

Mirko Navara, Petr Olšák

# Základy fuzzy množin

Praha, 2001, 2002



Text je šířen volně podle licence <ftp://math.feld.cvut.cz/pub/olsak/fuzzy/licence.txt>.  
Text ve formátech  $\text{\TeX}$  (csplain), PostScript, dvi, PDF najdete na adrese  
<ftp://math.feld.cvut.cz/pub/olsak/fuzzy/>.

Verze textu: 10. 4. 2002

## Obsah

---

<b>1. Základní pojmy</b>	2
1.1. Základní pojmy z teorie množin	2
1.2. Charakteristická funkce	3
1.3. Základní pojmy teorie fuzzy množin	3
1.4. Popis fuzzy množin pomocí řezů	4
1.5. Fuzzy inkluze	8
<b>2. Operace s fuzzy množinami</b>	9
2.1. Ostré množiny	9
2.2. Analogie pro operace s fuzzy množinami	9
2.3. Fuzzy negace	10
2.4. Fuzzy konjunkce (trojúhelníkové normy)	11
2.5. Fuzzy disjunkce (trojúhelníkové konormy)	14
2.6. Fuzzy výrokové algebry	16
2.7. Fuzzy implikace	18
2.8. Fuzzy biimplikace (ekvivalence)	20
2.9. Agregační operátory	20
<b>3. Fuzzy relace</b>	22
3.1. Binární relace v klasické teorii množin	22
3.2. Fuzzifikace binárních relací	23
3.3. Konzistence fuzzy relací	23
3.4. Projekce a cylindrické rozšíření	24
<b>4. Princip rozšíření</b>	25
4.1. Rozšíření binárních relací na ostré množiny	25
4.2. Princip rozšíření binárních relací na fuzzy množiny	26
4.3. Konvexní fuzzy množiny	27
<b>5. Fuzzy čísla a fuzzy intervaly</b>	28
5.1. Zavedení pojmů a základní vlastnosti	28
5.2. Binární operace s fuzzy čísly	28
<b>6. Literatura</b>	30
6.1. Základní	30
6.2. Doplnková	30
<b>7. Rejstřík</b>	31

# 1. Základní pojmy

## 1.1. Základní pojmy z teorie množin

V této kapitole zopakujeme základní skutečnosti z teorie množin, které budeme později zobecňovat. Není zde místo na podrobnou výstavbu základů teorie množin, která bývá často nahrazována intuitivním chápáním pojmu množina. Z předchozích kursů byste měli vědět, že např. ke každé množině  $A$  existuje množina všech jejích podmnožin, budeme ji značit  $\mathcal{P}(A)$ . Zato však neexistuje množina všech množin, neboť takový pojem vede ke sporu. Těmto problémům se snadno vyhneme tak, že se omezíme na studium podmnožin jedné (libovolné, ale pevně dané) tzv. *univerzální množiny* (univerza), kterou budeme značit  $X$ .

Připomeňme některé pojmy:

*Kardinalitou* (též *mohutností*) konečné množiny rozumíme její počet prvků. Zobecnění na nekonečné množiny je obtížnější, ale pro tento kurs není podstatné.

*Kartézský součin* dvou množin  $A, B$ , značíme  $A \times B$ , je množina všech uspořádaných dvojic, v nichž první prvek je z první množiny, druhý z druhé, tedy

$$A \times B = \{(a, b) : a \in A, b \in B\}.$$

Množinové operace průnik a sjednocení můžeme snadno zavést pomocí výrokových operací konjunkce ( $\wedge$ ) a disjunkce ( $\vee$ ).

*Průnik:*  $A \cap B = \{x : (x \in A) \wedge (x \in B)\}$ .

*Sjednocení:*  $A \cup B = \{x : (x \in A) \vee (x \in B)\}$ .

*Doplňkem* množiny  $A$ , značíme  $\overline{A}$ , má být množina všech prvků, které do ní nepatří. Aby taková definice byla korektní, musíme se omezit na prvky univerzální množiny, tedy

$$\overline{A} = \{x : x \in X, x \notin A\}.$$

*Inkluzi* (tj. vlastnost „býti podmnožinou“),  $A \subseteq B$ , lze zavést několika ekvivalentními způsoby, např.

- (1)  $\forall x \in A : x \in B$ ,
- (2)  $\forall x \in X : (x \in A \Rightarrow x \in B)$ ,
- (3)  $A \cap B = A$ ,
- (4)  $A \cup B = B$ .

Poslední dva vztahy charakterizují inkluzi pomocí množinových operací.

Povšimněme si ještě, že naopak lze všechny množinové operace zavést pomocí inkluze (a z ní přirozeně odvozených operací maxima a minima souboru množin):

$$\begin{aligned} A \cap B &= \max\{C \subseteq X : C \subseteq A, C \subseteq B\}, \\ A \cup B &= \min\{C \subseteq X : A \subseteq C, B \subseteq C\}, \\ \overline{A} &= \max\{C \subseteq X : C \cap A = \emptyset\} = \min\{C \subseteq X : C \cup A = X\}. \end{aligned}$$

Doplňek je také jednoznačně charakterizován vztahy

$$A \cap \overline{A} = \emptyset, \quad A \cup \overline{A} = X.$$

Doplňek nedostačuje k určení inkluze, splňuje však následující ekvivalenci:

$$A \subseteq B \Leftrightarrow \overline{B} \subseteq \overline{A}.$$

## 1.2. Charakteristická funkce

Alternativně lze množinu  $A$  popsat její *charakteristickou funkcí*  $\mu_A : X \rightarrow \{0, 1\}$ ,

$$\mu_A(x) = \begin{cases} 1 & \text{pro } x \in A, \\ 0 & \text{pro } x \notin A. \end{cases}$$

(Zde je opět důležitá univerzální množina  $X$  jako definiční obor charakteristické funkce.) Takto běžně reprezentujeme množiny na počítači, např. v Pascalu. Množina  $A$  je svou charakteristickou funkcí  $\mu_A$  jednoznačně určena:

$$A = \{x \in X : \mu_A(x) = 1\} = \{x \in X : \mu_A(x) > 0\}.$$

I když charakteristická funkce nebývá prostá, budeme pro ni (podobně jako pro jiná zobrazení) používat značení pro inverzi  $\mu_A^{-1}$ , která množině obrazů  $M \subseteq \{0, 1\}$  přiřadí množinu všech odpovídajících vzorů, tj.

$$\mu_A^{-1}(M) = \{x \in X : \mu_A(x) \in M\}.$$

S tímto značením lze psát

$$A = \mu_A^{-1}(\{1\}) = \mu_A^{-1}(\langle 0, 1 \rangle).$$

Je-li argumentem  $\mu_A^{-1}$  jednoprvková množina, často píšeme pouze tento prvek, tedy  $\mu_A^{-1}(1)$  znamená  $\mu_A^{-1}(\{1\})$ .

Inkluzi a množinové operace lze pomocí charakteristických funkcí vyjádřit následovně:

$$\begin{aligned} A \subseteq B &\Leftrightarrow \mu_A \leq \mu_B, \\ \mu_{A \cap B}(x) &= \mu_A(x) \wedge \mu_B(x) = \mu_A(x) \cdot \mu_B(x) = \min(\mu_A(x), \mu_B(x)), \\ \mu_{A \cup B}(x) &= \mu_A(x) \vee \mu_B(x) = \max(\mu_A(x), \mu_B(x)), \\ \mu_{\bar{A}}(x) &= 1 - \mu_A(x) = \neg \mu_A(x), \end{aligned}$$

kde  $\neg$  značí logickou negaci.

## 1.3. Základní pojmy teorie fuzzy množin

Zatímco zobecnění pojmu množiny v původním tvaru je těžko představitelné, charakteristickou funkci lze snadno zobecnit na funkci nabývající více (pravdivostních) hodnot. Zde se až na výjimky omezíme na případ, kdy množinou pravdivostních hodnot bude interval reálných čísel  $\langle 0, 1 \rangle$  nebo jeho podmnožina.

Opět budeme předpokládat pevně zvolenou univerzální množinu  $X$ . *Fuzzy podmnožinou*  $A$  univerza  $X$  (stručně *fuzzy množinou*) budeme rozumět objekt popsáný (zobecněnou) charakteristickou funkcí

$$\mu_A : X \rightarrow \langle 0, 1 \rangle$$

(nazývanou též *funkce příslušnosti*). Pro každý prvek  $x \in X$  hodnota  $\mu_A(x) \in \langle 0, 1 \rangle$  říká, do jaké míry je  $x$  prvkem fuzzy množiny  $A$ . Každá funkce z  $X$  do  $\langle 0, 1 \rangle$  určuje jednoznačně nějakou fuzzy množinu. V některých učebnicích se ztotožňují fuzzy množiny a jejich funkce příslušnosti, pak místo  $\mu_A(x)$  píšeme stručněji  $A(x)$ . Zde budeme tyto pojmy důsledně rozlišovat, mj. proto, že fuzzy množina pro nás bude objektem, který je možno popsat více způsoby, z nichž jedním je funkce příslušnosti. Podobně např. náhodná veličina je objektem, který lze popsat distribuční funkcí, ale i jinak, např. hustotou (pokud existuje), charakteristickou funkcí apod.

Zápis  $x \in A$  nebudeme pro fuzzy množiny používat, protože ztrácí původní význam. Vyhradíme jej pouze pro „klasické“ množiny (které nejsou fuzzy); těm budeme pro odlišení říkat *ostré množiny* (angl. *crisp*). Zápis  $\mu_A(x)$  budeme používat jak pro fuzzy množiny, tak pro ostré množiny jako speciální případ. Je-li tedy  $A$  ostrá množina a  $x \in X$ , pak  $\mu_A(x) \in \{0, 1\}$  je pravdivostní hodnota výroku  $x \in A$ .

Všechny fuzzy podmnožiny univerza  $X$  tvoří množinu, kterou budeme značit  $\mathcal{F}(X)$ .

Nejdříve zavedeme několik základních pojmů pro libovolnou fuzzy množinu  $A$  na univerzu  $X$ .

**Obor hodnot:**  $\text{Range}(A) = \{\alpha \in \langle 0, 1 \rangle : (\exists x \in X : \mu_A(x) = \alpha)\}$

**Výška:**  $h(A) = \sup \text{Range}(A)$

Je-li fuzzy množina výšky 1, nazývá se *normální*; v opačném případě jí říkáme *subnormální*.

**Nosič** (angl. *support*) je ostrá množina

$$\text{Supp}(A) = \{x \in X : \mu_A(x) > 0\}, \quad \text{neboli} \quad \text{Supp}(A) = \mu_A^{-1}((0, 1)).$$

(Aby se nosič nepletl se supremem, píšeme zde velké „S“ a dvě „P“.)

**Jádro** (angl. *core*) je ostrá množina

$$\text{core}(A) = \{x \in X : \mu_A(x) = 1\}, \quad \text{tj.} \quad \text{core}(A) = \mu_A^{-1}(1).$$

Fuzzy množina se nazývá **konečná**, má-li konečný nosič. V tom případě definujeme tzv. **skalární kardinalitu** předpisem

$$\text{card}(A) = \sum_{x \in X} \mu_A(x).$$

Je zřejmé, že stačí sčítat přes  $x \in \text{Supp}(A)$  a že pro konečné ostré množiny tento pojem splývá s klasickou kardinalitou.

Libovolnou fuzzy množinu můžeme popsat její funkcí příslušnosti. Například na univerzu  $X = \mathbf{R}$  můžeme definovat fuzzy množiny  $A, B$  předpisem

$$\mu_A(x) = \begin{cases} 0 & \text{pro } x < 0, \\ x & \text{pro } x \in \langle 0, 1 \rangle, \\ 2 - x & \text{pro } x \in (1, 2), \\ 0 & \text{pro } x > 2, \end{cases}$$

$$\mu_B(x) = \begin{cases} \frac{1}{2} & \text{pro } x = 3, \\ 1 & \text{pro } x = 4, \\ \frac{1}{4} & \text{pro } x = 5, \\ 0 & \text{jinak.} \end{cases}$$

Pro konečné fuzzy množiny je tento zápis zbytečně nepřehledný, zavádí se proto pro něj stručnější vyjádření. Zde budeme psát např.

$$\mu_B = \{(3, \frac{1}{2}), (4, 1), (5, \frac{1}{4})\}.$$

Využíváme toho, že reálná funkce na  $X$  je podmnožina kartézského součinu  $X \times \mathbf{R}$ , tady množina uspořádaných dvojic; jediná odchylka od standardního značení spočívá tedy v tom, že neuvádíme prvky s nulovým stupněm příslušnosti. (Pak ale musíme zvlášť říci, co je univerzem, tedy definičním oborem funkce příslušnosti.)

**Poznámka 1.1.** V literatuře se setkáme s mnoha jinými zápisy, např.

$$\mu_B = \{\frac{1}{2}/3, 1/4, \frac{1}{4}/5\}.$$

Zde jsme volili zápis co nejpodobnější zvykům z jiných oblastí matematiky.

#### 1.4. Popis fuzzy množin pomocí řezů

Nyní ukážeme i jiný způsob určení fuzzy množiny než pomocí její funkce příslušnosti. Ten bude mnohde výhodný, proto bude účelné naučit se oba popisy navzájem převádět.

**Definice 1.2.** Nechť  $A \in \mathcal{F}(X)$ ,  $\alpha \in \langle 0, 1 \rangle$ . Pak  **$\alpha$ -hladina** (angl.  *$\alpha$ -level*) fuzzy množiny  $A$  je ostrá množina

$$\mu_A^{-1}(\alpha) = \{x \in X : \mu_A(x) = \alpha\}.$$

**Systém řezů** fuzzy množiny  $A$  je zobrazení

$$R_A : \langle 0, 1 \rangle \rightarrow \mathcal{P}(X),$$

kteř každému  $\alpha \in \langle 0, 1 \rangle$  přiřazuje tzv.  **$\alpha$ -řez** (angl.  *$\alpha$ -cut*)

$$R_A(\alpha) = \mu_A^{-1}([\alpha, 1]) = \{x \in X : \mu_A(x) \geq \alpha\}. \quad (1.1)$$

Použijeme-li v předchozím vztahu ostrou nerovnost, dostaneme **systém ostrých řezů**  $S_A : \langle 0, 1 \rangle \rightarrow \mathcal{P}(X)$ , kde **ostrý  $\alpha$ -řez** je

$$S_A(\alpha) = \mu_A^{-1}((\alpha, 1]) = \{x \in X : \mu_A(x) > \alpha\}.$$

**Poznámka 1.3.** V literatuře se setkáváme s mnoha jinými způsoby značení  $\alpha$ -řezu fuzzy množiny  $A$ , např.  $[A]_\alpha$ ,  ${}^\alpha A$ ,  ${}_\alpha A$  atd.

Řezy a hladiny fuzzy množin mají následující vztah k dříve zavedeným pojmům:

$$\begin{aligned}\text{Range}(A) &= \{\alpha \in \langle 0, 1 \rangle : \mu_A^{-1}(\alpha) \neq \emptyset\}, \\ h(A) &= \sup\{\alpha \in \langle 0, 1 \rangle : R_A(\alpha) \neq \emptyset\}, \\ \text{Supp}(A) &= S_A(0), \\ \text{core}(A) &= R_A(1).\end{aligned}$$

Triviálně platí pro všechna  $A \in \mathcal{F}(X)$ :

$$R_A(0) = X, \quad S_A(1) = \emptyset.$$

**Věta 1.4 (o systému řezů).** **A.** Nechť  $M : \langle 0, 1 \rangle \rightarrow \mathcal{P}(X)$  je systém řezů fuzzy množiny  $A \in \mathcal{F}(X)$ , tj.  $M = R_A$ . Pak  $M$  splňuje podmínky

$$M(0) = X, \tag{R1}$$

$$0 \leq \alpha < \beta \leq 1 \Rightarrow M(\alpha) \supseteq M(\beta), \tag{R2}$$

$$0 < \beta \leq 1 \Rightarrow M(\beta) = \bigcap_{\alpha < \beta} M(\alpha). \tag{R3}$$

(Průnik v (R3) je přes všechna  $\alpha \in \langle 0, \beta \rangle$ .)

**B.** Naopak, každé zobrazení  $M : \langle 0, 1 \rangle \rightarrow \mathcal{P}(X)$  splňující podmínky (R1), (R2), (R3) je systémem řezů nějaké fuzzy množiny  $A \in \mathcal{F}(X)$ , tj.  $M = R_A$ .

**Důkaz.**

**A.** (R1):  $M(0) = R_A(0) = X$  (0-řez).

(R2): Je-li  $x \in M(\beta) = R_A(\beta)$ , znamená to, že  $\mu_A(x) \geq \beta > \alpha$ , tedy  $x \in R_A(\alpha) = M(\alpha)$ .

(R3): Pro rovnost dvou množin je potřeba dokázat dvě inkluze.

