesem součtu všech příslušností k jazykovým hodnotám stavové proměnné.

Z uvedeného také vyplývá, že je omezen celkový počet algebraických operací, které můžeme uskutečnit. Je výhodné provádět co nejkompaktnější operace, aby byl minimální počet volání uvedených metod (a tedy prováděných granulací). To v případě integrace stavových proměnných limituje délku predikce.

Rovněž je zajímavé, že numerická stabilita je lepší u méně přesné metody PP2, než u metody AOFULV, což je evidentně způsobeno jednodušším výpočtem – nižším počtem numerických operací a tedy i menšími akumulovanými numerickými chybami.

3. Heterogenní reprezentace dat a znalostí

V procesu návrhu technických systémů inženýři často začínají svoji práci s velmi vágními specifikacemi struktury a funkce vyvíjeného zařízení. Obecně můžeme tvrdit, že neurčitost informace o navrhovaném systému v průběhu návrhového procesu klesá, pokud pomineme momenty, kdy jsou rozpoznány určité rozpory či neřešitelné situace a je nutné se vrátit v návrhovém procesu o několik kroků zpět a revidovat předchozí rozhodnutí.

Hlavním rozdílem mezi fuzzy-numerickou simulací známou s oblasti obecné simulace dynamických systémů a fuzzy-numerickou simulací pro podporu procesu konceptuálního designu je potřeba uchování informace o neurčitosti v celém průběhu simulace za účelem zobrazení vlivů těchto neurčitostí na chování systému, především pak na jeho výstupy. Simulační nástroj pro počítačovou podporu konceptuálního designu (Computer Aided Conceptual Design Support) musí být schopen pracovat s takovýmito neurčitostmi a musí být schopen provádět shodné operace s neurčitými daty jako s přesnými numerickými (crisp) daty bez vyjádření neurčitosti, a to bez ztráty informace o charakteru a míře neurčitosti. To znamená, že takový systém musí být schopen kombinovat crisp a neurčitostí zatížená data (především pro takové typy neurčitosti, jaké jsou produktem neúplnosti modelu navrhovaného zařízení/systému). Takovým typem neurčitosti je především fuzzy (posibilistická) neurčitost, jejíž popis může být rovněž použit pro reprezentaci intervalů možných hodnot, jak je známe např. z kvalitativní simulace.

3.1. Heterogenní popisy

Funkce navrhovaného systému může být popsána nejen ve tvaru algebraických rovnic, ale rovněž ve pomoci fuzzy pravidel. Podobně parametry a počáteční podmínky simulace musíme uvažovat minimálně ve třech tvarech – crisp data, fuzzy čísla a fuzzy lingvistické proměnné.

Tudíž musíme řešit čtyři základní případy: crisp data - algebraické rovnice, crisp data - fuzzy pravidla, fuzzy data - fuzzy pravidla, fuzzy data – algebraické operace a jejich kombinace. Musíme rovněž rozlišovat mezi fuzzy daty ve tvaru předdefinovaných fuzzy lingvistických proměnných a fuzzy daty ve tvaru fuzzy čísel (která mají obecně dynamickou strukturu). **Tabulka 1** představuje základní metody aplikovatelné pro řešení každé kombinace:

Operace \ Data	Crisp	Fuzzy čísla	Fuzzy lingvistické proměnné
Algebraické operace	Numerická matematika	Oprace s fuzzy čísla	Metoda AOFULV
Pravidla	Fuzzyfikace fuzzy pravidla Defuzzyfikace	Uvažování založené na podobnosti	Fuzzy pravidla

Tabulka 1: Základní metody aplikovatelné pro jednotlivé kombinace popisu operací a dat.

V tabulce 1 můžeme rozpoznat šest základních situací. Tato tabulka samozřejmě může mít mnohem více sloupců, aby bylo možno obsáhnout další typy neurčitosti, například pomocí Intuitionistických fuzzy množin, nebo dále popsaných fuzzy množin s intervalově ohodnocenou příslušností je možno nalézt společný popis fuzzy a pravděpodobnostní neurčitosti. Nicméně použití takovýchto reprezentací již není jednoduché a práce s nimi je komplikovaná. Navíc některé problémy ještě nejsou po teoretické stránce dořešeny.

