

Mihaela (Ghindeanu) Colhon

ELEMENTE DE LOGICĂ FUZZY

Craiova, 2012

Cuprins

1	Despre IA	9
1.1	Concepte generale. Inspirații	9
1.1.1	Reprezentarea cunoașterii	9
2	Elemente de Logică Fuzzy	11
2.1	Mulțimi fuzzy	11
2.2	Operații cu mulțimi fuzzy	13
2.2.1	Principiul extensiei	14
2.2.2	Numere fuzzy	16
2.3	t -norme și t -conorme	18
2.4	Relații fuzzy	21
2.5	Variabile lingvistice	26
2.5.1	Valori de adevăr fuzzy	28
2.6	Propoziții și implicații fuzzy	28
2.6.1	Modus ponens generalizat	31
2.7	Sisteme fuzzy	32
2.7.1	Two-Input/Single-Output fuzzy sistem	34
2.7.2	Inferența fuzzy într-o R -bază a unui sistem fuzzy Two-Input/ Single-Output	38
2.7.3	Metode de defuzzificare	42

3	Sisteme fuzzy pentru control inteligent	49
3.1	Mulțimi vagi	49
3.1.1	Funcții de apartenență tipice	50
3.1.2	Operații cu mulțimi fuzzy	53
3.1.3	Evenimente fuzzy, probabilitate și entropie	53
3.2	Logica fuzzy de tip lingvistic	55
3.2.1	Variabile lingvistice	55
3.2.2	Implicații pentru logica fuzzy	56
3.2.3	Operatori pentru logica fuzzy	58
3.3	Metodologia de sinteză a automatelor fuzzy	59
3.3.1	Baza euristică a algoritmului	60
3.3.2	Definirea variabilelor de lucru	61
3.3.3	Baza de reguli pentru inferențe fuzzy	63
3.4	Implementarea software a algoritmilor fuzzy	64
3.4.1	Structura unui automat fuzzy	65
3.4.2	Proiectarea sistemelor fuzzy cu MATLAB	67
3.4.3	Aplicație. Sistem fuzzy pentru analiză spațială	74
3.4.4	Sistem fuzzy pentru analiza spatiaa - Interfata	77
3.4.5	Sistem fuzzy pentru analiza spatiaa - Implementarea	78

Lista de figuri

2.1	Convexitatea mulțimilor fuzzy	12
2.2	Mărimi asociate mulțimilor fuzzy	13
2.3	Principiul extensiei aplicat în Exemplul 1.1	15
2.4	Numere fuzzy	17
2.5	Exemple de t -norme	19
2.6	Exemple de t -conorme	20
2.7	Cele două mulțimi fuzzy din Exemplul 2.4.3	24
2.8	Mulțimea fuzzy " <i>diferența de presiune este mare</i> "	25
2.9	Variabila lingvistică <i>vârsta</i>	26
2.10	Valori de adevăr fuzzy	28
2.11	Arhitectura unui controler fuzzy	33
2.12	O partiție fuzzy a intervalului $[-1, 1]$	33
2.13	Mulțimea de ieșire C' corespunzătoare intrărilor crisp u_0 și v_0	36
2.14	Mulțimea de ieșire C' corespunzătoare intrărilor fuzzy A' și B'	38
2.15	Reprezentarea grafică a metodei de inferență Mamdani	39
2.16	Reprezentarea grafică a metodei de inferență Larsen	40
2.17	Reprezentarea grafică a metodei de inferență TSK	41
2.18	Defuzzificare	42
2.19	Variabila lingvistică <i>temperatura</i>	44
2.20	Variabila lingvistică <i>presiunea</i>	44
2.21	Ieșirea sistemului folosind implicația Mamdani (a) și Larsen (b)	46

3.1	Funcția de apartenență triunghiulară	50
3.2	Funcția de apartenență trapezoidală	51
3.3	Funcția de apartenență parabolică	51
3.4	Funcția de apartenență de tip <i>clopot</i>	52
3.5	Funcții de apartenență de tip saturație	52
3.6	Variabila lingvistică <i>distanța</i> cu trei valori lingvistice	57
3.7	Efectul operatorilor “concentrator” și “dilatator”	58
3.8	Arhitectura unui controler fuzzy	60
3.9	Schema logică a unui controler fuzzy	65
3.10	Funcția GAUSSMF	68
3.11	Funcția TRIMF	69
3.12	Funcția TRAPMF	70
3.13	Variabila lingvistică “eroare”	71
3.14	Efectul funcției DEFUZZ	74