Podle (R2) pro všechna  $\alpha \in \langle 0, \beta \rangle$  platí  $M(\beta) \subseteq M(\alpha)$ ,

proto  $M(\beta) \subseteq \bigcap_{\alpha < \beta} M(\alpha)$ .

Pro důkaz obrácené inkluze předpokládejme, že  $x \in \bigcap_{\alpha < \beta} M(\alpha)$ .

To znamená, že pro všechna  $\alpha \in \langle 0, \beta \rangle$  platí  $\mu_A(x) \geq \alpha$ ,

tedy  $\mu_A(x) \geq \beta$ , neboli  $x \in R_A(\beta) = M(\beta)$ .

**B.** Funkci příslušnosti hledané fuzzy množiny  $A$  lze definovat v každém bodě takto:

$$\mu_A(x) = \sup\{\alpha \in \langle 0, 1 \rangle : x \in M(\alpha)\}. \tag{1.5}$$

(Supremum existuje, protože podle (R1) je příslušná množina neprázdná.) Dokážeme, že systém řezů  $R_A$  je roven  $M$ . Důkaz opět rozložíme na dvě inkluze.

Pokud  $x \in M(\beta)$ , pak přímo z definice  $\mu_A$  vyplývá  $\mu_A(x) \geq \beta$ , tj.  $x \in R_A(\beta)$ .

Nechť  $x \in R_A(\beta)$ , tj.  $\mu_A(x) = \sup\{\alpha \in \langle 0, 1 \rangle : x \in M(\alpha)\} \geq \beta$ . Vzhledem k (R2) to znamená, že pro všechna  $\alpha \in \langle 0, \beta \rangle$  platí  $x \in M(\alpha)$ , a tedy s využitím (R3)

$$x \in \bigcap_{\alpha < \beta} M(\alpha) = M(\beta).$$

□

**Poznámka 1.5.** Kromě vztahu (R3) platí triviálně také

$$R_A(\beta) = \bigcap_{\alpha \leq \beta} R_A(\alpha),$$

$$R_A(\beta) = \bigcup_{\alpha \geq \beta} R_A(\alpha),$$

ale neplatí

$$R_A(\beta) = \bigcup_{\alpha > \beta} R_A(\alpha).$$

Za protipříklad stačí vzít  $X = \{x, y\}$ ,  $\mu_A = \{(x, 1), (y, 0)\}$ . Pro  $\beta = 0$  dostáváme  $R_A(0) = X$ ,  $\bigcup_{\alpha > 0} R_A = \{x\}$ .

Věta o reprezentaci pomocí řezů nám zajišťuje, že každá fuzzy množina je jednoznačně určena svým systémem řezů. Popisu fuzzy množiny pomocí systému řezů říkáme *horizontální reprezentace*, na rozdíl od *vertikální reprezentace* pomocí funkce příslušnosti. Vzájemný převod obou reprezentací zajišťují vztahy (1.1) a (1.5). Ty budeme potřebovat, neboť pro některé účely je jedna z reprezentací vhodnější než druhá. Převod z horizontální reprezentace na vertikální uvedeme ještě v jiném tvaru s využitím násobku funkce příslušnosti skalárem.

**Věta 1.6.** Nechť  $A \in \mathcal{F}(X)$ . Pak

$$\mu_A(x) = \sup\{\alpha \in \langle 0, 1 \rangle : x \in R_A(\alpha)\}, \quad \mu_A = \sup_{\alpha \in \langle 0, 1 \rangle} \alpha \mu_{R_A(\alpha)} = \sup_{\alpha \in \text{Range}(A)} \alpha \mu_{R_A(\alpha)},$$

kde supremum v posledním vztahu počítáme po bodech, tj.

$$\mu_A(x) = \sup_{\alpha \in \langle 0, 1 \rangle} \alpha \mu_{R_A(\alpha)}(x).$$

(S tímto supremem se později setkáme jako se standardním fuzzy sjednocením.)

**Důkaz.** První vztah se vyskytl již v důkazu věty o reprezentaci řezů (1.5). Další jsou jen jeho ekvivalentní formulace.  $\square$

Jako příklad využití horizontální reprezentace uvažujme, jak reprezentovat v počítači fuzzy množinu reálných čísel. Vertikální reprezentace vyžaduje zadat reálnou funkci. Její hodnoty mohou být určeny s velkou přesností, ale ta nemusí být užitečná. Jelikož už samy pravdivostní hodnoty vyjadřují vágnost, vystačíme často s poměrně malým počtem stupňů příslušnosti. V horizontální reprezentaci pak stačí ke každému z nich určit příslušný řez. Často bývá řezem interval, k jehož určení stačí dvojice čísel. Později uvidíme, že tato reprezentace je vhodná i pro některé operace.

**Příklad 1.7.** Na univerzu  $X = \{a, b, c, d\}$  je dána fuzzy množina  $\mu_A = \{(a, 0.3), (b, 1), (c, 0.5)\}$ . Najděte její horizontální reprezentaci.

**Řešení.**

$$R_A(\alpha) = \begin{cases} X & \text{pro } \alpha = 0, \\ \{a, b, c\} & \text{pro } \alpha \in (0, 0.3), \\ \{b, c\} & \text{pro } \alpha \in (0.3, 0.5), \\ \{b\} & \text{pro } \alpha \in (0.5, 1). \end{cases}$$

**Příklad 1.8.** Fuzzy množina  $A$  má horizontální reprezentaci

$$R_A(\alpha) = \begin{cases} \{a, b, c, d\} & \text{pro } \alpha \in \langle 0, 1/3 \rangle, \\ \{a, d\} & \text{pro } \alpha \in (1/3, 1/2), \\ \{d\} & \text{pro } \alpha \in (1/2, 2/3), \\ \emptyset & \text{pro } \alpha \in (2/3, 1). \end{cases}$$

Najděte její vertikální reprezentaci.

**Řešení.**

$$\begin{aligned} \mu_A(a) &= \sup\{\alpha \in \langle 0, 1 \rangle : a \in R_A(\alpha)\} = \sup\langle 0, 1/2 \rangle = 1/2, \\ \text{podobně } \mu_A(b) &= 1/3, \quad \mu_A(c) = 1/3, \quad \mu_A(d) = 2/3, \quad \text{tedy} \\ \mu_A &= \{(a, 1/2), (b, 1/3), (c, 1/3), (d, 2/3)\}. \end{aligned}$$



**Příklad 1.9.** Fuzzy množina  $A$  má horizontální reprezentaci

$$R_A(\alpha) = \begin{cases} \{a, b, c\} & \text{pro } \alpha = 0, \\ \{a\} & \text{pro } \alpha \in (0, 1/2), \\ \{a, b\} & \text{jinak.} \end{cases}$$

Najděte její vertikální reprezentaci.

**Řešení.** Zadání není horizontální reprezentací žádné fuzzy množiny, protože není splněna podmínka (R2). Například  $R_A(1/2) \not\subseteq R_A(1)$ . Dostáváme  $\mu_A(b) = \sup\{\alpha \in \langle 0, 1 \rangle : b \in R_A(\alpha)\} = \sup(\{0\} \cup (1/2, 1)) = 1$ , ale  $b \notin R_A(1/2)$ .

**Příklad 1.10.** Fuzzy množina  $A$  má horizontální reprezentaci

$$R_A(\alpha) = \begin{cases} \{a, b\} & \text{pro } \alpha = 0, \\ \{a\} & \text{pro } \alpha \in (0, 1/2), \\ \emptyset & \text{jinak.} \end{cases}$$

Najděte její vertikální reprezentaci.

**Řešení.** Zadání není horizontální reprezentací žádné fuzzy množiny, protože není splněna podmínka (R3). Dostáváme  $\mu_A(a) = \sup\{\alpha \in \langle 0, 1 \rangle : a \in R_A(\alpha)\} = \sup(0, 1/2) = 1/2$ , ale  $a \notin R_A(1/2)$ .

**Příklad 1.11.** Na univerzu  $X = \mathbf{R}$  je dána fuzzy množina  $A$ :

$$\mu_A(x) = \begin{cases} x & \text{pro } x \in \langle 0, 1 \rangle, \\ 2 - x & \text{pro } x \in \langle 1, 1.5 \rangle, \\ 0 & \text{jinak.} \end{cases}$$

Najděte její horizontální reprezentaci.

**Řešení.**

$$R_A(\alpha) = \begin{cases} \mathbf{R} & \text{pro } \alpha = 0, \\ \langle \alpha, 1.5 \rangle & \text{pro } \alpha \in (0, 0.5), \\ \langle \alpha, 2 - \alpha \rangle & \text{pro } \alpha \in (0.5, 1). \end{cases}$$

**Příklad 1.12.** Je dána horizontální reprezentace fuzzy množiny  $A$ :

$$R_A(\alpha) = \begin{cases} \mathbf{R} & \text{pro } \alpha = 0, \\ \langle \alpha^2, 1 \rangle & \text{jinak.} \end{cases}$$

Najděte její vertikální reprezentaci.

**Řešení.**

$$\mu_A(x) = \begin{cases} \sqrt{x} & \text{pro } x \in (0, 1), \\ 0 & \text{jinak.} \end{cases}$$

**Příklad 1.13.** Je dána horizontální reprezentace fuzzy množiny  $A$ :

$$R_A(\alpha) = \begin{cases} \mathbf{R} & \text{pro } \alpha = 0, \\ \langle \alpha^2, 1 \rangle & \text{jinak.} \end{cases}$$

Najděte její vertikální reprezentaci.

**Řešení.** Zadání není horizontální reprezentací žádné fuzzy množiny, protože není splněna podmínka (R3). Dostáváme například  $\mu_A(1/4) = \sup\{\alpha \in \langle 0, 1 \rangle : 1/4 \in R_A(\alpha)\} = \sup(0, 1/2) = 1/2$ , ale  $1/4 \notin R_A(1/2)$ .

### 1.5. Fuzzy inkluze

**Definice 1.14.** Necht  $A, B \in \mathcal{F}(X)$ . Říkáme, že  $A$  je *podmnožinou*  $B$  a píšeme  $A \subseteq B$ , jestliže platí  $\forall x \in X : \mu_A(x) \leq \mu_B(x)$ .

Protože takto je definována i nerovnost reálných funkcí, kterými funkce příslušnosti fuzzy množin jsou, můžeme ekvivalentně psát též  $\mu_A \leq \mu_B$ .

**Poznámka 1.15.** Nemůžeme použít zápis  $\forall x \in A : x \in B$ , neboť pro fuzzy množinu  $A$  nemáme dosud definován význam kvantifikátoru  $\forall x \in A$ .

**Věta 1.16.** Necht  $A, B \in \mathcal{F}(X)$ . Pak  $A \subseteq B$  právě tehdy, když

$$\forall \alpha \in \langle 0, 1 \rangle : R_A(\alpha) \subseteq R_B(\alpha). \quad (1.6)$$

**Důkaz.** 1. Předpokládejme, že  $A \subseteq B$ ,  $x \in R_A(\alpha)$ . Pak  $\alpha \leq \mu_A(x) \leq \mu_B(x)$ , tedy  $x \in R_B(\alpha)$  a  $R_A(\alpha) \subseteq R_B(\alpha)$ .

2. Předpokládejme, že platí (1.6). Necht  $x \in X$ . Podle věty 1.6 je

$$\mu_A(x) = \sup\{\alpha \in \langle 0, 1 \rangle : x \in R_A(\alpha)\}.$$

Protože  $\{\alpha \in \langle 0, 1 \rangle : x \in R_A(\alpha)\} \subseteq \{\alpha \in \langle 0, 1 \rangle : x \in R_B(\alpha)\}$ , platí nerovnost  $\mu_A(x) \leq \sup\{\alpha \in \langle 0, 1 \rangle : x \in R_B(\alpha)\} = \mu_B(x)$ .  $\square$

Díky této větě máme dvě ekvivalentní formulace fuzzy inkluze; jednu pro vertikální a jednu pro horizontální reprezentaci.

## 2. Operace s fuzzy množinami

### 2.1. Ostré množiny

Začneme přehledem situace pro ostré množiny a zaměříme se na vztah mezi množinovými a výrokovými operacemi. Výrokovými operacemi v tomto speciálním případě míníme operace Booleovy algebry, dané známými tabulkami hodnot.

množinové operace	výrokové operace	vztah
doplňek $\bar{\phantom{x}} : \mathcal{P}(X) \rightarrow \mathcal{P}(X)$	negace $\neg : \{0, 1\} \rightarrow \{0, 1\}$	$\bar{A} = \{x \in X : \neg(x \in A)\}$
průnik $\cap : \mathcal{P}(X)^2 \rightarrow \mathcal{P}(X)$	konjunkce $\wedge : \{0, 1\}^2 \rightarrow \{0, 1\}$	$A \cap B = \{x \in X : (x \in A) \wedge (x \in B)\}$
sjednocení $\cup : \mathcal{P}(X)^2 \rightarrow \mathcal{P}(X)$	disjunkce $\vee : \{0, 1\}^2 \rightarrow \{0, 1\}$	$A \cup B = \{x \in X : (x \in A) \vee (x \in B)\}$

Pro charakteristické funkce lze předchozí vzorce psát:

$$\mu_{\bar{A}}(x) = \neg\mu_A(x), \quad \mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x), \quad \mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x).$$

Důležitost uvedených vzorců tkví mj. v tom, že zatímco definiční obor množinových operací může být různý v závislosti na volbě univerzální množiny, výrokové operace zůstávají stejné. Stačí tedy znát výrokové operace, aby bylo možné zavést množinové operace na libovolném univerzu.

Dalším důsledkem je, že množinové operace splňují stejné vlastnosti jako odpovídající výrokové operace (např. komutativitu, asociativitu, distributivitu), jmenovitě zákony Booleovy algebry. Ty lze vyjádřit např. následovně (není to nejušpurnější soustava axiomů, některé lze odvodit z ostatních):

involuce:	$\neg\neg\alpha = \alpha,$	
komutativita:	$\alpha \vee \beta = \beta \vee \alpha,$	$\alpha \wedge \beta = \beta \wedge \alpha,$
asociativita:	$(\alpha \vee \beta) \vee \gamma = \alpha \vee (\beta \vee \gamma),$	$(\alpha \wedge \beta) \wedge \gamma = \alpha \wedge (\beta \wedge \gamma),$
distributivita:	$\alpha \wedge (\beta \vee \gamma) = (\alpha \wedge \beta) \vee (\alpha \wedge \gamma),$	$\alpha \vee (\beta \wedge \gamma) = (\alpha \vee \beta) \wedge (\alpha \vee \gamma),$
idempotence:	$\alpha \vee \alpha = \alpha,$	$\alpha \wedge \alpha = \alpha,$
absorpce:	$\alpha \vee (\alpha \wedge \beta) = \alpha,$	$\alpha \wedge (\alpha \vee \beta) = \alpha,$
absorpce s univerzem a 0:	$\alpha \vee 1 = 1,$	$\alpha \wedge 0 = 0,$
neutrální prvky:	$\alpha \vee 0 = \alpha,$	$\alpha \wedge 1 = \alpha,$
zákon kontradikce:		$\alpha \wedge \neg\alpha = 0,$
zákon vyloučeného třetího:	$\alpha \vee \neg\alpha = 1,$	
de Morganovy zákony:	$\neg\alpha \wedge \beta = \neg\alpha \vee \neg\beta,$	$\neg\alpha \vee \beta = \neg\alpha \wedge \neg\beta.$

### 2.2. Analogie pro operace s fuzzy množinami

Rovněž pro operace s fuzzy množinami budou základem operace fuzzy výrokového počtu, tedy operace s pravdivostními hodnotami, tentokrát z intervalu  $\langle 0, 1 \rangle$ .

**Poznámka 2.1.** Vycházíme z předpokladu, že stupeň příslušnosti bodu  $x \in X$  k výsledku operace závisí jen na jeho stupních příslušnosti k operandům a je jimi jednoznačně určen (tomu říkáme, že fuzzy logika je *funkcionální*).

V případě ostrých množin nebyl tento předpoklad vůbec překvapivý. V případě fuzzy množin je nutno tento princip zdůraznit, neboť mnohdy nebývá správně pochopen. Jeho první část říká, že výsledek je nezávislý na hodnotách příslušnosti v ostatních bodech.

Druhá část říká, že stupně příslušnosti bodu k operandům poskytují *dostatečnou* informaci pro určení stupně příslušnosti k výsledku. Např. že stupeň pravdivosti fuzzy konjunkce „je chladno a prší“ je plně určen tím, nakolik je chladno a nakolik prší.

To je úplně jiná situace než u pravděpodobnostní neurčitosti. Kdybychom definovali *ostrá* kritéria pro jevy „je chladno“ a „prší“, mohli bychom stanovit (ostrou) pravdivostní hodnotu výroku „dnes je chladno a prší“. Mohli bychom také hovořit o pravděpodobnosti jevů „zítra bude chladno a bude pršet“. Ta *není* jednoznačně určena pravděpodobnostmi výroků „zítra bude chladno“ a „zítra bude pršet“; záleží zde navíc na závislosti zkoumaných jevů.