3.2. Heterogenní fuzzy modely

Můžeme uvažovat dvě základní situace: použití přinejmenším dvou typů popisů operací (algebraického a založeného na pravidlech) a/nebo užití přinejmenším dvou typů popisů dat (např. crisp data a fuzzy čísla). Použití obou typů popisu operací je možné pro jakýkoli typ dat, nám tedy nezbyvá, než v této chvíli studovat jednotlivé kombinace typů dat za účelem nalezení univerzálního popisu dat včetně neurčitých. S výběrem omezeným na typy popsané v **Tabulce 1** můžeme analyzovat následující základní kombinace typů popisu dat:

- Kombinace crisp dat a fuzzy čísel nepřináší žádné problémy, protože můžeme zobrazit crisp data jako singletony s příslušností rovnou jedné a pozicí ekvivalentní hodnotě crisp dat. Tato transformace nepřináší žádnou novou neurčitost. Na druhé straně opačná transformace je problematická, protože je spojena se ztrátou veškeré informace o (fuzzy) neurčitosti.
- Kombinace crisp dat a fuzzy lingvistických proměnných je řešitelná přes fuzzifikaci crisp dat reprezentace pomocí fuzzy lingvistických proměnných se všemi problémy zmiňovanými výše, neboť při této transformaci je doplňována původně v crisp datech neobsažená informace.
- Kombinace fuzzy čísel a fuzzy lingvistických proměnných může být řešena transformací fuzzy lingvistických proměnných do reprezentace pomocí fuzzy čísel, jak je ostatně použito v metodě AOFULV, ale tato cesta přináší dva základní problémy: Výsledné fuzzy číslo obvykle není konvexní a takováto transformace může dávat různý smysl funkcím příslušnosti originální fuzzy

lingvistické proměnné, jak již bylo uvedeno v předchozí kapitole v souvislosti s metodou AOFULV.

Jedinou univerzální reprezentací jsou fuzzy čísla. Naneštěstí z diskutovaných typů dat fuzzy čísla přinášejí nejkomplikovanější výpočtu v případě algebraicky popsaných operací a problémy s nejednoznačným měřením podobnosti v aplikacích založených na pravidlovém popisu operací.

To znamená, že v případě simulačního nástroje pro konceptuální design a ostatních simulačních nástrojů s heterogenním, algebraickým a pravidlovým popisem modelu je užitečné volit sofistikované výpočetní metody pro každou kombinaci typů dat a přiřazovat ke každé proměnné informaci o aktuálním typu popisu neurčitosti dat.

4. Fuzzy logika intervalů příslušnosti – Membership interval fuzzy logic

Práce v oblasti fuzzy logiky intervalů příslušnosti byly postupně publikovány v těchto publikacích a příspěvcích: (Brandejsky2000a, b), (Brandejsky2001a, b, c, d), (Brandejsky2002).

4.1. Fuzzy problémy

Teorie fuzzy množin bezesporu představuje významný posun přístupu k regulaci, srovnatelný s objevením stavového prostoru. Fuzzy regulace nicméně ve své současné podobě využívá jen malou část potenciálu fuzzy množin a zpravidla jejich využití omezuje na aproximaci reálných funkcí. Nebývá běžně zvykem vytvářet regulátory, které by „uvažovaly“, že měřené vstupní veličiny jsou zatíženy různými chybami a i když se tváří jako reálná čísla, jsou ve skutečnosti také tak trochu „fuzzy“. Současné regulátory jsou postaveny na reprezentaci znalostí pomocí fuzzy pravidel, která jsou vždy zcela pravdivá, a na pravé straně obvykle mívají singleton (reálné číslo s příslušností, či chcete-li jednoprvkovou fuzzy množinu). Tento přístup plně postačuje pro aproximaci reálných funkcí (i nelineárních), a tedy pro potřeby regulace.