Je tedy třeba připomenout, že fuzzy neurčitost se liší od pravděpodobnostní mj. v tom, že je funkcionální.

Jelikož fuzzy množinové i výrokové operace vesměs zobecňují odpovídající klasické operace, budeme pro ně používat totéž značení:  $\overline{\phantom{x}}, \cap, \cup, \dots, \neg, \wedge, \vee, \dots$  a tutéž terminologii, pouze s přívlastkem „fuzzy“. Jak ovšem uvidíme, toto zobecnění lze zavést více způsoby, které budeme rozlišovat indexy, např.  $\neg_s, \cap_s, \cup_s, \dots$ . Index nahradíme tečkou, chceme-li hovořit o nějaké (blíže nespecifikované) fuzzy operaci příslušného typu, např.  $\cap$  bude znamenat libovolný fuzzy průnik. Operandy bez indexů vyhradíme jen pro dva účely:

- operace klasické logiky a teorie množin,
  - pro spojky použité v logice pro vytváření formulí, plnící tedy roli čistě syntaktickou.
- Spojky  $\Rightarrow, \Leftrightarrow$  vyhrazuujeme pouze pro klasickou implikaci a ekvivalenci ostrých výroků.

### 2.3. Fuzzy negace

**Definice 2.2.** *Fuzzy negace* je unární operace  $\neg : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$ , splňující následující axiomy:

$$\alpha \leq \beta \Rightarrow \neg \beta \leq \neg \alpha, \quad (\text{N1})$$

$$\neg \neg \alpha = \alpha. \quad (\text{N2})$$

Podle (N1) je fuzzy negace nerostoucí, podle (N2) je *involutivní*.

**Příklad 2.3.** *Standardní fuzzy negace*  $\neg_s$  je definována vztahem  $\neg_s \alpha = 1 - \alpha$ .

Z axiomů (N1), (N2) vyplývají mnohem přísnější podmínky:

**Věta 2.4.** Každá fuzzy negace  $\neg$  je spojitá, klesající, bijektivní a splňuje okrajové podmínky

$$\neg 1 = 0, \quad \neg 0 = 1. \quad (\text{N0})$$

Její graf je symetrický podle osy 1. a 3. kvadrantu, tj.  $\neg^{-1} = \neg$  (neboli  $\neg$  je sama k sobě inverzní).

**Důsledek 2.5.** Pro každou fuzzy negaci  $\neg$  existuje právě jedna hodnota  $e \in (0, 1)$ , pro kterou  $\neg e = e$ . Nazýváme ji *rovnovážnou hodnotou* (angl. *equilibrium*).

**Důkaz.** Funkce  $f(\beta) = \neg \beta - \beta$  splňuje  $f(0) = 1, f(1) = -1$ . Protože je spojitá, má podle věty o střední hodnotě v intervalu  $(0, 1)$  nulové místo, které je rovnovážnou hodnotou. Jednoznačnost plyne z toho, že  $f$  je klesající.  $\square$

**Věta 2.6 (o reprezentaci fuzzy negací).** **A.** Nechť  $i : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$  je rostoucí bijekce. Pak funkce

$$\neg_i = i^{-1} \circ \neg_s \circ i, \quad \text{tj.} \quad \neg_i \alpha = i^{-1}(\neg_s i(\alpha))$$

je fuzzy negace.

**B.** Naopak, každá fuzzy negace  $\neg$  je uvedeného tvaru pro nějakou rostoucí bijekci  $i$ ; ta se nazývá *generátor fuzzy negace*  $\neg$ .

**Důkaz.** (Dle [7].) **A.** (N1): Nechť  $\alpha, \beta \in \langle 0, 1 \rangle, \alpha \leq \beta$ . Jelikož  $i, i^{-1}$  uspořádání zachovávají a  $\neg_s$  obrací, dostáváme postupně

$$i(\alpha) \leq i(\beta), \quad \neg_s i(\alpha) \geq \neg_s i(\beta), \quad i^{-1}(\neg_s i(\alpha)) \geq i^{-1}(\neg_s i(\beta)),$$

tedy  $\neg_i \alpha \geq \neg_i \beta$ .

(N2):  $\neg_i \circ \neg_i = i^{-1} \circ \neg_s \circ i \circ i^{-1} \circ \neg_s \circ i = i^{-1} \circ \neg_s \circ \neg_s \circ i = i^{-1} \circ i = \text{id}$ , kde  $\text{id}$  je identita na  $\langle 0, 1 \rangle$ .

**B.** Definujeme zobrazení  $i$  předpisem

$$i(\alpha) = \frac{\alpha + \neg_s \neg \alpha}{2}$$

a dokážeme, že je generátorem fuzzy negace  $\neg$ . Je zřejmé, že  $i$  je rostoucí, spojitá a splňuje  $i(0) = 0, i(1) = 1$ . Je to tedy bijekce na  $\langle 0, 1 \rangle$ . Dále platí

$$\neg_i i(\alpha) = 1 - \frac{\alpha + \neg_s \neg \alpha}{2} = \frac{1 - \alpha + 1 - \neg_s \neg \alpha}{2} = \frac{\neg_s \alpha + \neg_s \neg \neg \alpha}{2} = \frac{\neg_s \alpha + \neg \alpha}{2} = \frac{\neg_s \neg \neg \alpha + \neg \alpha}{2} = i(\neg \alpha).$$

Tím jsme dokázali, že  $\neg_s \circ i = i \circ \neg$ , neboli  $i^{-1} \circ \neg_s \circ i = \neg$ .  $\square$

**Poznámka 2.7.** Pro rozlišení od jiných reprezentací se někdy tomuto typu generátoru fuzzy negace říká *rostoucí generátor*.

**Poznámka 2.8.** Rostoucí generátor fuzzy negace není jednoznačně určen. V předchozím důkazu jsme zkonstruovali jeden z možných rostoucích generátorů. Zcela jinou konstrukci lze najít v [6], její důkaz je však mnohem komplikovanější.

Věta o reprezentaci fuzzy negací má několik důsledků. Rostoucí bijekci  $i$  lze interpretovat jako změnu měřítka na intervalu  $\langle 0, 1 \rangle$ ; mění se označení pravdivostních hodnot, ale zůstává zachováno jejich uspořádání.

Podle reprezentační věty lze libovolnou fuzzy negaci dostat ze standardní. To ovšem neznamená, že by standardní negace měla nějaké výsadní postavení; naopak na jejím místě bylo možno použít libovolnou jinou fuzzy negaci, věta platí i pro ni.

Různé fuzzy negace se mohou jevit odlišně z hlediska uživatele, který jimi chce popsat vágnost informací, ale z matematického hlediska mezi nimi není (zatím) žádný podstatný rozdíl. Další text tedy neztratí příliš na obecnosti, když se v něm omezíme na jedinou – standardní – fuzzy negaci.

**Poznámka 2.9.** Někdy se uvažuje (a jako fuzzy negace označuje) *zobecněná fuzzy negace*, což je operace  $\neg : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$  splňující pouze (N0) a (N1). Ta nemusí být involutivní ani spojitá. V tom případě se fuzzy negaci v našem smyslu (splňující (N1),(N2)) říká *silná fuzzy negace*.

**Příklad 2.10.** *Gödelova zobecněná fuzzy negace:*

$$\neg_G \alpha = \begin{cases} 1 & \text{pro } \alpha = 0, \\ 0 & \text{jinak.} \end{cases}$$

**Definice 2.11.** *Fuzzy doplněk* je operace na fuzzy množinách definovaná pomocí fuzzy negace:

$$\mu_{\bar{A}}(X) = \neg \mu_A(x).$$

Přitom  $\bar{A}$  znamená obecný fuzzy doplněk k fuzzy množině  $A$ . Jednotlivé typy budeme rozlišovat stejnými indexy, jako u fuzzy negací. Například  $\bar{A}^s$  je standardní fuzzy doplněk fuzzy množiny  $A$  (odpovídající standardní fuzzy negaci  $\neg_s$ ).

## 2.4. Fuzzy konjunkce (trojúhelníkové normy)

**Definice 2.12.** *Fuzzy konjunkce*, (*trojúhelníková norma*, *t-norma*, angl. *triangular norm*) je binární operace  $\wedge : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , splňující následující axiomy pro všechna  $\alpha, \beta, \gamma \in \langle 0, 1 \rangle$ :

$$\begin{array}{ll} \alpha \wedge \beta = \beta \wedge \alpha & \text{(komutativita)} & \text{(T1)} \\ \alpha \wedge (\beta \wedge \gamma) = (\alpha \wedge \beta) \wedge \gamma & \text{(asociativita)} & \text{(T2)} \\ \beta \leq \gamma \Rightarrow \alpha \wedge \beta \leq \alpha \wedge \gamma & \text{(monotonie)} & \text{(T3)} \\ \alpha \wedge 1 = \alpha & \text{(okrajová podmínka)} & \text{(T4)} \end{array}$$

**Poznámka 2.13.** Pojem *trojúhelníková norma* se jeví poněkud nepřiměřený, ale je všeobecně používaný. Pochází z prací Schweizera a Sklara [16], které se nezabývaly fuzzy množinami, nýbrž metrikami na prostorech pravděpodobností, nicméně podaly první soustavné studium těchto operací. V současné době je asi nejuplnějším dílem o trojúhelníkových normách monografie [13].

Definiční vlastnosti fuzzy konjunkcí reprezentují přirozené minimální požadavky, které na takovou operaci můžeme mít. Jelikož konjunkci běžně užíváme pro více argumentů bez ohledu na jejich pořadí, potřebujeme komutativitu a asociativitu. Monotonie je rovněž přirozená – pokud zvýšíme stupeň pravdivosti jednoho z argumentů, bylo by velmi nepřirozené, kdyby se tím snížil stupeň pravdivosti jejich konjunkce. Okrajová podmínka říká, že existuje hodnota („úplná pravda“, 1), která, přidána k argumentům konjunkce, její výsledek nesníží (ani nezvýší), je tedy neutrálním prvkem vzhledem k této operaci.

**Příklad 2.14.**

- *Standardní* fuzzy konjunkce (*min*, *Gödelova*, *Zadehova* ...):

$$\alpha \wedge_S \beta = \min(\alpha, \beta).$$

- *Lukasiewiczova* fuzzy konjunkce (*Gilesova*, angl. též *bold* ...):

$$\alpha \wedge_L \beta = \begin{cases} \alpha + \beta - 1 & \text{pro } \alpha + \beta - 1 > 0, \\ 0 & \text{jinak.} \end{cases}$$

- *Součinnová* fuzzy konjunkce (*produktová*, *pravděpodobnostní*, angl. *algebraic product* ...):

$$\alpha \wedge_P \beta = \alpha \cdot \beta.$$

- *Drastická* fuzzy konjunkce (*slabá*, angl. *weak* ...):

$$\alpha \wedge_D \beta = \begin{cases} \alpha & \text{pro } \beta = 1, \\ \beta & \text{pro } \alpha = 1, \\ 0 & \text{jinak.} \end{cases}$$

**Věta 2.15.** Pro každou fuzzy konjunkci  $\wedge$  a  $\alpha \in \langle 0, 1 \rangle$  platí  $\alpha \wedge 0 = 0$ .

**Důkaz.** Podle (T3) a (T4) platí:  $\alpha \wedge 0 \stackrel{(T3)}{\leq} 1 \wedge 0 \stackrel{(T4)}{=} 0$ . □

Mezi fuzzy konjunkcemi můžeme uvažovat stejné uspořádání, jaké známe u funkcí, tj.  $\wedge_1 \leq \wedge_2$ , jestliže  $\forall \alpha, \beta \in \langle 0, 1 \rangle : \alpha \wedge_1 \beta \leq \alpha \wedge_2 \beta$ .

**Věta 2.16.** Mezi všemi fuzzy konjunkcemi je standardní největší a drastická nejmenší, tj. pro libovolnou fuzzy konjunkci  $\wedge$  platí

$$\forall \alpha, \beta \in \langle 0, 1 \rangle : \alpha \wedge_D \beta \leq \alpha \wedge \beta \leq \alpha \wedge_S \beta.$$

**Důkaz.** Je-li  $\alpha = 1$  nebo  $\beta = 1$ , pak podmínka (T4) dává stejný výsledek pro všechny fuzzy konjunkce. Předpokládejme (bez újmy na obecnosti)  $\alpha \leq \beta < 1$ . Pak

$$\alpha \wedge_D \beta = 0 \leq \alpha \wedge \beta \leq \alpha \wedge 1 = \alpha = \alpha \wedge_S \beta. \quad \square$$

**Věta 2.17.** Standardní fuzzy konjunkce je jediná, která splňuje  $\alpha \wedge_S \alpha = \alpha$  pro všechna  $\alpha \in \langle 0, 1 \rangle$ . (Této vlastnosti binárních operací říkáme *idempotence*.)

**Důkaz.** Nechť  $\wedge$  je idempotentní fuzzy konjunkce. Dokážeme, že je standardní. Předpokládejme  $\alpha, \beta \in \langle 0, 1 \rangle$ ,  $\alpha \leq \beta$ . Pak

$$\alpha = \alpha \wedge \alpha \stackrel{(T3)}{\leq} \alpha \wedge \beta \stackrel{(T3)}{\leq} \alpha \wedge 1 \stackrel{(T4)}{=} \alpha,$$

tedy  $\alpha \wedge \beta = \alpha = \alpha \wedge_S \beta$ . Pro  $\alpha > \beta$  zaměníme  $\alpha, \beta$  a stejným postupem dostaneme  $\alpha \wedge \beta = \beta = \alpha \wedge_S \beta$ . □

Dále se zaměříme především na *spojité* fuzzy konjunkce. Z fuzzy konjunkcí z příkladu 2.14 pouze drastická je nespojitá.

**Definice 2.18.** Nechť  $\wedge$  je spojitá fuzzy konjunkce. Řekneme, že  $\wedge$  je

- *archimedovská* (angl. *archimedean*), jestliže

$$\forall \alpha \in (0, 1) : \alpha \wedge \alpha < \alpha \quad (\text{TA})$$

- *striktní*, (angl. *strict*), jestliže

$$\forall \alpha \in (0, 1) \forall \beta, \gamma \in \langle 0, 1 \rangle : \beta < \gamma \Rightarrow \alpha \wedge \beta < \alpha \wedge \gamma \quad (\text{T3+})$$

- *nilpotentní* (angl. *nilpotent*), jestliže je archimedovská a není striktní.

**Poznámka 2.19.** V některých pramenech jsou jako archimedovské označovány všechny – i nespojitě – fuzzy konjunkce, které splňují (TA). Je nutno se vždy přesvědčit, v jakém významu autor tento termín používá.

**Příklad 2.20.** Součinnová fuzzy konjunkce je striktní, Łukasiewiczova je nilpotentní, standardní a drastická nejsou archimedovské (standardní nesplňuje (TA), drastická není spojitá). V dalším uvidíme, že tyto příklady jsou typické a v jistém smyslu univerzální.

**Poznámka 2.21.** Podmínka (T3+) je silnější než (TA); stačí v ní dosadit  $\beta := \alpha$ ,  $\gamma := 1$ . Tedy každá striktní fuzzy konjunkce je archimedovská; archimedovské fuzzy konjunkce se dělí na dvě disjunktní podtřídy, striktní a nilpotentní.

**Definice 2.22.** Chceme-li aplikovat fuzzy konjunkci  $\wedge$  na  $n$  argumentů  $\alpha_1, \dots, \alpha_n$ , použijeme zápis

$$\bigwedge_{k=1}^n \alpha_k = \alpha_1 \wedge \dots \wedge \alpha_n.$$

**Věta 2.23.** Nechť  $\wedge$  je archimedovská fuzzy konjunkce. Pak pro každé  $\alpha \in (0, 1)$  a  $\varepsilon > 0$  existuje  $n \in \mathbf{N}$  takové, že

$$\bigwedge_{k=1}^n \alpha < \varepsilon$$

Pro striktní fuzzy konjunkce nelze předchozí větu zesílit, pro nilpotentní ano:

**Věta 2.24.** Nechť  $\wedge$  je nilpotentní fuzzy konjunkce. Pak pro každé  $\alpha \in (0, 1)$  existuje  $n \in \mathbf{N}$  takové, že

$$\bigwedge_{k=1}^n \alpha = 0$$

**Věta 2.25 (o reprezentaci striktních fuzzy konjunkcí).** **A.** Nechť  $i : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$  je rostoucí bijekce. Pak operace  $\wedge_i : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , definovaná vztahem

$$\alpha \wedge_i \beta = i^{-1}(i(\alpha) \cdot i(\beta)),$$

je striktní fuzzy konjunkce.

**B.** Naopak, každá striktní fuzzy konjunkce  $\wedge$  je uvedeného tvaru pro nějakou rostoucí bijekci  $i$ , kterou nazýváme *multiplikativní generátor*.

**Poznámka 2.26.** Nechť  $i$  je multiplikativní generátor fuzzy konjunkce  $\wedge_i$ . Definujeme funkci  $h : \langle 0, 1 \rangle \rightarrow \langle 0, \infty \rangle$  předpisem

$$h(\alpha) = -\ln i(\alpha) \quad (\text{klademe } \ln 0 = -\infty).$$

Pak inverzní funkce je  $h^{-1}(t) = i^{-1}(e^{-t})$  a pro všechna  $\alpha, \beta \in \langle 0, 1 \rangle$  platí

$$\alpha \wedge_i \beta = h^{-1}(h(\alpha) + h(\beta)),$$

neboť  $h^{-1}(h(\alpha) + h(\beta)) = i^{-1}(e^{-(h(\alpha) + h(\beta))}) = i^{-1}(e^{-(-\ln i(\alpha) - \ln i(\beta))}) = i^{-1}(e^{\ln i(\alpha) + \ln i(\beta)}) = i^{-1}(i(\alpha) \cdot i(\beta)) = \alpha \wedge_i \beta$ .

Funkci  $h$  nazýváme *aditivní generátor* fuzzy konjunkce  $\wedge_i$ , neboť nám dovoluje vyjádřit tuto operaci pomocí součtu reálných čísel. Na rozdíl od multiplikativního generátoru, aditivní generátor je *klesající* funkce a jeho obor hodnot je nekonečný interval  $\langle 0, \infty \rangle$ . Proto zde budeme přednostně pracovat s multiplikativním generátorem, na rozdíl od např. [16].

**Věta 2.27 (o reprezentaci nilpotentních fuzzy konjunkcí).** **A.** Nechť  $i : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$  je rostoucí bijekce. Pak operace  $\wedge_i : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , definovaná vztahem

$$\alpha \wedge_i \beta = i^{-1}(i(\alpha) \wedge_L i(\beta)),$$

je nilpotentní fuzzy konjunkce.

**B.** Naopak, každá nilpotentní fuzzy konjunkce  $\wedge$  je uvedeného tvaru pro nějakou rostoucí bijekci  $i$ , kterou nazýváme *Łukasiewiczův generátor*.

Poznamenejme ještě jednu důležitou vlastnost archimedovských konjunkcí:

**Věta 2.28.** Je-li  $\wedge$  archimedovská konjunkce a  $\alpha_i < 1$ , kde  $i \in I$  a  $I$  je nespočetná množina, pak

$$\bigwedge_{i \in I} \alpha_i = 0.$$

**Důkaz.** Pomocí aditivního generátoru odpovídá uvedené konjunkci nespočetná suma nenulových členů. Z matematické analýzy je známo, že taková suma nemůže být konečná.  $\square$

Pro některé spočetné množiny argumentů analogie předchozí věty platit nemusí, stejně jako součet nekonečné (spočetné) řady může, ale nemusí být nekonečný. Důsledkem této věty je, že použití archimedovských fuzzy konjunkcí na nekonečné, zejména pak na nespočetné množiny argumentů nám zřídka dá užitečný výsledek. Naproti tomu u standardní fuzzy konjunkce (která je idempotentní) na takový problém nenarážíme. To se projeví při použití v některých vzorcích; pak bude vhodné omezit se na standardní fuzzy konjunkci a zamítnout zobecnění, které by ji nahrazovalo obecnější fuzzy konjunkcí, zejména archimedovskou.

**Definice 2.29.** *Fuzzy průnik* je operace na fuzzy množinách definovaná pomocí fuzzy konjunkce:

$$\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x).$$

Přitom  $\cap$  znamená obecný fuzzy průnik. Jednotlivé typy budeme rozlišovat stejnými indexy jako u příslušných fuzzy konjunkcí.

## 2.5. Fuzzy disjunkce (trojúhelníkové konormy)

**Definice 2.30.** *Fuzzy disjunkce*, (*trojúhelníková konorma*, *t-konorma*, angl. *triangular conorm*) je binární operace  $\dot{\vee} : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , splňující následující axiomy pro všechna  $\alpha, \beta, \gamma \in \langle 0, 1 \rangle$ :

$$\begin{aligned} \alpha \dot{\vee} \beta &= \beta \dot{\vee} \alpha && \text{(komutativita)} && \text{(S1)} \\ \alpha \dot{\vee} (\beta \dot{\vee} \gamma) &= (\alpha \dot{\vee} \beta) \dot{\vee} \gamma && \text{(asociativita)} && \text{(S2)} \\ \beta \leq \gamma &\Rightarrow \alpha \dot{\vee} \beta \leq \alpha \dot{\vee} \gamma && \text{(monotonie)} && \text{(S3)} \\ \alpha \dot{\vee} 0 &= \alpha && \text{(okrajová podmínka)} && \text{(S4)} \end{aligned}$$

**Příklad 2.31.**

- *Standardní* fuzzy disjunkce (*max*, *Gödelova*, *Zadehova* ...):

$$\alpha \overset{S}{\vee} \beta = \max(\alpha, \beta).$$

- *Lukasiewiczova* fuzzy disjunkce (*Gilesova*, angl. též *bold*, *bounded sum* ...):

$$\alpha \overset{L}{\vee} \beta = \begin{cases} \alpha + \beta & \text{pro } \alpha + \beta < 1, \\ 1 & \text{jinak.} \end{cases}$$

- *Součinnová* fuzzy disjunkce (*produktová*, *pravděpodobnostní* ...):

$$\alpha \overset{P}{\vee} \beta = \alpha + \beta - \alpha \cdot \beta.$$

- *Drastická* fuzzy disjunkce (*slabá*, angl. *weak* ...):

$$\alpha \overset{D}{\vee} \beta = \begin{cases} \alpha & \text{pro } \beta = 0, \\ \beta & \text{pro } \alpha = 0, \\ 1 & \text{jinak.} \end{cases}$$

**Věta 2.32.** Pro každou fuzzy disjunkci  $\dot{\vee}$  a  $\alpha \in \langle 0, 1 \rangle$  platí  $\alpha \dot{\vee} 1 = 1$ .

**Důkaz.** Podle (S3) a (S4) platí:  $\alpha \dot{\vee} 1 \stackrel{(S3)}{\geq} 0 \dot{\vee} 1 \stackrel{(S4)}{=} 1$ .  $\square$

Mezi fuzzy disjunkcemi uvažujeme stejné uspořádání jako u funkcí.



**Věta 2.33.** Mezi všemi fuzzy disjunkcemi je standardní nejmenší a drastická největší, tj. pro libovolnou fuzzy disjunkci  $\dot{\vee}$  platí

$$\forall \alpha, \beta \in \langle 0, 1 \rangle : \alpha \overset{S}{\dot{\vee}} \beta \leq \alpha \dot{\vee} \beta \leq \alpha \overset{D}{\dot{\vee}} \beta.$$

**Důkaz.** Je-li  $\alpha = 0$  nebo  $\beta = 0$ , pak podmínka (S4) dává stejný výsledek pro všechny fuzzy disjunkce. Předpokládejme (bez újmy na obecnosti)  $0 < \alpha \leq \beta$ . Pak

$$\alpha \overset{S}{\dot{\vee}} \beta = \beta = 0 \dot{\vee} \beta \leq \alpha \dot{\vee} \beta \leq 1 = \alpha \overset{D}{\dot{\vee}} \beta. \quad \square$$

**Věta 2.34.** Standardní fuzzy disjunkce je jediná, která je idempotentní, tj.  $\alpha \overset{S}{\dot{\vee}} \alpha = \alpha$  pro všechna  $\alpha \in \langle 0, 1 \rangle$ .

**Důkaz.** Nechť  $\dot{\vee}$  je idempotentní fuzzy disjunkce. Dokážeme, že je standardní.

Předpokládejme  $\alpha, \beta \in \langle 0, 1 \rangle$ ,  $\alpha \leq \beta$ . Pak

$$\alpha = \alpha \dot{\vee} \alpha \stackrel{(S3)}{\leq} \alpha \dot{\vee} \beta \stackrel{(S3)}{\leq} \alpha \dot{\vee} 1 \stackrel{(S4)}{=} \alpha,$$

tedy  $\alpha \dot{\vee} \beta = \alpha = \alpha \overset{S}{\dot{\vee}} \beta$ . Pro  $\alpha > \beta$  zaměníme  $\alpha, \beta$  a stejným postupem dostaneme  $\alpha \dot{\vee} \beta = \beta = \alpha \overset{S}{\dot{\vee}} \beta$ .  $\square$

**Věta 2.35.** Nechť  $\neg$  je fuzzy negace.

**A.** Je-li  $\wedge$  fuzzy konjunkce, pak de Morganova formule  $\alpha \dot{\vee} \beta = \neg(\neg \alpha \wedge \neg \beta)$  definuje fuzzy disjunkci  $\dot{\vee}$  *duální* k  $\wedge$  vzhledem k  $\neg$ .

**B.** Je-li  $\dot{\vee}$  fuzzy disjunkce, pak de Morganova formule  $\alpha \wedge \beta = \neg(\neg \alpha \dot{\vee} \neg \beta)$  definuje fuzzy konjunkci  $\wedge$  *duální* k  $\dot{\vee}$  vzhledem k  $\neg$ .

**Poznámka 2.36.** Pokud u duality neuvědeme, vzhledem k jaké negaci je chápána, pak automaticky předpokládáme standardní fuzzy negaci.

**Příklad 2.37.**

- Lukasiewiczovy operace  $\overset{L}{\wedge}, \overset{L}{\dot{\vee}}$  jsou duální vzhledem ke *standardní* negaci.
- Součinnové operace  $\overset{P}{\wedge}, \overset{P}{\dot{\vee}}$  jsou duální vzhledem ke *standardní* negaci.
- Standardní operace  $\overset{S}{\wedge}, \overset{S}{\dot{\vee}}$  jsou duální vzhledem k *jakékoli* fuzzy negaci.
- Drastické operace  $\overset{D}{\wedge}, \overset{D}{\dot{\vee}}$  jsou duální vzhledem k *jakékoli* fuzzy negaci.

Dále se zaměříme především na *spojité* fuzzy disjunkce. Z fuzzy disjunkcí z příkladu 2.31 pouze drastická je nespojitá.

**Definice 2.38.** Nechť  $\dot{\vee}$  je spojitá fuzzy disjunkce. Řekneme, že  $\dot{\vee}$  je

- *archimedovská* (angl. *archimedean*), jestliže

$$\forall \alpha \in \langle 0, 1 \rangle : \alpha \dot{\vee} \alpha > \alpha \tag{SA}$$

- *striktní*, (angl. *strict*), jestliže

$$\forall \alpha \in \langle 0, 1 \rangle \forall \beta, \gamma \in \langle 0, 1 \rangle : \beta < \gamma \Rightarrow \alpha \dot{\vee} \beta < \alpha \dot{\vee} \gamma \tag{S3+}$$

- *nilpotentní* (angl. *nilpotent*), jestliže je archimedovská a není striktní.

**Poznámka 2.39.** V některých pramenech jsou jako archimedovské označovány všechny – i nespojité – fuzzy disjunkce, které splňují (SA).

**Příklad 2.40.** Součinnová fuzzy disjunkce je striktní, Lukasiewiczova je nilpotentní, standardní a drastická nejsou archimedovské (standardní nesplňuje (SA), drastická není spojitá).

**Poznámka 2.41.** Podmínka (S3+) je silnější než (SA); stačí v ní dosadit  $\gamma := \alpha$ ,  $\beta := 0$ .

**Definice 2.42.** Chceme-li aplikovat fuzzy disjunkci  $\dot{\vee}$  na  $n$  argumentů  $\alpha_1, \dots, \alpha_n$ , použijeme zápis

$$\dot{\bigvee}_{k=1}^n \alpha_k = \alpha_1 \dot{\vee} \dots \dot{\vee} \alpha_n.$$

**Věta 2.43.** Nechť  $\dot{\vee}$  je archimedovská fuzzy disjunkce. Pak pro každé  $\alpha \in (0, 1)$  a  $\varepsilon > 0$  existuje  $n \in \mathbf{N}$  takové, že

$$\dot{\bigvee}_{k=1}^n \alpha > 1 - \varepsilon$$

Pro striktní fuzzy disjunkce nelze předchozí větu zesílit, pro nilpotentní ano:

**Věta 2.44.** Nechť  $\dot{\vee}$  je nilpotentní fuzzy disjunkce. Pak pro každé  $\alpha \in (0, 1)$  existuje  $n \in \mathbf{N}$  takové, že

$$\dot{\bigvee}_{k=1}^n \alpha = 1$$

**Věta 2.45 (o reprezentaci striktních fuzzy disjunkcí).** **A.** Nechť  $i : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$  je rostoucí bijekce. Pak operace  $\dot{\vee} : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , definovaná vztahem

$$\alpha \dot{\vee} \beta = i^{-1}(i(\alpha) \overset{P}{\vee} i(\beta)),$$

je striktní fuzzy disjunkce.

**B.** Naopak, každá striktní fuzzy disjunkce  $\dot{\vee}$  je uvedeného tvaru pro nějakou rostoucí bijekci  $i$ .

**Věta 2.46 (o reprezentaci nilpotentních fuzzy disjunkcí).** **A.** Nechť  $i : \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$  je rostoucí bijekce. Pak operace  $\dot{\vee} : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , definovaná vztahem

$$\alpha \dot{\vee} \beta = i^{-1}(i(\alpha) \overset{L}{\vee} i(\beta)),$$

je nilpotentní fuzzy disjunkce.

**B.** Naopak, každá nilpotentní fuzzy disjunkce  $\dot{\vee}$  je uvedeného tvaru pro nějakou rostoucí bijekci  $i$ , kterou nazýváme *aditivní generátor*.

Poznamenejme ještě důležitou vlastnost archimedovských disjunkcí:

**Věta 2.47.** Je-li  $\dot{\vee}$  archimedovská disjunkce a  $\alpha_i > 0$ , kde  $i \in I$  a  $I$  je nespočetná množina, pak

$$\dot{\bigvee}_{i \in I} \alpha_i = 1.$$

Důkaz i význam této věty je obdobný jako u věty ??.

**Definice 2.48.** *Fuzzy sjednocení* je operace na fuzzy množinách definovaná pomocí fuzzy disjunkce:

$$\mu_{A \dot{\cup} B}(x) = \mu_A(x) \dot{\vee} \mu_B(x).$$

Přitom  $\dot{\cup}$  znamená obecné fuzzy sjednocení. Jednotlivé typy budeme rozlišovat stejnými indexy jako u fuzzy disjunkcí.

## 2.6. Fuzzy výrokové algebry

Dosud jsme zavedli 3 základní logické spojky – negaci, konjunkci a disjunkci. Pomocí nich lze vytvářet další logické formule. V této kapitole porovnáme, jaké zákony tyto operace splňují. Východiskem bude tabulka zákonů Booleových algeber, přepsaných pro fuzzy logické operace.

**Tabulka 2.49.** Analogie zákonů Booleových algeber pro fuzzy logické operace (platné pouze pro některé volby fuzzy operací).

involute:	$\neg(\neg\alpha) = \alpha,$	
komutativita:	$\alpha \dot{\vee} \beta = \beta \dot{\vee} \alpha,$	$\alpha \wedge \beta = \beta \wedge \alpha,$
asociativita:	$(\alpha \dot{\vee} \beta) \dot{\vee} \gamma = \alpha \dot{\vee} (\beta \dot{\vee} \gamma),$	$(\alpha \wedge \beta) \wedge \gamma = \alpha \wedge (\beta \wedge \gamma),$
distributivita:	$\alpha \wedge (\beta \dot{\vee} \gamma) = (\alpha \wedge \beta) \dot{\vee} (\alpha \wedge \gamma),$	$\alpha \dot{\vee} (\beta \wedge \gamma) = (\alpha \dot{\vee} \beta) \wedge (\alpha \dot{\vee} \gamma),$
idempotence:	$\alpha \dot{\vee} \alpha = \alpha,$	$\alpha \wedge \alpha = \alpha,$
absorpce:	$\alpha \dot{\vee} (\alpha \wedge \beta) = \alpha,$	$\alpha \wedge (\alpha \dot{\vee} \beta) = \alpha,$
absorpce s jedničkou a nulou:	$\alpha \dot{\vee} 1 = 1,$	$\alpha \wedge 0 = 0,$
neutrální prvky:	$\alpha \dot{\vee} 0 = \alpha,$	$\alpha \wedge 1 = \alpha,$
zákon kontradikce:		$\alpha \wedge \neg\alpha = 0,$
zákon vyloučeného třetího:	$\alpha \dot{\vee} \neg\alpha = 1,$	
de Morganovy zákony:	$\neg(\alpha \dot{\vee} \beta) = \neg\alpha \wedge \neg\beta,$	$\neg(\alpha \wedge \beta) = \neg\alpha \dot{\vee} \neg\beta.$

**Věta 2.50.** Pro libovolnou fuzzy negaci, fuzzy konjunci a fuzzy disjunci platí následující zákony z tabulky 2.49: involuce, komutativita, asociativita, absorpce s jedničkou a nulou, neutrální prvky.