Fuzzy modely bývají mnohdy postaveny na obdobných principech. To reprezentuje jistá úskalí. Jak jsme již zmínili v souvislosti s fuzzy regulací, používáme fuzzy aproximaci. Avšak každá aproximace není ideální popis, ale přidává k němu určitou chybu. Tato chyba (díky stavovému popisu a časovým integracím, na které vede) s dobou simulace zpravidla narůstá. To je významná odlišnost od fuzzy řízení, ve kterém se aproximační chyba projeví jen v aktuálním kroku a v dalším kroku se již vychází z nově změřené skutečné odezvy systému – chyby se tedy nesčítají. V praxi může být výhodné vědět, jak moc se fuzzy modelu dá v dané chvíli „věřit“, jak velkou chybou je zatížen. Na to ovšem nemůže fuzzy teorie odpovědět, neboť se jedná o jiný typ neurčitosti, zpravidla o ignoranci.

Fuzzy znalostní systémy se ještě potýkají s jedním problémem, a tím je zpracování ne zcela pravdivých pravidel. Existuje sice velké množství vzorců, podle kterých můžeme vypočítat pravdivost důsledku implikace, některé z nich zachycuje tab. 2, ale právě v tom množství je skryt zádrhel. Který z nich zvolit? Nebo na tom nezáleží? A jak je možné, že klasická logika vystačí se vztahem jediným?

Odpověď na tyto otázky nemusí být složitá. Každá z těchto implikací je vhodná pro jiné aplikace. Žádná z nich není zcela obecná a univerzální, spíše jsou všechny zjednodušení nějakého neznámého obecnějšího vztahu.

Hlavní problém je patrný právě ze známého vztahu (jeho přepis do pravdivostní tabulky naleznete v tab.3) pro výpočet pravdivosti implikace. Z něho totiž plyne,

pokud se pokusíme vyjádřit závislost pravdivosti důsledku implikace na pravdivosti jejího předpokladu a na pravdivosti implikace samotné, že se v klasické logice vůbec nejedná o funkci, a že se k výsledku přidává, pokud není implikace pravdivá, další typ neurčitosti – ignorance, neboť nejsme schopni získat jednoznačný výsledek. Tato nová neurčitost vzniká nejen v průběhu klasické implikace, ale i v případě fuzzy implikace (a vede ke vzniku velkého množství zjednodušených vzorců).

4.2. Fuzzy logika intervalů příslušnosti

Fuzzy logika intervalů příslušnosti (Membership Interval fuzzy Logic - MIL) představuje algebraické rozšíření teorie fuzzy množin.

Pokud bychom tabulku pravdivosti implikace v situaci $P=0, Q=0$ doplnili pravdivostí C jako 0 or 1 (tedy shodně s druhým řádkem) a přepsali ji pro oblast fuzzy logiky (tedy pro spojitý definiční obor, kde jsou pravdivosti zobrazeny v intervalu $\langle 0,1 \rangle$, pak bychom obdrželi vztah /17/ - tedy alespoň v případě tzv. min-max kalkulu.

$$\begin{aligned} \mu_{\max}^C &= \max(1 - \mu^P, \mu^Q) \\ \mu_{\min}^C &= \min(\mu^P, \mu^Q) \end{aligned} \quad /17/$$

Proč právě takto? Je možno vytvořit velké množství příkladů, kdy na nepravdivý předpoklad použijeme nepravdivou implikaci. Důsledky této implikace budou často nepravdivé, ale ne vždy. Především v situacích, kdy opustíme předpoklad „uzavřeného vesmíru“, tedy v situacích, kdy připustíme, že naše modely nejsou kompletní a kdy mohou zkoumané systémy ovlivňovat i nějaké neznámé, resp. nepopsané, objekty a děje. Vzpomínáte na hodiny matematiky, kde nás učili, jak je tento předpoklad důležitý? Protože když není splněn, vstupuje do hry neurčitost. Pravdivost důsledku pravidla pak již nezávisí jen na pravdivosti předpokladu (a pravdivosti pravidla) a pravidlo pak jen podle situace udává nejoptimističtější, resp. nejpesimističtější odhad výsledku.

Je zajímavé, že výsledkem použití implikace vzniká nový typ neurčitosti zvaný ignorance. Ještě mnohem zajímavější je otázka, zda je možno z intervalů možných příslušností zkonstruovat logický systém, a zda, pokud aplikujeme implikaci na data zatížená tímto typem neurčitosti, neobdržíme nějaký další typ neurčitosti.

Nejprve bychom ale měli něco říci o intervalovém rozšíření fuzzy množin. V duchu vztahu /17/ můžeme definovat takové fuzzy množiny, u kterých neznáme skutečný tvar funkce příslušnosti, ale zato známe dvě funkce, které shora a zdola ohraničují oblast, ve které funkce příslušnosti určitě musí ležet.

Logický součin je v logice intervalů příslušností v případě min-max kalkulu definován rovnicí /18/:

$$\mu(I \wedge J) = \langle \min(\mu_{\min}^I, \mu_{\min}^J), \min(\mu_{\max}^I, \mu_{\max}^J) \rangle \quad /18/$$

To znamená, že pokud $\mu_{\min} = \mu_{\max}$, tak získáváme vztah známý z fuzzy logiky. Obdobnou vlastnost bude mít i operátor logického součtu a negace.

Logický součet je v logice intervalů příslušností analogicky definován jako /19/:

$$\mu(I \vee J) = \langle \max(\mu_{\min}^I, \mu_{\min}^J), \max(\mu_{\max}^I, \mu_{\max}^J) \rangle \quad /19/$$

Negace je v logice intervalů příslušností definována jako doplněk do 1:

$$\mu(\neg J) = \langle 1 - \mu_{\max}^J, 1 - \mu_{\min}^J \rangle \quad /20/$$

Existuje mnoho způsobů jak odvodit tvar operátoru implikace pro logiku intervalů příslušnosti. Zřejmě nejjednodušší je aplikovat vztah /17/ na minimální a maximální hodnoty předpokladu a důsledku. Po sloučení těchto čtyř dílčích výsledků obdržíme vztah /21/:

$$\begin{aligned} & \mu(P \xrightarrow{Q} C) \\ \mu_{\max}^C &= \max(1 - \mu_{\min}^P, \mu_{\max}^Q) \\ \mu_{\min}^C &= \min(\mu_{\min}^P, \mu_{\min}^Q) \end{aligned} \quad /21/$$

Tím jsme dokázali definovat systém se všemi základními operacemi. Dokonce operace implikace, která způsobovala problémy ve fuzzy logice, produkuje výsledek zatížený stejnými druhy neurčitosti, jakými je zatížen předpoklad a pravdivost implikace.

Pro praktické aplikace jsou potřebné (podobně jako ve fuzzy světě) lingvistické proměnné. Pomocí logiky intervalů příslušnosti je možno definovat analogické jazykové proměnné, které nabývají jazykových hodnot s pravdivostmi z příslušných intervalů. Ovšem zatímco v klasické logice přiřazujeme každé jazykové hodnotě jednu funkci příslušnosti, v logice intervalů příslušnosti musíme každé jazykové hodnotě přiřadit funkce příslušnosti hned dvě. Jednu pro minimální příslušnost a druhou pro maximální. Obdobně jako v případě logických operátorů, pokud jsou minimální a maximální funkce příslušnosti ekvivalentní, zůstáváme u známé definice z fuzzy světa.