**Věta 2.51.** Standardní fuzzy operace  $\neg_s, \wedge_s, \dot{\vee}_s$  splňují všechny zákony z tabulky 2.49 kromě zákona kontradikce a zákona vyloučeného třetího.

**Příklad 2.52.** Pro  $\alpha = 1/3$  dostáváme

$$\begin{aligned}\neg_s \alpha \wedge_s \alpha &= \frac{2}{3} \wedge_s \frac{1}{3} = 1/3 \neq 0, \\ \neg_s \alpha \dot{\vee}_s \alpha &= \frac{2}{3} \dot{\vee}_s \frac{1}{3} = 2/3 \neq 1.\end{aligned}$$

Vždy však platí  $\neg_s \alpha \wedge_s \alpha \leq \frac{1}{2}$ ,  $\neg_s \alpha \dot{\vee}_s \alpha \geq \frac{1}{2}$ .

**Poznámka 2.53.** Speciálně upozorňujeme, že standardní operace splňují oba distributivní zákony.

**Věta 2.54.** Lukasiewiczovy operace  $\neg_s, \wedge_L, \dot{\vee}_L$  splňují všechny vztahy z tabulky 2.49 kromě distributivity, idempotence a zákonů absorpce.

**Poznámka 2.55.** Zdůrazněme, že Lukasiewiczovy operace splňují zákon kontradikce a zákon vyloučeného třetího.

**Věta 2.56.** Součinnové operace  $\neg_s, \wedge_P, \dot{\vee}_P$  splňují pouze vztahy z věty 2.50 a de Morganovy zákony.

Mohlo by se zdát, že vhodnou volbou fuzzy operací by mohlo být splněno ještě více zákonů klasické logiky, případně všechny. To však není možné, protože tyto zákony definují Booleovy algebry a nemohou tudíž všechny platit pro netriviální zobecnění, jakým fuzzy operace jsou. Uvedeme ještě konkrétní příklad rozporu, jemuž se nelze vyhnout při zobecnění výrokových operací na  $\langle 0, 1 \rangle$ .

**Věta 2.57.** Splňují-li fuzzy operace  $\neg, \wedge, \dot{\vee}$  na  $\langle 0, 1 \rangle$  de Morganovy zákony, zákon kontradikce a zákon vyloučeného třetího, pak nesplňují distributivitu.

**Důkaz.** Nechť  $e \in (0, 1)$  je rovnovážná hodnota fuzzy negace  $\neg$ , tj.  $\neg e = e$ . Pak

$$\begin{aligned}e \dot{\vee} e &= \neg e \dot{\vee} e = 1, \\ e \wedge e &= \neg e \wedge e = 0.\end{aligned}$$

Z distributivity by plynulo například

$$e \wedge (e \dot{\vee} e) = (e \wedge e) \dot{\vee} (e \wedge e).$$

Podle předchozího se však levá strana rovná  $e \wedge 1 = e$ , zatímco pravá je  $0 \dot{\vee} 0 = 0$ , což je spor. Není tedy možné, aby byly všechny uvedené vlastnosti splněny současně.  $\square$

**Poznámka 2.58.** Z reprezentačních vět pro fuzzy negace a pro striktní a nilpotentní fuzzy konjunkce (resp. disjunkce) by se mohlo zdát, že stačí změnit měřítko pomocí vhodné rostoucí bijekce  $i: \langle 0, 1 \rangle \rightarrow \langle 0, 1 \rangle$ , abychom mohli místo obecných operací pracovat se standardní fuzzy negací a součinnou nebo Lukasiewiczovou fuzzy konjunkcí. Takové zjednodušení není obecně možné. Problém je v tom, že rostoucí generátor příslušné fuzzy negace nemusí být multiplikativní či Lukasiewiczův generátor uvažované fuzzy konjunkce.

Změnou měřítka lze proto splnit jen jeden cíl – buď mít „pěknou“ (rozuměj standardní) fuzzy negaci a obecnou fuzzy konjunkci, nebo mít „pěknou“ (rozuměj součinnou nebo Lukasiewiczovu) fuzzy konjunkci a obecnou fuzzy negaci.

Obojí najednou splnit obvykle nelze. Zde se kloníme k prvnému případu, neboť každá fuzzy negace je až na změnu měřítka izomorfní se standardní fuzzy negací, kdežto reprezentační věty pro fuzzy konjunkce nejsou tak univerzální.

Stejná úvaha platí i pro fuzzy disjunkce místo konjunkcí.

## 2.7. Fuzzy implikace

Na rozdíl od předchozích operací, pro implikace není ustálená axiomatická definice. Proto budeme za *fuzzy implikaci* považovat jakoukoli operaci  $\dot{\rightarrow} : \langle 0, 1 \rangle^2 \rightarrow \langle 0, 1 \rangle$ , která se na  $\{0, 1\}^2$  shoduje s klasickou implikací. Místo podrobnější axiomatiky uvedeme přímo způsoby, kterými jsou nejdůležitější fuzzy implikace konstruovány z jiných fuzzy operací. Zaměříme se na 3 nejčastěji používané typy implikací:

$$\alpha \xrightarrow{S} \beta = \neg_S \alpha \dot{\vee} \beta \quad (\text{SI})$$

$$\alpha \xrightarrow{Q} \beta = \neg_S \alpha \dot{\vee} (\alpha \wedge \beta) \quad (\text{QI})$$

$$\alpha \xrightarrow{R} \beta = \sup\{\gamma : \alpha \wedge \gamma \leq \beta\} \quad (\text{RI})$$

V Boolově algebře všechny tři vzorce definují tutéž klasickou implikaci. Ve fuzzy logice se obecně liší a vedou na 3 třídy fuzzy implikací. Další členění závisí na volbě fuzzy operací na pravých stranách vzorců.

**Definice 2.59.** Vzorec (RI) definuje *reziduovanou fuzzy implikaci (reziduum, R-implikaci)* příslušnou fuzzy konjunkci  $\wedge$ . Dolní index použijeme stejný jako u odpovídající fuzzy konjunkce.

**Příklad 2.60.** Od standardní fuzzy konjunkce  $\wedge_S$  je odvozena *Gödelova fuzzy implikace*

$$\alpha \xrightarrow{R_S} \beta = \begin{cases} 1 & \text{pro } \alpha \leq \beta, \\ \beta & \text{jinak.} \end{cases}$$

Tato fuzzy implikace je po částech lineární a spojitá s výjimkou bodů  $(\alpha, \alpha)$ ,  $\alpha < 1$ .

**Příklad 2.61.** Od Lukasiewiczovy fuzzy konjunkce  $\wedge_L$  je odvozena *Lukasiewiczova fuzzy implikace*

$$\alpha \xrightarrow{R_L} \beta = \begin{cases} 1 & \text{pro } \alpha \leq \beta, \\ 1 - \alpha + \beta & \text{jinak.} \end{cases}$$

Tato fuzzy implikace je po částech lineární a všude spojitá.

**Příklad 2.62.** Od součinné fuzzy konjunkce  $\wedge_P$  je odvozena *Goguenova (též Gainesova) fuzzy implikace*

$$\alpha \xrightarrow{R_P} \beta = \begin{cases} 1 & \text{pro } \alpha \leq \beta, \\ \frac{\beta}{\alpha} & \text{jinak.} \end{cases}$$

Tato fuzzy implikace má jediný bod nespojitosti  $(0, 0)$ .

**Věta 2.63.** Každá reziduovaná implikace  $\xrightarrow{R}$  splňuje následující podmínky:

$$\alpha \xrightarrow{R} \beta = 1, \text{ právě když } \alpha \leq \beta, \quad (\text{I1})$$

$$1 \xrightarrow{R} \beta = \beta, \quad (\text{I2})$$

$$\xrightarrow{R} \text{ je nerostoucí v 1. argumentu a neklesající v 2. argumentu.} \quad (\text{I3})$$

**Věta 2.64.** Nechť  $\overset{\cdot}{\wedge}_i$  je striktní fuzzy konjunkce s multiplikativním generátorem  $i$  (dle věty 2.25). Pak pro příslušnou reziduovanou implikaci  $\overset{R}{\rightarrow}_i$  platí

$$\alpha \overset{R}{\rightarrow}_i \beta = \begin{cases} 1 & \text{pro } \alpha \leq \beta, \\ i^{-1} \left( \frac{i(\beta)}{i(\alpha)} \right) & \text{jinak.} \end{cases}$$

**Věta 2.65.** Nechť  $\overset{\cdot}{\wedge}_i$  je nilpotentní fuzzy konjunkce s Łukasiewiczovým generátorem  $i$  (dle věty 2.27). Pak pro příslušnou reziduovanou implikaci  $\overset{R}{\rightarrow}_i$  platí

$$\alpha \overset{R}{\rightarrow}_i \beta = \begin{cases} 1 & \text{pro } \alpha \leq \beta, \\ i^{-1}(1 - i(\alpha) + i(\beta)) & \text{jinak.} \end{cases}$$

**Důsledek 2.66.** Reziduovaná fuzzy implikace příslušná archimedovské fuzzy konjunkci  $\overset{\cdot}{\wedge}$  je spojitá, právě když  $\overset{\cdot}{\wedge}$  je nilpotentní.

**Definice 2.67.** Vzorec (SI) definuje *S-implikaci* odpovídající fuzzy disjunkci  $\overset{\cdot}{\vee}$  a fuzzy negaci  $\overset{\cdot}{\neg}_S$ . Při konstrukci S-implikace zde uvažujeme vždy pouze standardní fuzzy negaci a dolní index S-implikace bude označovat použitou fuzzy disjunkci.

**Příklad 2.68.** Ze standardní fuzzy disjunkce dostáváme *Kleeneovu-Dienesovu* fuzzy implikaci

$$\alpha \overset{S}{\rightarrow} \beta = \max(1 - \alpha, \beta).$$

**Příklad 2.69.** Z Łukasiewiczovy fuzzy disjunkce dostáváme *Łukasiewiczovu* fuzzy implikaci  $\overset{S}{\rightarrow}_L$ , která se shoduje s Łukasiewiczovou reziduovanou fuzzy implikací  $\overset{R}{\rightarrow}_L$ .

**Příklad 2.70.** Ze součinnové fuzzy disjunkce dostáváme *Reichenbachovu* fuzzy implikaci

$$\alpha \overset{S}{\rightarrow}_P \beta = 1 - \alpha + \alpha\beta.$$

**Definice 2.71.** Nechť  $\overset{\cdot}{\wedge}$  je fuzzy konjunkce a  $\overset{\cdot}{\vee}$  fuzzy disjunkce duální k  $\overset{\cdot}{\wedge}$  (vzhledem k  $\overset{\cdot}{\neg}_S$ ). Pak vzorec (QI) definuje *Q-implikaci* odpovídající fuzzy konjunkci  $\overset{\cdot}{\wedge}$  a fuzzy negaci  $\overset{\cdot}{\neg}_S$ . Při konstrukci Q-implikace zde uvažujeme vždy pouze standardní fuzzy negaci a dolní index Q-implikace označuje použitou fuzzy konjunkci.

**Poznámka 2.72.** Písmeno „Q“ v termínu Q-implikace znamená „kvantová“ (angl. *quantum*), neboť obdobně zavedené operace hrají důležitou roli v kvantových logikách.

**Příklad 2.73.** Ze standardní fuzzy konjunkce dostáváme *původní Zadehovu* fuzzy implikaci (angl. *early Zadeh fuzzy implication*)

$$\alpha \overset{Q}{\rightarrow}_S \beta = \overset{\cdot}{\neg}_S \alpha \overset{\cdot}{\vee}_S (\alpha \overset{\cdot}{\wedge}_S \beta).$$

Z Łukasiewiczovy fuzzy konjunkce dostáváme již známou *Kleeneovu-Dienesovu* fuzzy implikaci

$$\alpha \overset{Q}{\rightarrow}_L \beta = \overset{\cdot}{\neg}_S \alpha \overset{\cdot}{\vee}_L (\alpha \overset{\cdot}{\wedge}_L \beta) = \overset{\cdot}{\neg}_S \alpha \overset{\cdot}{\vee}_S \beta = \max(1 - \alpha, \beta) = \alpha \overset{S}{\rightarrow} \beta.$$

Na fuzzy implikace je možno klást i další požadavky. Kromě již uvedených (I1), (I2), (I3) se často požaduje:

$$\alpha \overset{\cdot}{\rightarrow} \beta = \overset{\cdot}{\neg} \beta \overset{\cdot}{\rightarrow} \overset{\cdot}{\neg} \alpha, \quad (I4)$$

$$\alpha \overset{\cdot}{\rightarrow} (\beta \overset{\cdot}{\rightarrow} \gamma) = \beta \overset{\cdot}{\rightarrow} (\alpha \overset{\cdot}{\rightarrow} \gamma), \quad (I5)$$

$$\text{spojitost.} \quad (I6)$$

Všechny požadavky (I1)–(I6) splňují ze zde probíraných fuzzy implikací pouze ty reziduované, které odpovídají nilpotentním fuzzy konjunkcím dle věty 2.27. Příkladem je Łukasiewiczova fuzzy implikace.

Vzorec pro S-implikaci používá fuzzy negaci, která musí být předem dána. Naopak reziduovanou implikaci lze použít pro definici *zobecněné fuzzy negace*  $\overset{\cdot}{\neg}$  předpisem

$$\overset{\cdot}{\neg} \alpha = \alpha \overset{R}{\rightarrow} 0.$$

Použijeme-li na pravé straně například Gödelovu nebo Goguenovu fuzzy implikaci ( $\overset{R}{\rightarrow}_S$  nebo  $\overset{R}{\rightarrow}_P$ ), dostaneme Gödelovu zobecněnou fuzzy negaci  $\overset{\cdot}{\neg}_G$ . Łukasiewiczova fuzzy implikace  $\overset{R}{\rightarrow}_L$  dává tímto způsobem standardní fuzzy negaci  $\overset{\cdot}{\neg}_S$ .

**Poznámka 2.74.** Pojem fuzzy implikace není dosud ustálený. Někteří autoři [10, 11] uvažují pouze reziduované fuzzy implikace. Naopak v některých pramenech jsou jako fuzzy implikace označovány i operace, které se ani na  $\{0, 1\}^2$  neshodují s klasickou implikací. Například standardní konjunkce  $\wedge_S$  je někdy nevhodně označována jako „Mamdaniho implikace“.

## 2.8. Fuzzy biimplikace (ekvivalence)

Od implikace  $\dot{\rightarrow}$  se odvozuje komutativní operace  $\dot{\leftrightarrow}$ , obvykle definovaná vztahem

$$\alpha \dot{\leftrightarrow} \beta = (\alpha \dot{\rightarrow} \beta) \wedge (\beta \dot{\rightarrow} \alpha).$$

Pokud  $\dot{\rightarrow}$  splňuje (I1) (například pro reziduovanou implikaci), je vždy aspoň jedna ze závorek na pravé straně rovna jedné, takže nezáleží na volbě fuzzy konjunkce  $\wedge$ . Výsledná operace  $\dot{\leftrightarrow}$  bývá označována jako *fuzzy ekvivalence*. Protože však pojem ekvivalence označuje i speciální relaci (viz dále), dáváme zde přednost (rovněž častému) pojmu *fuzzy biimplikace*. Indexujeme ji stejně jako fuzzy implikaci, z níž vznikla.

**Příklad 2.75.** *Lukasiewiczova* fuzzy biimplikace:  $\alpha \overset{R}{\underset{L}{\leftrightarrow}} \beta = 1 - |\alpha - \beta|$ .  
*Gödelova* fuzzy biimplikace:

$$\alpha \overset{R}{\underset{S}{\leftrightarrow}} \beta = \begin{cases} 1 & \text{pro } \alpha = \beta, \\ \alpha \wedge_S \beta & \text{jinak.} \end{cases}$$

*Součinnová* fuzzy biimplikace:

$$\alpha \overset{R}{\underset{P}{\leftrightarrow}} \beta = \begin{cases} 1 & \text{pro } \alpha = \beta = 0, \\ \frac{\alpha \wedge_S \beta}{\alpha \vee_S \beta} & \text{jinak.} \end{cases}$$

**Věta 2.76.** Pro reziduovanou fuzzy implikaci  $\overset{R}{\rightarrow}$  a jí příslušnou fuzzy biimplikaci platí

$$\alpha \overset{R}{\leftrightarrow} \beta = (\alpha \overset{S}{\vee} \beta) \overset{R}{\rightarrow} (\alpha \wedge_S \beta).$$

## 2.9. Agregáčnı́ operátory

Dosud uvedené fuzzy logické operace se snažily o zobecnění operací klasické logiky. Pro zpracování vágních informací však bývají užitečné i operace, které žádnou analogii v Booleových algebrách nemají. Jako příklad uvažujme sdružení informací, které nám o téže otázce poskytne skupina expertů. Z jejich údajů chceme vypočítat jeden „kolektivní názor“, jakýsi druh průměru. K tomu účelu se nabízejí agregáčnı́ operátory a jejich podtřída, fuzzy průměry. (Zde prezentovaný přístup je převzat z [6].)

V této kapitole se budeme zabývat operátory, jejichž počet argumentů (arita) není pevně daný, ale může jím být libovolné celé číslo  $n \geq 2$ . *Agregáčnı́ operátor* (angl. *aggregation operator*) je zobrazení  $h$ , které každé  $n$ -tici hodnot z  $\langle 0, 1 \rangle$  ( $n \geq 2$ ) přiřadí číslo z  $\langle 0, 1 \rangle$  v souladu s následujícími podmínkami:

$$h(0, \dots, 0) = 0, \quad h(1, \dots, 1) = 1, \tag{A1}$$

$$(\forall i = 1, \dots, n : \alpha_i \leq \beta_i) \Rightarrow h(\alpha_1, \dots, \alpha_n) \leq h(\beta_1, \dots, \beta_n), \tag{A2}$$

$$h \text{ je spojité.} \tag{A3}$$

Agregáčnı́ operátor se nazývá *fuzzy průměr* (angl. *averaging operator*), splňuje-li navíc podmínky

$$\text{pro každou permutaci } p \text{ čísel } 1, \dots, n \text{ je } h(\alpha_{p(1)}, \dots, \alpha_{p(n)}) = h(\alpha_1, \dots, \alpha_n), \tag{A4}$$

$$\forall \alpha \in \langle 0, 1 \rangle : h(\alpha, \dots, \alpha) = \alpha. \tag{A5}$$

(Podmínka (A5) je zesílením podmínky (A1).)

**Příklad 2.77.** Všechny fuzzy konjunkce a disjunkce splňují podmínky (A1)–(A4), takže to jsou agregáční operátory. Standardní fuzzy konjunkce a disjunkce splňují i idempotenci (A5), jsou to tedy fuzzy průměry.

**Věta 2.78.** Pokud  $h$  splňuje podmínky (A2), (A5), pak  $\min \leq h \leq \max$  (ve smyslu uspořádání funkcí).

**Poznámka 2.79.** Někdy budeme připouštět i agregáční operátory, které nejsou definovány na celém oboru  $\langle 0, 1 \rangle^n$ .

**Příklad 2.80.** *Zobecněný průměr* (angl. *generalized means*)  $h_\lambda$  je pro  $\lambda \in \mathbf{R}$ ,  $\lambda \neq 0$ , definován vzorcem

$$h_\lambda(\alpha_1, \dots, \alpha_n) = \left( \frac{1}{n} \sum_{i=1}^n \alpha_i^\lambda \right)^{\frac{1}{\lambda}}.$$

(Pro  $\lambda < 0$  je definován jen pro  $\alpha_i$  kladná.) Je to fuzzy průměr.

Speciálně dostáváme:

- pro  $\lambda = 1$  aritmetický průměr,
- pro  $\lambda = 2$  kvadratický průměr,
- pro  $\lambda = -1$  harmonický průměr,
- pro  $\lambda \rightarrow 0$  geometrický průměr,
- pro  $\lambda \rightarrow +\infty$  maximum,
- pro  $\lambda \rightarrow -\infty$  minimum.

**Příklad 2.81.** *Vážený průměr*  $h_w$  je pro  $n \in \mathbf{N}$  určen vektorem vah  $w = (w_1, \dots, w_n) \in \langle 0, 1 \rangle^n$  splňujícím  $\sum_{i=1}^n w_i = 1$ :

$$h_w(\alpha_1, \dots, \alpha_n) = \sum_{i=1}^n w_i \alpha_i.$$

Splňuje (A1)–(A3) a (A5), je to tedy agregáční operátor, který je aditivní; tj. splňuje

$$h(\alpha_1 + \beta_1, \dots, \alpha_n + \beta_n) = h(\alpha_1, \dots, \alpha_n) + h(\beta_1, \dots, \beta_n).$$

(Aditivita je slabší forma linearity.)

**Příklad 2.82.** *Uspořádaný vážený průměr* (ang. *ordered weighted averaging operator, OWA-operator*)  $\bar{h}_w$  je určen vektorem vah  $w = (w_1, \dots, w_n) \in \langle 0, 1 \rangle^n$  splňujícím  $\sum_{i=1}^n w_i = 1$ :

$$\bar{h}_w(\alpha_1, \dots, \alpha_n) = \sum_{i=1}^n w_i \alpha_{p(i)},$$

kde  $p$  je permutace indexů taková, že

$$\alpha_{p(1)} \leq \alpha_{p(2)} \leq \dots \leq \alpha_{p(n)}.$$

Od váženého průměru se liší tím, že nejprve argumenty seřadíme podle velikosti, a teprve pak jim přiřadíme váhy (podle jejich pořadí v uspořádané posloupnosti). Díky tomu je splněna i podmínka (A4) a dostáváme fuzzy průměr.

Speciálně dostáváme

- pro  $w = (1, 0, \dots, 0)$  minimum,
- pro  $w = (0, \dots, 0, 1)$  maximum,
- pro  $w = (1/n, 1/n, \dots, 1/n)$  aritmetický průměr.
- pro  $w = (0, 1/(n-2), 1/(n-2), \dots, 1/(n-2), 0)$  operátor, používaný např. v hodnocení krasobruslařů — napřed se vyškrtne největší a nejmenší prvek, pak se ze zbývajících vypočte aritmetický průměr.

Mnoho dalších příkladů lze zkonstruovat pomocí následující věty.

**Věta 2.83.** Nechť  $h, h_1, \dots, h_k$  jsou agregáční operátory (resp. fuzzy průměry). Pak zobrazení

$$H(\alpha_1, \dots, \alpha_n) = h(h_1(\alpha_1, \dots, \alpha_n), \dots, h_k(\alpha_1, \dots, \alpha_n))$$

je agregáční operátor (resp. fuzzy průměr).

### 3. Fuzzy relace

V této kapitole se budeme zabývat fuzzifikací binárních relací. Nejprve připomeneme potřebné pojmy pro ostré množiny.

#### 3.1. Binární relace v klasické teorii množin

**Definice 3.1.** Nechtě  $X, Y$  jsou množiny. Binární *relace*  $R$  z  $X$  do  $Y$  je (jakákoli) podmnožina kartézského součinu  $X \times Y$ . Ve vztahu k relaci  $R \subseteq X \times Y$  označujeme  $X$  jako množinu *vzorů* a  $Y$  jako množinu *obrazů*. *Inverzní relace* k  $R$  je relace  $R^{-1}$  z  $Y$  do  $X$

$$R^{-1} = \{(y, x) \in Y \times X : (x, y) \in R\}.$$

**Definice 3.2.** Nechtě  $X, Y, Z$  jsou množiny. *Složená relace* z relací  $R \subseteq X \times Y, S \subseteq Y \times Z$  je relace  $R \circ S$  z  $X$  do  $Z$

$$R \circ S = \{(x, z) \in X \times Z : (\exists y \in Y : (x, y) \in R, (y, z) \in S)\}.$$

Pokud je stejná množina  $X$  množinou vzorů i množinou obrazů, pak mezi podmnožinami kartézského součinu  $X \times X$  rozlišujeme následující *speciální relace*:

**Definice 3.3.** Nechtě  $X$  je množina. *Rovnost* na  $X$  je relace

$$E = \{(x, x) : x \in X\}.$$

Pro  $R \subseteq X \times X$  definujeme

- *reflexivitu*:  $\forall x \in X : (x, x) \in R$ , tj.  $E \subseteq R$ ,
- *symetrii*:  $(x, y) \in R \Rightarrow (y, x) \in R$ , tj.  $R = R^{-1}$ ,
- *antisymetrii*:  $((x, y) \in R) \wedge ((y, x) \in R) \Rightarrow x = y$ , tj.  $R \cap R^{-1} \subseteq E$ ,
- *tranzitivitu*:  $((x, y) \in R) \wedge ((y, z) \in R) \Rightarrow (x, z) \in R$ , tj.  $R \circ R \subseteq R$ ,
- *částečné uspořádání*: relace antisymetrická, reflexivní a tranzitivní,
- *ekvivalenci*: relace symetrická, reflexivní a tranzitivní.

**Poznámka 3.4.** Zde používaný termín ekvivalence pro *binární relaci* nemá nic společného s biimplikací (rovněž nazývanou ekvivalence) z odstavce 2.8. Biimplikace je *binární operace*, tedy *ternární relace*.

Vyjádříme předchozí pojmy pomocí funkcí příslušnosti. Ostré relaci  $R \subseteq X \times Y$  odpovídá funkce příslušnosti  $\mu_R : X \times Y \rightarrow \{0, 1\}$ . Inverzní relace  $R^{-1} \subseteq Y \times X$  má funkci příslušnosti

$$\mu_{R^{-1}}(y, x) = \mu_R(x, y).$$

(Zde se hodí, že rozlišujeme fuzzy množiny a jejich funkce příslušnosti; díky tomu se odliší funkce příslušnosti inverzní relace,  $\mu_{R^{-1}}$ , od inverze k funkci příslušnosti původní relace,  $\mu_R^{-1}$ .) Složená relace z relací  $R \subseteq X \times Y$  a  $S \subseteq Y \times Z$  je  $R \circ S \subseteq X \times Z$  určená funkcí příslušnosti

$$\mu_{R \circ S}(x, z) = \sup_{y \in Y} \{\mu_R(x, y) \wedge \mu_S(y, z)\},$$

kde  $\wedge$  je klasická konjunkce.

Relaci rovnosti,  $E \subseteq X \times X$  odpovídá funkce příslušnosti

$$\mu_E(x, y) = \delta(x, y) = \begin{cases} 1 & \text{pro } x = y, \\ 0 & \text{pro } x \neq y, \end{cases}$$

tedy jedná se o binární operaci známou jako *Kroneckerovo delta*, nadále ji budeme značit  $\delta$ .

Ostatní speciální relace již byly charakterizovány i ve tvarech, jaké potřebujeme pro další zobecnění.



### 3.2. Fuzzifikace binárních relací

**Definice 3.5.** Nechť  $X, Y$  jsou ostré množiny. *Fuzzy relace*  $R$  z  $X$  do  $Y$  je (jakákoli) fuzzy podmnožina kartézského součinu  $X \times Y$ , tedy  $R \in \mathcal{F}(X \times Y)$ . Odpovídá jí funkce příslušnosti  $\mu_R : X \times Y \rightarrow \langle 0, 1 \rangle$ . *Inverzní relace* k  $R$  je  $R^{-1} \in \mathcal{F}(Y \times X)$  taková, že  $\forall x \in X \forall y \in Y : \mu_{R^{-1}}(y, x) = \mu_R(x, y)$ .

**Definice 3.6.** Nechť  $X, Y, Z$  jsou ostré množiny,  $R \in \mathcal{F}(X \times Y)$ ,  $S \in \mathcal{F}(Y \times Z)$  a  $\wedge$  je fuzzy konjunkce. Pak *--složená relace*  $R \circ S \in \mathcal{F}(X \times Z)$  je určena funkcí příslušnosti

$$\mu_{R \circ S}(x, z) = \bigvee_{y \in Y}^S \mu_R(x, y) \wedge \mu_S(y, z),$$

Dostáváme různé typy skládání, které označujeme stejným indexem jako příslušnou fuzzy konjunkci a hovoříme o  $S$ -skládání (standardním skládání) apod.

**Poznámka 3.7.** Roli existenčního kvantifikátoru z definice skládání ostrých relací zde přebírá standardní fuzzy disjunkce přes všechny hodnoty  $y \in Y$ . I zde bychom si mohli představit jinou fuzzy disjunkci. Protože však množina  $Y$  může být nekonečná, ba i nespočetná, podle věty ?? by výsledek byl velmi často jednotkový a nenesl by užitečnou informaci o argumentech.

**Poznámka 3.8.** Pro konečné množiny  $X, Y, Z$  lze fuzzy relace reprezentovat maticemi a složenou relaci počítat obdobně jako součin matic, kde místo součinu prvků aplikujeme fuzzy konjunkci  $\wedge$  a místo součtu standardní fuzzy disjunkci  $\check{\vee}$ , tedy maximum.

Speciální fuzzy relace lze zavést zcela analogicky jako pro ostré relace:

**Definice 3.9.** Nechť  $X$  je ostrá množina. Pro  $R \in \mathcal{F}(X \times X)$  definujeme

- *reflexivitu*:  $\delta \subseteq R$ ,
- *symetrii*:  $R = R^{-1}$ ,
- *--antisymetrii*:  $R \cap R^{-1} \subseteq \delta$ ,
- *--tranzitivitu*:  $R \circ R \subseteq R$ ,
- *--částečné uspořádání*: fuzzy relace --antisymetrická, reflexivní a --tranzitivní,
- *--ekvivalenci*: fuzzy relace symetrická, reflexivní a --tranzitivní.

Je třeba mít na paměti, že poslední čtyři pojmy závisí na volbě fuzzy konjunkce  $\wedge$ , vyskytující se v příslušných vztazích. Pro ostré množiny všechny tyto pojmy mají svůj obvyklý význam z klasické teorie množin.

**Věta 3.10 (vlastnosti skládání fuzzy relací).** Nechť  $R, S$  a  $T$  jsou fuzzy relace s takovými definičními obory, aby následující rovnosti (postupně, ne všechny současně) měly smysl. Platí:

$$R \circ (S \circ T) = (R \circ S) \circ T \quad (\text{asociativita})$$

$$(R \check{\cup} S) \circ T = (R \circ T) \check{\cup} (S \circ T) \quad (\text{distributivita zprava})$$

$$R \circ (S \check{\cup} T) = (R \circ S) \check{\cup} (R \circ T) \quad (\text{distributivita zleva})$$

kde  $\circ$  značí --skládání vzhledem k libovolně pevně zvolené fuzzy konjunkci  $\wedge$ . U distributivity můžeme také nahradit sjednocení  $\check{\cup}$  průnikem  $\cap$ .

### 3.3. Konzistence fuzzy relací

V této části podáme některé vlastnosti fuzzy množin, zejména fuzzy relací, které nemají adekvátní obdobu v ostrých množinách. Nejprve vezmeme na vědomí následující skutečnost.

**Věta 3.11.** Vytvoření  $\alpha$ -řezu fuzzy množiny (kde  $\alpha \in \langle 0, 1 \rangle$ ) lze interpretovat jako specifický způsob defuzzifikace: Uvažujme skokovou funkci  $r_\alpha : \langle 0, 1 \rangle \rightarrow \{0, 1\}$ :

$$r_\alpha(\beta) = \begin{cases} 1 & \text{pro } \beta \geq \alpha, \\ 0 & \text{pro } \beta < \alpha. \end{cases}$$

Pro  $A \in \mathcal{F}(X)$ ,  $x \in X$  platí  $\mu_{R_A(\alpha)}(x) = r_\alpha(\mu_A(x)) = (r_\alpha \circ \mu_A)(x)$ , tj.  $\mu_{R_A(\alpha)} = r_\alpha \circ \mu_A$ , kde  $\circ$  je (obyčejné) skládání zobrazení.

**Definice 3.12.** Vlastnost fuzzy množiny se nazývá *konzistentní* (angl. *cutworthy*), jestliže každá fuzzy množina  $A$  má tuto vlastnost, právě když tutéž vlastnost mají všechny  $\alpha$ -řezy  $R_A(\alpha)$  pro  $\alpha > 0$ .

**Poznámka 3.13.** Triviální 0-řez  $R_A(0) = X$  zde záměrně neuvažujeme.

**Příklad 3.14.** Uvažujme následující vlastnost fuzzy množiny  $A$  (tzv. *silnou normalitu*):  $\exists x \in X : \mu_A(x) = 1$ . Tato vlastnost je konzistentní. (Pro ostré množiny se tato vlastnost shoduje s neprázdnotí.) Naproti tomu „ostrost množiny“ není konzistentní, neboť všechny řezy fuzzy množiny jsou ostré, i když tato fuzzy množina ostrá není.

**Věta 3.15.** Následující vlastnosti fuzzy relací jsou konzistentní:

- reflexivita,
- symetrie,
- standardní antisymetrie,
- standardní tranzitivita,
- standardní částečné uspořádání,
- standardní ekvivalence.

Také vlastnost „býti rovností“, tj. „rovnat se  $\delta$ “, je konzistentní.

**Poznámka 3.16.** Konzistenci lze využít například k testování, zda daná fuzzy relace je standardní ekvivalence apod. Vše lze převést na klasický postup uplatněný pro všechny řezy.

Jiné než standardní druhy antisymetrie a tranzitivity (například součinná tranzitivita) nejsou konzistentní, což komplikuje jejich ověřování a použití.

### 3.4. Projekce a cylindrické rozšíření

Zde se seznámíme s dalšími konstrukcemi, jejichž analogie pro ostré množiny buď neexistují, nebo jsou triviální.