Definice 8: Necht' N je jméno lingvistické proměnné, $T(N)$ je její množina lingvistických hodnot (termů), U je universum, G je syntaktické pravidlo generující hodnoty $A \in T(N)$ a S je sémantické pravidlo přiřazující smysl

$S(A) \subseteq U$ každému termu $A \in T(N)$. Pak MIL lingvistická proměnná je popsána vztahem /22/:

$$\langle N, T(N), U, G, S \rangle \quad /22/$$

Fuzzifikace je v logice intervalů příslušnosti definována například jako hodnota funkcí minimální a maximální příslušnosti jednotlivých jazykových hodnot pro argument rovný fuzzifikované hodnotě.

Defuzzifikace může být definována například jako hledání minimální a maximální hodnoty těžiště význačných bodů (těžišť) jednotlivých jazykových hodnot násobených příslušnostmi z jejich intervalů. Obecně představuje defuzzifikace v logice intervalů příslušností optimalizační problém (hledání extrémů), ale v případě, že existují jen dvě jazykové hodnoty, y_1 a y_2 vede na poměrně jednoduchý vztah /23/:

$$\begin{aligned} r_{\min} &= \frac{y_1 \max(\mu_1^y) + y_2 \min(\mu_2^y)}{\max(\mu_1^y) + \min(\mu_2^y)} \\ r_{\max} &= \frac{y_1 \min(\mu_1^y) + y_2 \max(\mu_2^y)}{\min(\mu_1^y) + \max(\mu_2^y)} \end{aligned} \quad /23/$$

4.3. Některé další vlastnosti fuzzy množin s intervalově vymezenou příslušností

Modelování komplexních systémů je obtížné pro jejich komplexnost a nemožnost popsat je přesně bez skrytých nejednoznačností a neúplně definovaných stavů a komponent. Modelování takových systémů je nemožné v rámci klasické numerické matematiky a některé takovéto systémy je nelze dokonce modelovat ani v rámci fuzzy množin.

Existují systémy, např. dopravní, které je možno popsat pouze nepřesně a pak může být užitečné predikovat ne jen konkrétní hodnoty, ale také jejich spolehlivost či věrohodnost. Pro tyto účely mohou být užitečné tak zvané fuzzy množiny s intervalově vymezenou příslušností.

4.3.1. Základní vlastnosti fuzzy množin s intervalově vymezenou příslušností

V práci (Brandejsky2000b) jsou definovány fuzzy množiny s intervalově vymezenou příslušností jako struktura /24/:

$$MIFS = \langle \mu_U, \mu_L, U \rangle, \mu_L \leq \mu_U, \quad /24/$$

kde μ_U označuje horní funkci příslušnosti, μ_L představuje dolní funkci příslušnosti a U označuje universum. Neznámá funkce příslušnosti $\mu(x)$ pak v každém bodu x z U leží uvnitř intervalu $\langle \mu_L, \mu_U \rangle$.

Definice 9: Nosič množiny MIFS je definován jako /25/:

$$s(MIFS) = s(\mu_{MIFS}(u)) = \{u : \mu_{MIFS}(u) > 0.0\} \quad /25/$$

Definice 10: Jádro (core) fuzzy množiny A je definováno jako /26/:

$$c(A) = \{u : \mu(u) = 1.0\} \quad /26/$$

V rámci MIFS musíme užít definici 11 pro neznámý tvar funkce příslušnosti popsané pouze horní a dolní mezí oblasti možného výskytu:

Definice 11: Jádro MIFS leží v rámci mezí daných množinami $c(\mu_L)$ a $c(\mu_U)$.

Věta 12: α -řez množiny MIFS leží mezi hranicemi danými α -řezy μ_L a μ_U . Jádro a nosič jsou zvláštními případy α -řezu pro α rovno 1.0 respektive větší než 0.0.