**Definice 3.17.** Nechť  $X, Y$  jsou ostré množiny,  $R \in \mathcal{F}(X \times Y)$ . *Levá (první) projekce*  $R$  je  $P_1(R) \in \mathcal{F}(X)$ , kde

$$\mu_{P_1(R)}(x) = \bigvee_{y \in Y} \mu_R(x, y).$$

*Pravá (druhá) projekce*  $R$  je  $P_2(R) \in \mathcal{F}(Y)$ , kde

$$\mu_{P_2(R)}(y) = \bigvee_{x \in X} \mu_R(x, y).$$

Vzhledem ke geometrické analogii se projekce někdy nazývá *stín*.

**Poznámka 3.18.** Standardní fuzzy disjunkce v této definici znamená supremum. Zobecnění na jiné fuzzy disjunkce nelze doporučit ze stejných důvodů, jako v poznámce 3.7.

V jistém omezeném smyslu je opačnou operací k projekci cylindrické rozšíření:

**Definice 3.19.** Nechť  $X, Y$  jsou ostré množiny,  $A \in \mathcal{F}(X)$ ,  $B \in \mathcal{F}(Y)$ . *Cylindrické rozšíření*  $A$  a  $B$  (též *kartézský součin* fuzzy množin) je  $A \times B \in \mathcal{F}(X \times Y)$ , kde

$$\mu_{A \times B}(x, y) = \mu_A(x) \wedge_s \mu_B(y).$$

**Věta 3.20.** Cylindrické rozšíření  $A \times B$  je maximální fuzzy relace  $R \in \mathcal{F}(X \times Y)$  taková, že  $P_1(R) \subseteq A$  a  $P_2(R) \subseteq B$ .

**Poznámka 3.21.** V předchozím tvrzení nelze obecně požadovat rovnost. K tomu by musely  $A$  i  $B$  mít stejnou výšku.

## 4. Princip rozšíření

Princip rozšíření je jednou ze základních myšlenek, kterou obohatil teorii L. Zadeh. Umožňuje aplikovat na fuzzy množiny funkce a operace, definované původně pro jednodušší objekty, např. čísla.

### 4.1. Rozšíření binárních relací na ostré množiny

Zde ukážeme, jakým způsobem se například aritmetické operace na reálných číslech rozšiřují na ostré množiny reálných čísel. Dostaneme tak mj. tzv. intervalovou aritmetiku. Celý postup uvedeme obecněji.

Připomeňme, že *zobrazení* je taková binární relace  $R \subseteq X \times Y$ , pro kterou platí: pro každý prvek  $x \in X$  existuje právě jeden prvek  $y = r(x) \in Y$  takový, že  $(x, y) \in R$ . Na zobrazení  $r : X \rightarrow Y$  tedy můžeme pohlížet jako na relaci  $R \subseteq X \times Y$  s uvedenou vlastností. Zápis  $(x, y) \in R$  je ekvivalentní s  $y = r(x)$ . Také je  $R = \{(x, r(x)) : x \in X\}$ .

**Definice 4.1.** Nechť  $R \subseteq X \times Y$  je libovolná relace (nemusí být nutně zobrazením). Zobrazení  $r : \mathcal{P}(X) \rightarrow \mathcal{P}(Y)$ , které každé množině  $A \subseteq X$  přiřadí množinu  $B \subseteq Y$  podle předpisu

$$r(A) = \{y \in Y : (\exists x \in A : (x, y) \in R)\} \quad (4.1)$$

nazýváme *rozšířením* relace  $R$ .

Analogicky zobrazení  $r^{-1} : \mathcal{P}(Y) \rightarrow \mathcal{P}(X)$  definované vzorcem

$$r^{-1}(B) = \{x \in X : (\exists y \in B : (x, y) \in R)\} \quad (4.2)$$

je rozšířením relace  $R^{-1}$ .

**Poznámka 4.2.** Rozšíření  $r$  a  $r^{-1}$  z původní definice jsou zobrazení, i když původní relace  $R$  zobrazení není. Nejsou však navzájem inverzní, tj.  $r \circ r^{-1}$  nemusí být identita, jak ukážeme na příkladech.

Pokud výchozí relace  $R$  je navíc zobrazení, pak ji budeme též psát ve tvaru  $r : X \rightarrow Y$  a podle kontextu poznáme, zda písmeno  $r$  značí původní zobrazení, nebo jeho rozšíření. Je-li argumentem prvek množiny  $X$ , pak se jedná o původní zobrazení, je-li argumentem podmnožina množiny  $X$ , pak jde o rozšíření. Vzorce (4.1) a (4.2) pak nabývají jednodušší tvar

$$\begin{aligned} r(A) &= \{r(x) : x \in A\}, \\ r^{-1}(B) &= \{x \in X : r(x) \in B\}. \end{aligned}$$

Použití stejného symbolu pro dvě formálně různá zobrazení  $r : X \rightarrow Y$  a  $r : \mathcal{P}(X) \rightarrow \mathcal{P}(Y)$  lze ospravedlnit tím, že první z nich splňuje rovnost  $r(x) = y$  právě tehdy, když druhé splňuje  $r(\{x\}) = \{y\}$ .

**Příklad 4.3.** Nechť  $R = \{(x, \sin x) : x \in \mathbf{R}\}$ , tj. uvažujeme funkci (zobrazení, relaci) sinus. Inverzní relace  $\sin^{-1}$  není zobrazení. Rozšíříme relace  $\sin, \sin^{-1}$  na zobrazení z podmnožin reálných čísel do podmnožin reálných čísel a příslušná rozšíření značíme stejně. Pak například

$$\begin{aligned} \sin \left( \left\langle \frac{\pi}{4}, 2 \right\rangle \right) &= \left\langle \frac{1}{\sqrt{2}}, 1 \right\rangle, \\ \sin^{-1} \left( \left\{ \frac{1}{2} \right\} \right) &= \left\{ \frac{\pi}{4} + 2k\pi : k \in \mathbf{Z} \right\} \cup \left\{ \frac{3\pi}{4} + 2k\pi : k \in \mathbf{Z} \right\}, \end{aligned}$$

kde  $\mathbf{Z}$  značí množinu všech celých čísel. Zde  $\sin \circ \sin^{-1}$  je identické zobrazení (na  $\langle -1, 1 \rangle$ ), ale  $\sin^{-1} \circ \sin$  není identita.

Používáme-li rozšířené operace na jednobodové množiny, množinové závorky pro zjednodušení vynecháváme; zejména

$$r^{-1}(y) = r^{-1}(\{y\}) = \{x \in X : r(x) = y\}.$$

Tento zápis jsme již dříve použili, například v definici hladiny.

**Příklad 4.4.** Necht  $X = \{a, b, c\}$ ,  $Y = \{1, 2\}$ ,  $\mu_R = \{(a, 1), (b, 1), (c, 2)\}$ . Pak například

$$\begin{aligned} r(\{a\}) &= r(\{b\}) = r(\{a, b\}) = \{1\}, \\ r(\{a, c\}) &= r(\{b, c\}) = r(X) = Y, \\ r^{-1}(\{1\}) &= \{a, b\}, \\ r^{-1}(\{2\}) &= \{c\}, \\ r^{-1}(Y) &= X, \\ r^{-1}(r(\{a\})) &= \{a, b\}, \end{aligned}$$

takže rozšíření zobrazení  $r^{-1}$  není inverzní k rozšíření zobrazení  $r$ .

**Poznámka 4.5.** Zapišme vzorec (4.1) tak, že použijeme funkci příslušnosti:

$$\begin{aligned} \mu_{r(A)}(y) &= \begin{cases} 1 & \text{pokud } \exists x \in A : (x, y) \in R \\ 0 & \text{jinak} \end{cases} = \begin{cases} 1 & \text{pokud } \exists x \in X : (\mu_R(x, y) \wedge \mu_A(x) = 1) \\ 0 & \text{jinak} \end{cases} = \\ &= \sup_{x \in X} \mu_R(x, y) \wedge \mu_A(x). \end{aligned}$$

Podobně vychází:

$$\mu_{r^{-1}(B)}(x) = \sup_{y \in Y} \mu_R(x, y) \wedge \mu_B(y).$$

Připomeňme, že zatím pracujeme s ostrými množinami, takže funkce příslušnosti nabývá pouze hodnot 0 nebo 1. Přesněji  $\mu_A(x) = 1$  pro  $x \in A$  a  $\mu_A(x) = 0$  jinak. Stejně tak  $\mu_R(x, y) = 1$  pro  $(x, y) \in R$  a  $\mu_R(x, y) = 0$  jinak. Tato poznámka je jen přípravnou úvahou pro následující definici.

#### 4.2. Princip rozšíření binárních relací na fuzzy množiny

**Definice 4.6.** Necht  $R \subseteq X \times Y$  je ostrá relace. Definujeme *rozšíření* této relace  $r : \mathcal{F}(X) \rightarrow \mathcal{F}(Y)$  předpisem

$$\mu_{r(A)}(y) = \bigvee_{x \in X}^s \mu_R(x, y) \wedge \mu_A(x), \quad (4.3)$$

kde  $A \in \mathcal{F}(X)$ ,  $y \in Y$  a  $\wedge$  je fuzzy konjunkce. Podobně rozšíření relace  $R^{-1}$  je zobrazení  $r^{-1} : \mathcal{F}(Y) \rightarrow \mathcal{F}(X)$  dané vzorcem

$$\mu_{r^{-1}(B)}(x) = \bigvee_{y \in Y}^s \mu_R(x, y) \wedge \mu_B(y),$$

kde  $B \in \mathcal{F}(Y)$ ,  $x \in X$  a  $\wedge$  je fuzzy konjunkce.

**Poznámka 4.7.** Protože  $R$  je ostrá relace, na volbě fuzzy konjunkce  $\wedge$  nezáleží. Symbol  $\bigvee^s$  ve vzorcích z definice odpovídá supremu. Proti použití jiné než standardní fuzzy disjunkce lze vznést stejnou námitku, jako v poznámce 3.7.

Uvedený postup, zavedený Zadehem [18] a nazývaný *princip rozšíření*, dovoluje mj. aplikovat na fuzzy množiny z  $\mathcal{F}(\mathbf{R})$  funkce, které jsou původně definovány jako funkce reálné proměnné.

**Příklad 4.8.** Necht  $A \in \mathcal{F}(\mathbf{R})$ ,

$$\mu_A(x) = \begin{cases} \frac{x+1}{2} & \text{pro } x \in \langle -1, 1 \rangle, \\ \frac{3-x}{2} & \text{pro } x \in (1, 3), \\ 0 & \text{jinak.} \end{cases}$$

Zobrazme  $A$  následujícími funkcemi:

- unární  $-$ ,
- druhá mocnina.

Jinými slovy, najděme fuzzy množiny  $-A$  a  $A^2$ .

**Řešení.** a) Zde  $R = \{(x, -x) : x \in \mathbf{R}\}$ , tedy  $\mu_R(x, y) = \delta(x, -y)$ . Podle (4.3) je

$$\mu_{-A}(y) = \bigvee_{x \in X}^s \mu_R(x, y) \wedge \mu_A(x) = \bigvee_{x \in X}^s \delta(x, -y) \wedge \mu_A(x) = \mu_A(-y)$$

Zdůvodníme poslední rovnost: výraz  $\delta(x, -y) \wedge \mu_A(x)$  dává nenulový výsledek jen tehdy, když  $x = -y$  a tudíž počítáme supremum z jednobodové množiny  $\{\delta(-y, -y) \wedge \mu_A(-y)\} = \{1 \wedge \mu_A(-y)\} = \{\mu_A(-y)\}$ .

Dostáváme výsledek

$$\mu_{-A}(y) = \mu_A(-y) = \begin{cases} \frac{3+y}{2} & \text{pro } y \in \langle -3, -1 \rangle, \\ \frac{1-y}{2} & \text{pro } y \in \langle -1, 1 \rangle, \\ 0 & \text{jinak.} \end{cases}$$

b) Zde  $R = \{(x, x^2) : x \in \mathbf{R}\}$ , takže  $\mu_R(x, y) = 1$  právě tehdy, když  $x = \pm\sqrt{y}$ . Podle (4.3) dostáváme pro  $y \geq 0$ :

$$\mu_{A^2}(y) = \bigvee_{x \in X}^S \mu_R(x, y) \wedge \mu_A(x) = \mu_A(\sqrt{y}) \overset{S}{\vee} \mu_A(-\sqrt{y}) = \max(\mu_A(\sqrt{y}), \mu_A(-\sqrt{y})).$$

Pro  $y > 0$  je hodnota  $\mu_R(x, y) \wedge \mu_A(x)$  nenulová pro  $x = \pm\sqrt{y}$ , takže se nám supremum přes  $x \in X$  redukuje na uvedené maximum ze dvou hodnot. Pro  $y < 0$  je  $\mu_R(x, y) = 0$  pro všechna  $x \in \mathbf{R}$ , takže v tomto případě je  $\mu_A(y) = 0$ .

Pro naši konkrétní množinu  $A$  máme tento výsledek:

$$\mu_A(y) = \begin{cases} \frac{\sqrt{y}+1}{2} & \text{pro } y \in \langle 0, 1 \rangle, \\ \frac{3-\sqrt{y}}{2} & \text{pro } y \in \langle 1, 9 \rangle, \\ 0 & \text{jinak.} \end{cases}$$

**Věta 4.9.** Rozšíření  $r : \mathcal{F}(X) \rightarrow \mathcal{F}(Y)$  binární relace  $R \subseteq X \times Y$  má následující vlastnosti

$$\begin{aligned} r(\emptyset) &= \emptyset, \\ A_1 \subseteq A_2 &\Rightarrow r(A_1) \subseteq r(A_2), \\ r\left(\bigcup_i A_i\right) &= \bigcup_i r(A_i), \\ r\left(\bigcap_i A_i\right) &\subseteq \bigcap_i r(A_i) \quad (\text{nemusí platit rovnost}). \end{aligned}$$

Stejně vzorce platí i pro  $r^{-1} : \mathcal{F}(Y) \rightarrow \mathcal{F}(X)$ .

**Věta 4.10.** Pokud je  $R$  navíc zobrazení, pak platí

$$r^{-1}\left(\bigcap_i A_i\right) = \bigcap_i r^{-1}(A_i).$$

**Věta 4.11.** Pro všechna  $\alpha \in \langle 0, 1 \rangle$  platí

$$\begin{aligned} r(R_A(\alpha)) &\subseteq R_{r(A)}(\alpha), \\ r(S_A(\alpha)) &= S_{r(A)}(\alpha), \end{aligned}$$

Pro konečné množiny platí rovnost i v prvním vztahu.

### 4.3. Konvexní fuzzy množiny

**Definice 4.12.** Nechť  $L$  je lineární prostor. Ostrá podmnožina  $A \subseteq L$  se nazývá *konvexní*, jestliže pro všechna  $x, y \in A$  a pro všechna  $\lambda \in (0, 1)$  platí  $\lambda x + (1 - \lambda)y \in A$ .

Pro funkce příslušnosti lze definiční vztah psát

$$\min(\mu_A(x), \mu_A(y)) \leq \mu_A(\lambda x + (1 - \lambda)y).$$

To nám umožňuje zobecnění na fuzzy množiny.

**Definice 4.13.** Nechť  $X$  je ostrá konvexní podmnožina lineárního prostoru. Fuzzy množina  $A \in \mathcal{F}(X)$  se nazývá *konvexní*, jestliže

$$\forall x, y \in X \quad \forall \lambda \in (0, 1) : \quad \mu_A(\lambda x + (1 - \lambda)y) \geq \mu_A(x) \underset{S}{\wedge} \mu_A(y).$$

**Věta 4.14.** Konvexita je konzistentní vlastnost.

Konvexní fuzzy množiny tedy snadno poznáme podle toho, že mají všechny řezy konvexní.

## 5. Fuzzy čísla a fuzzy intervaly

### 5.1. Zavedení pojmů a základní vlastnosti

**Definice 5.1.** *Fuzzy interval* je taková množina  $A \in \mathcal{F}(\mathbf{R})$ , která splňuje následující podmínky:

- $\text{Supp } A$  je omezená množina,
- Pro všechna  $\alpha \in (0, 1)$  je  $R_A(\alpha)$  uzavřený interval,
- $R_A(1) \neq \emptyset$  (tj.  $R_A(1)$  je neprázdný uzavřený interval).

Je-li navíc  $R_A(1)$  jednobodová množina, nazývá se  $A$  *fuzzy číslo*.

**Poznámka 5.2.** Toto je převládající, nikoli však jediná definice fuzzy čísla, s jakou se lze setkat v literatuře. Pro fuzzy intervaly a fuzzy čísla se používá společný termín *fuzzy kvantity*.

Podle věty 4.14 jsou fuzzy intervaly konvexní.

Jednoprvkové množiny reálných čísel jsou zvláštním případem fuzzy čísel, odpovídající původním reálným číslům („ostrá fuzzy čísla“).

**Věta 5.3.** Je-li  $A$  fuzzy číslo a  $\mu_A(x) = 1$ , pak  $A$  je neklesající na  $(-\infty, x)$  a nerostoucí na  $(x, +\infty)$ .

Rozmyslete si, jak modifikovat větu 5.3 pro fuzzy interval.

**Definice 5.4.** Fuzzy číslo *opačné* k fuzzy číslu  $A$  je množina  $-A$  definovaná vztahem

$$\mu_{-A}(x) = \mu_A(-x)$$

Fuzzy číslo opačné je definováno podle principu rozšíření binárních relací uplatněnému na unární minus, viz příklad 4.8. Speciálně pro všechna  $\alpha \in (0, 1)$  je

$$R_{-A}(\alpha) = -R_A(\alpha).$$

### 5.2. Binární operace s fuzzy čísly

Nyní rozšíříme binární operace  $+$ ,  $-$ ,  $\cdot$ ,  $/$  reálných čísel na fuzzy intervaly. Použijeme k tomu princip rozšíření. Je však třeba jej kombinovat s další konstrukcí, totiž s cylindrickým rozšířením. Tento obrat je v mnohých knihách přehlížen, proto se tomuto kroku budeme věnovat podrobněji.

Chceme rozšířit binární aritmetickou operaci  $\square \in \{+, -, \cdot, /\}$ . Jelikož  $\square : \mathbf{R}^2 \rightarrow \mathbf{R}$ , můžeme na  $\square$  pohlížet též jako na relaci, konkrétně jako na podmnožinu  $\mathbf{R}^2 \times \mathbf{R}$ . Tu můžeme podle již zavedeného principu rozšíření pro *binární relace* rozšířit na operaci  $\mathcal{F}(\mathbf{R}^2) \rightarrow \mathcal{F}(\mathbf{R})$  (definice 4.6). Tu potřebujeme ještě složit se zobrazením  $\mathcal{F}(\mathbf{R}) \times \mathcal{F}(\mathbf{R}) \rightarrow \mathcal{F}(\mathbf{R}^2)$ , k čemuž použijeme cylindrické rozšíření (definice 3.19). Tím dostáváme potřebnou binární operaci nad fuzzy čísly  $\square : \mathcal{F}(\mathbf{R}) \times \mathcal{F}(\mathbf{R}) \rightarrow \mathcal{F}(\mathbf{R})$ . Popsanou myšlenku rozšíření binární operace na fuzzy čísla upřesníme v následující definici:

**Definice 5.5.** Necht  $A, B$  jsou fuzzy intervaly,  $\square \in \{+, -, \cdot, /\}$ . Pak  $A \square B$  je fuzzy množina definovaná předpisem

$$\mu_{A \square B}(x) = \sup \{ \min(\mu_A(y), \mu_B(z)) : y, z \in \mathbf{R}, y \square z = x \} = \bigvee_y \bigvee_{z, y \square z = x} \mu_A(y) \wedge \mu_B(z).$$

Uplatníme-li tuto definici na ostré intervaly, dostaneme tzv. *intervalovou aritmetiku*, viz následující příklad.

**Příklad 5.6.** Uvažujme ostré intervaly  $\langle a, b \rangle$ ,  $\langle c, d \rangle$ . Pak platí

$$\begin{aligned} \langle a, b \rangle + \langle c, d \rangle &= \langle a + c, b + d \rangle, \\ \langle a, b \rangle - \langle c, d \rangle &= \langle a - d, b - c \rangle, \\ \langle a, b \rangle \cdot \langle c, d \rangle &= \langle \min(ac, ad, bc, bd), \max(ac, ad, bc, bd) \rangle, \\ \langle a, b \rangle / \langle c, d \rangle &= \langle \min(a/c, a/d, b/c, b/d), \max(a/c, a/d, b/c, b/d) \rangle. \end{aligned}$$

Poslední rovnost platí pouze tehdy, když  $0 \notin \langle c, d \rangle$ . V opačném případě výsledkem není interval.

Právě popsaná intervalová aritmetika nám umožní výpočet binárních operací s fuzzy intervaly převedením do horizontální reprezentace, neboť platí tato věta:

**Věta 5.7.** Pro libovolné fuzzy intervaly  $A, B$  a  $\alpha \in \langle 0, 1 \rangle$  platí

$$R_{A \square B}(\alpha) = R_A(\alpha) \square R_B(\alpha).$$

**Poznámka 5.8.** Výsledek násobení  $A \cdot A$  nemusí být nezáporný, tj. může nabývat nenulových stupňů příslušnosti i pro záporná čísla, pokud  $\text{Supp } A$  obsahuje záporná i kladná čísla. Tím se tato operace liší od unární  $A^2$  popsané v příkladu 4.8.

**Věta 5.9.** Součet, rozdíl a součin fuzzy čísel (resp. intervalů) je fuzzy číslo (resp. interval).

Dělení fuzzy čísel a intervalů se zavádí odlišně, abychom se vyhnuli problémům s dělením nulou:

$$\begin{aligned} \mu_{A/B}(x) &= \sup \left\{ \min(\mu_A(y), \mu_B(z)) : y, z \in \mathbf{R}, y = z \cdot x \right\} = \\ &= \bigvee_y \bigvee_{z, y=z \cdot x} \mu_A(y) \wedge_S \mu_B(z) = \bigvee_z \mu_A(z \cdot x) \wedge_S \mu_B(z). \end{aligned}$$

Podle tohoto vzorce lze dělit i „nulou“. Je-li  $B = \{0\}$ , pak  $\mu_{A/B}(x) = \mu_A(0)$ , což je konstantní fuzzy množina (nikoli však fuzzy interval). I při dělení jinými fuzzy intervaly, obsahujícími nulu (s nenulovým stupněm příslušnosti) vycházejí fuzzy množiny, které nejsou fuzzy intervaly. Jejich nosič je neomezený a řezy nemusí být konvexní.

Libovolné reálné číslo  $x \in \mathbf{R}$  lze považovat za speciální případ fuzzy čísla, reprezentovaného jednobodovou ostrou množinou  $\{x\}$ . V dalším textu je budeme značit stručně  $x$ ; funkce příslušnosti je  $\mu_x(y) = \delta(y, x)$ .

**Věta 5.10 (vlastnosti operací s fuzzy čísly).** Pro fuzzy čísla  $A, B, C$  platí

$$\begin{aligned} 0 + A &= A, & 0 \cdot A &= 0, & 1 \cdot A &= A, \\ A + B &= B + A, & A \cdot B &= B \cdot A, \\ A + (B + C) &= (A + B) + C, & A \cdot (B \cdot C) &= (A \cdot B) \cdot C, \\ A + (-B) &= A - B, & (-A) \cdot B &= -(A \cdot B) = A \cdot (-B), \\ -(-A) &= A, \\ A/B &= A \cdot (1/B), \quad \text{je-li pravá strana fuzzy interval,} \\ A \cdot (B + C) &\leq (A \cdot B) + (A \cdot C) \quad (\text{nemusí platit rovnost}). \end{aligned}$$

Pokud je v posledním vztahu  $A$  ostré číslo ( $A = x$ ), pak nastává rovnost.

**Poznámka 5.11.** Následující vztahy *nemusí* platit pro fuzzy čísla:

$$\begin{aligned} A - A &= 0, \\ (A + B) - B &= A, \\ A/A &= 1, \\ (A/B) \cdot B &= A, \\ A \cdot (B + C) &= A \cdot B + A \cdot C. \end{aligned}$$

## 6. Literatura

### 6.1. Základní

- [1] Novák, V.: *Základy fuzzy modelování*. BEN – technická literatura, Praha, 2000.
- [2] Novák, V.: *Fuzzy množiny a jejich aplikace*. Mat. seminář SNTL, Praha, 1990.
- [3] Vysoký, P.: *Fuzzy řízení*. Skriptum ČVUT, Praha, 1996.
- [4] Kreidl, M.: *Diagnostické systémy*. Skriptum ČVUT, Praha, 1997.
- [5] Mareš, M.: Počítání s vágností I, II. *Automatizace* **44** (2001), No. 1, 34–37, No. 2, 96–99.
- [6] Klir, G.J.; Yuan, B.: *Fuzzy Sets and Fuzzy Logic. Theory and Applications*. Prentice-Hall, 1995.
- [7] Nguyen, H.T.; Walker, E.A.: *A First Course in Fuzzy Logic*. CRC Print, Boca Raton/New York/London/Tokyo, 1997.
- [8] Kruse, R.; Gebhardt, J.; Klawon, F.: *Foundations of Fuzzy Systems*. J. Wiley, 1994.
- [9] Lowen, R.: *Fuzzy Logic*. Kluwer, 1995.

### 6.2. Doplnková

- [10] Turunen, E.: *Mathematics Behind Fuzzy Logic*. Physica-Verlag, 1999.
- [11] Hájek, P.: *Metamathematics of Fuzzy Logic*. Kluwer, Dordrecht, 1998.
- [12] Butnariu, D.; Klement, E.P.: *Triangular Norm-Based Measures and Games with Fuzzy Coalitions*. Kluwer, Dordrecht, 1993.
- [13] Klement, E.P.; Mesiar, R.; Pap, E.: *Triangular Norms*. Kluwer, Dordrecht, 2000.
- [14] Gottwald, S.: *Fuzzy Sets and Fuzzy Logic*. Friedr. Vieweg & Sohn, Braunschweig, Teknea, SA, Toulouse, 1993.
- [15] Gottwald, S.: *Einführung in Fuzzy-Methoden*. 4th ed. Akademie Verlag, Berlin, 1993.
- [16] B. Schweizer, A. Sklar: *Probabilistic Metric Spaces*. North-Holland, New York, 1983.
- [17] Mareš, M.: *Computation over Fuzzy Quantities*. CRC Press, Boca Raton, 1994.
- [18] Zadeh, L.: Fuzzy Sets. *Inform. Control* **8** (1965), 338–353.
- [19] Zimmermann, H.-J.: *Fuzzy Set Theory — and Its Applications*. 3rd ed., Kluwer, 1996.



## 7. Rejstřík

- absorpce 17
- aditivní generátor 13
- aggregation operator 20
- agregační operátor 20
- alfa-hladina 4
- alfa-řez 4
- algebraic product 12
- alpha-cut 4
- alpha-level 4
- antisymetrie 22, 23
- archimedean fuzzy
  - conjunction 12
  - — disjunction 15
- archimedovská fuzzy
  - disjunkce 15
  - — konjunkce 12
- asociativita 17
- averaging operator 20
- binární relace 22
- bold fuzzy conjunction 12
  - — disjunction 14
- bounded sum 14
- core 4
- crisp set 3
- cutworthy 24
- cylické rozšíření 24
- částečné uspořádání 22, 23
- de Morganovy zákony 17
- distributivita 17
- doplňěk množiny 2
- drastická fuzzy disjunkce 14
  - — konjunkce 12
- duální fuzzy disjunkce 15
  - — konjunkce 15
- ekvivalence 22, 23
- equilibrium 10
- funkce příslušnosti 3
- funkcionální fuzzy logika 9
- fuzzy antisymetrie 23
  - biimplikace 20
  - biimplikace Gödelova 20
  - — Łukasiewiczova 20
  - — součinnová 20
  - conjunction archimedean 12
  - — bold 12
  - — nilpotent 12
  - — strict 12
  - — weak 12
  - částečné uspořádání 23
  - číslo 28
  - číslo opačné 28
  - disjunction archimedean 15
  - — bold 14
  - — nilpotent 15
  - — strict 15
  - — weak 14
  - disjunkce 14
  - disjunkce archimedovská 15
  - — drastická 14
  - — Gilesova 14
  - — Gödelova 14
  - — Łukasiewiczova 14
  - — max 14
  - — nilpotentní 15
  - — pravděpodobnostní 14
  - — produktová 14
  - — slabá 14
  - — součinnová 14
  - — standardní 14
  - — striktní 15
  - — Zadehova 14
  - doplňěk 11
  - ekvivalence 20, 23
  - implikace 18
  - implikace Gainesova 18
  - — Gödelova 18
  - — Goguenova 18
  - — Kleeneova-Dienesova 19
  - — Łukasiewiczova 18, 19
  - — původní Zadehova 19
  - — Reichenbachova 19
  - — reziduovaná 18
  - interval 28
  - konjunkce 11
  - konjunkce archimedovská 12
  - — drastická 12
  - — Gilesova 12
  - — Gödelova 12
  - — Łukasiewiczova 12
  - — min 12
  - — nilpotentní 12
  - — pravděpodobnostní 12
  - — produktová 12
  - — slabá 12
  - — součinnová 12
  - — standardní 12
  - — striktní 12
  - — Zadehova 12
  - kvantita 28
  - množina 3
  - množina konečná 4
  - — konvexní 27
  - — normální 3
  - — subnormální 3
  - negace 10
  - negace silná 11
  - — zobecněná 11, 19
  - podmnožina 3, 8
  - průměr 20
  - průnik 14
  - relace 23
  - relace inverzní 23
  - — složená 23
  - sjedocení 16
  - tranzitivita 23
- Gainesova fuzzy implikace 18
- generalized means 21
- generátor aditivní 13
  - fuzzy negace 10
  - rostoucí 11
- Gilesova fuzzy disjunkce 14
  - — konjunkce 12
- Gödelova fuzzy biimplikace 20
  - — disjunkce 14
  - — implikace 18
  - — konjunkce 12
  - zobecněná fuzzy negace 11
- Goguenova fuzzy implikace 18
- hladina 4
- horizontální reprezentace 6
- charakteristická funkce 3
- idempotence 12, 17
- inkluze množin 2
- intervalová aritmetika 28
- inverzní fuzzy relace 23
- inverzní relace 22
- involuce 10, 17
- jádro fuzzy množiny 4
- kardinalita množiny 2
- kartézský součin 2
- kartézský součin fuzzy množin 24
- Kleeneova-Dienesova fuzzy implikace 19
- komutativita 17
- konečná fuzzy množina 4
- konvexní fuzzy množina 27
  - množina 27
- konzistence 24
- Kroneckerovo delta 22
- levá projekce 24
- Łukasiewiczova fuzzy biimplikace 20
  - — disjunkce 14
  - — implikace 18, 19
  - — konjunkce 12

max fuzzy disjunkce 14  
 min fuzzy konjunkce 12  
 množina konvexní 27  
 mohutnost množiny 2  
 neutrální prvky 17  
 nilpotentní fuzzy conjunction 12  
 — — disjunction 15  
 nilpotentní fuzzy disjunkce 15  
 — — konjunkce 12  
 normální fuzzy množina 3  
 nosič fuzzy množiny 4  
 obor hodnot fuzzy množiny 3  
 operátor agregační 20  
 ordered weighted averaging  
   operator 21  
 ostrá množina 3  
 ostrý řez 4  
 OWA-operator 21  
 pravá projekce 24  
 pravděpodobnostní fuzzy  
   disjunkce 14  
 — — konjunkce 12  
 princip rozšíření 26  
 produktová fuzzy disjunkce 14  
 — — konjunkce 12  
 projekce druhá 24  
 — levá 24  
 — pravá 24  
 — první 24  
 průměr uspořádaný vážený 21  
 — vážený 21  
 — zobecněný 21  
 průnik množin 2  
 původní Zadehova fuzzy  
   implikace 19  
 Q-implikace 19  
 R-implikace 18  
 reflexivita 22, 23  
 Reichenbachova fuzzy  
   implikace 19  
 relace 22  
 relace binární 22  
 — fuzzy 23  
 — inverzní 22  
 — rovnosti 22  
 — složená 22  
 reprezentace horizontální 6  
 — vertikální 6  
 reziduum 18  
 rostoucí generátor 11  
 rovnovážná hodnota 10  
 rozšíření cylindrické 24  
 — relace 25, 26  
 řez 4  
 S-implikace 19  
 silná fuzzy negace 11  
 sjednocení množin 2  
 skalární kardinalita 4  
 slabá fuzzy disjunkce 14  
 — — konjunkce 12  
 složená relace 22, 23  
 součinná fuzzy biimplikace 20  
 — — disjunkce 14  
 — — konjunkce 12  
 standardní fuzzy disjunkce 14  
 — — konjunkce 12  
 — — negace 10  
 stín 24  
 strict fuzzy conjunction 12  
 — — disjunction 15  
 striktní fuzzy disjunkce 15  
 — — konjunkce 12  
 subnormální fuzzy množina 3  
 support 4  
 symetrie 22, 23  
 systém ostých řezů 4  
 — řezů 4  
 t-konorma 14  
 t-norma 11  
 tranzitivita 22, 23  
 triangular conorm 14  
 triangular norm 11  
 trojúhelníková konorma 14  
 — norma 11  
 univerzální množina 2  
 univerzum 2  
 uspořádaný vážený průměr 21  
 vážený průměr 21  
 vertikální reprezentace 6  
 výška fuzzy množiny 3  
 weak fuzzy conjunction 12  
 — — disjunction 14  
 Zadehova fuzzy disjunkce 14  
 — — konjunkce 12  
 zákon kontradikce 17  
 — vyloučeného třetího 17  
 zákony de Morganovy 17  
 zesílená forma normality 24  
 zobecněná fuzzy negace 11, 19  
 zobecněný průměr 21  
 zobrazení 25