Protože hranice α -řezu mají v případě konvexní MIFS charakter intervalu a ne bodu jako v případě klasické fuzzy množiny je median množiny MIFS α -cut interval na místo crisp hodnoty (počítáno dle vztahu /27/). Median musí být počítán v případě MIFS z horní funkce příslušnosti na jedné straně a z dolní funkce příslušnosti na straně druhé. MIFS tvar je popsán vztahem /28/.

$$med(A) = [\inf(c(A)) + \sup(c(A))] / 2 \quad /27/$$

$$med(MIFS) = \langle [\inf(c(\mu_U)) + \sup(c(\mu_L))] / 2, [\inf(c(\mu_L)) + \sup(c(\mu_U))] / 2 \rangle \quad /28/$$

Významně odlišný od klasických fuzzy množin je výpočet kardinality množiny MIFS. Pro klasické množiny se běžně používá výpočet podle vztahu /29/. Kardinalita je plocha pod funkcí příslušnosti dané fuzzy množiny. V případě množin MIFS není známa pozice a tvar funkce příslušnosti, protože MIFS definuje pouze její hranice možné polohy ve tvaru horní a dolní funkce příslušnosti. Tudíž kardinalita množiny MIFS je interval možných hodnot.

$$card({}_A \mu(u)) = \int_{u_{\min}}^{u_{\max}} \mu(u) du \quad /29/$$

Hraniční hodnoty intervalu kardinality množiny MIFS jsou tedy vyjádřitelné jako /30/:

$$card(\mu_{MIFS}(u)) = \left\langle \int_{u_{\min}}^{u_{\max}} \mu_L(u) du, \int_{u_{\min}}^{u_{\max}} \mu_U(u) du \right\rangle \quad /30/$$

Fuzziness (rozmazanost) fuzzy množiny A je definována Koskem v práci (Kosko 1992) jako míra fuzzy entropie /31/:

$$fuzz(A) = \frac{card(A \cap \neg A)}{card(A \cup \neg A)} \quad /31/$$

Průnik množin MIFS byl definován jako /18/, sjednocení jako /19/.

Crispness (ostrost) fuzzy množiny A je definována jako /32/:

$$cr(A) = \frac{card(c(A))}{card(s(A))} \quad /32/$$

V případě množiny MIFS nabývá tvaru /33/, protože jak nosič tak jádro jsou definovány s hranicemi ve tvaru intervalů. Tudíž jejich kardinality musejí být rovněž intervaly:

$$cr(MIFS) = \left\langle \frac{card_{\min}(c(A))}{card_{\max}(s(A))}, \frac{card_{\max}(c(A))}{card_{\min}(s(A))} \right\rangle \quad /33/$$

5. Na závěr

Úplné modely dopravních procesů si lze stěží představit bez modelů chování samotných účastníků. Mnohé práce v oblasti mentálních modelů, pokroky kognitivních věd obecně, jakož i rozmach bádání v oblasti neurčitosti začínají v současnosti vytvářet konzistentní systém. To nám dává právě v současnosti šanci tyto úplné modely dopravy uchopit na novém základě, pomocí nových metod a prostředků. Předkládaná práce si nekladla za cíl encyklopedicky zmapovat celý tento prostor, ale spíše ukázat, že některé nové metody mohou být výhodně použity právě (a nejen) v této oblasti.

Literatura

Schryver J. C.: *Object-Oriented Qualitative Simulation of Human Mental Models of Complex Systems*; IEEE Transactions on Systems, Man and Cybernetics, vol. 22, No. 3, str. 526 - 541, 1993

Halford G.S. and McCredden J.E.: Cognitive Science Questions for Cognitive development: the concepts of learning, analogy and capacity. Learning and Instructions, 8, 4, 1998, 289-308.

Bila J. and Brandejsky T.: An Alternative Approach to Theory of Fuzzy Numbers; EUFIT, Aachen, 1995

Brandejský T.: Doktorská disertační práce, "Uplatnění teorie fuzzy množin v kvalitativní simulaci dynamických systémů", ČVUT v Praze, Fakulta strojní, 1997

Brandejsky T., Bila J. and Broz K. (1999): Fuzzy Qualitative Modelling of Distributed

Energy and Heat Supply Complex. Szczerbinska H. (ed.): *Modelling and Simulation: A Tool for The Next Millenium*. SCS, Warsaw, Poland, pp. 391-394.

Pedrycz W.: 1999, Granular Computing for System Modelling, Szczerbinska (ed.): . Szczerbinska H. (ed.): *Modelling and Simulation: A Tool for The Next Millenium*. SCS, Warsaw, Poland, pp. 391-394.

Brandejsky T.(2000)a: Methods of Building Membership Interval Logic Models, Mendel 2000 conf., Brno University of Technology, 238-242

Brandejsky T. (2000)b: Membership Interval Fuzzy Logic Reasoning. *Proceeding east-west fuzzy colloquium 2000*; 8th Zittau Fuzzy Colloquium, September 6-8, 2000, 36-41

Brandejský T. (2001)a: Neurčitý článek v neurřitém světě. *Automatizace*, 7-8, 426-431

Brandejský T. (2001)b: Constrained MIL linguistic variables. Mendel 2001, Brno, VUT, Fakulta Strojní, 260-265.

Brandejský T. (2001)c: Solving of Constrained MIL Linguistic Variables and Relations Networks. 9th Zittau Fuzzy Colloquium. Zittau, Hochschule Zittau/Goerlitz, 2001, 15-20.

Brandejský T. (2001)d: Interval Fuzzy Logic C++ Library Applicable in Expert Systems Building. Inteligentní systémy pro praxi, Luhacovice, AD&M, Ostrava

Brandejský T. (2002): Similarity, distance and some other Behaviors of Membership Interval Fuzzy Sets. 10th Zittau Fuzzy Colloquium 2002, Proceedings 10th Zittau Fuzzy Colloquium 2002, Hochschule Zittau/Goerlitz IPM

Kosko B.(1992)b: Neural Networks and Fuzzy Systems, A Dynamical Systems Approach to Machine Intelligence, Prentice-Hall, Englewood Cliffs, NJ.

Dr. Ing. Tomáš Brandejský

CV odborné

Narozen 27.1.1969. Po absolvování gymnázia v Kolíně vystudoval ČVUT Fakultu strojní obor Automatické řízení a inženýrská informatika. V diplomové práci se zabýval návrhem expertního shellu s celulární architekturou optimalizovaného pro potřeby inteligentních CAD systémů. Produktem odvozeným z této práce bylo vývojové prostředí AutoBASIC, které pracovalo jako nadstavba AutoCADu a které se dočkalo komerčního uplatnění. Již v průběhu studia publikoval mnoho recenzí a článků v časopisu Bajt. V této aktivitě pokračoval i v průběhu doktorandského studia. Doktorandské studium absolvoval u prof. Bílý v oboru technická kybernetika na ČVUT FSI. V rámci doktorského studia pracoval na vývoji fuzzy simulátorů a kvalitativních simulátorů deizobutanizační kolony v a.s. Kaučuk Kralupy, které m.j. popsal ve své doktorské práci. V roce 1998 obhájil doktorskou práci na téma Uplatnění teorie fuzzy množin v kvalitativní simulaci dynamických systémů.

Po studiu pracoval rok u firmy BAJT-servis kde se zabýval návrhem SW systému sběru dat a poté přešel na Fakultu dopravní, kde působí dodnes. Ve svých publikacích a výzkumných zprávách se zabývá především otázkami algebraických operací nad fuzzy jazykovými proměnnými včetně problému fuzzy numerické integrace, teorií fuzzy množin s intervalově ohodnocenou příslušností a oblastí konceptuálního designu systémů.

Na Fakultě dopravní se dále zabývá problematikou posuzování bezpečnosti a spolehlivosti software, především v železničních zabezpečovacích systémech.

V rámci své pedagogické praxe vyučuje předměty Umělá inteligence a expertní systémy, Robotika v dopravě, Bezpečnost software – ADA, Modelování a objektivě orientované programování, Umělá inteligence a expertní systémy 2 a založil na Fakultě Dopravní tyto nové předměty: Umělá inteligence a expertní systémy, Umělá inteligence a expertní systémy 2, Bezpečnost software - ADA, Modelování a objektivě orientované programování