Lista de tabelas

Capitolul 1

Despre IA

1.1 Concepte generale. Inspirații

Obiectivul inteligenței artificiale este simularea comportamentului inteligent al unui om. În inteligența artificială există două abordări unanim acceptate. *Abordarea conexionistă* se bazează pe ideea că inteligența este emergentă rețelelor neuronale. Pe de altă parte, *abordarea simbolică* bazată pe *ipoteza sistemelor simbolice fizice* a lui H. Simon și A. Newell consideră că orice sistem inteligent (natural sau artificial) este un sistem fizic de prelucrare a simbolurilor.

În abordările simbolice de inteligență artificială, prelucrările sunt efectuate de un program care manipulează cunoștințe dintr-o așa numită *bază de cunoștințe*. Programele de calcul sunt denumite în acest caz *sisteme bazate pe cunoștințe*, principala lor caracteristică fiind separarea netă între baza de cunoștințe și mecanismul de raționament. Una din cele mai grele probleme ale dezvoltării unui astfel de sistem este construirea bazei de cunoștințe, așa numita achiziție de cunoștințe.

1.1.1 Reprezentarea cunoașterii

Spre deosebire de *informație*, noțiunea centrală în informatică (de unde și termenul de IT - *information technology* - tehnologia informației) cunoașterea era, până de curând,

specifică doar inteligenței artificiale. În acest context, cunoașterea are o semnificație bine precizată. Conform definiției lui Alan Newell, unul dintre pionierii inteligenței artificiale, *cunoașterea este ceea ce poate fi atribuit unui agent uman sau artificial astfel încât comportarea sa să poată fi catalogată drept rațională.*

Tot Newell în lucrarea sa *Nivelul cunoștințelor* atrage atenția asupra faptului că în universul științei calculatoarelor există un nivel separat al cunoștințelor situat deasupra nivelului programelor care la rândul lui este deasupra celor specifice hardware-ului (transferul între regiștrii, circuitele și dispozitivele). Trecerea la un alt nivel, cel al cunoștințelor este noutatea adusă tehnologiei informației.

Capitolul 2

Elemente de Logică Fuzzy

2.1 Mulțimi fuzzy

Noțiunea de *mulțime fuzzy* a fost introdusă de Lotfi A. Zadeh începând cu anul 1965 cu scopul de a modela caracterul imprecis al apartenenței. El a propus generalizarea conceptului de apartenență binară a unui element la o mulțime crisp deoarece teoria clasică a mulțimilor limitează posibilitatea descrierii matematice a unor situații reale.

Dacă pentru mulțimile crisp apartenența unui element la o mulțime este de tip binar (*da/nu*) în cazul mulțimilor fuzzy este vorba de un grad de apartenență. Fie X o mulțime crisp ale cărei elemente dorim să le analizăm folosind tehnici fuzzy. Atunci:

$$A = \{(x, \varphi_A(x)) \mid x \in X\}$$

definește o *mulțime fuzzy* a lui X unde φ_A este *funcția de apartenență* relativă la mulțimea A , pentru $A \subseteq X$ iar $\varphi_A(x)$ reprezintă gradul de apartenență al lui x la mulțimea fuzzy A . De obicei $\varphi_A(x) \in [0, 1]$. Mulțimea X se mai numește *univers de discurs* sau *mulțime referențial* [1].

Definiția 2.1.1 [1] O mulțime fuzzy A se numește *normalizată* sau *normală* dacă

$$\sup\{\varphi_A(x) \mid x \in X\} = 1$$

și *subnormală* în caz contrar:



Figura 2.1: Convexitatea mulțimilor fuzzy

Orice submulțime fuzzy subnormală se poate normaliza considerând drept funcție caracteristică pe $\frac{\varphi_A(x)}{\sup\{\varphi_A(x) \mid x \in X\}}$ în loc de $\varphi_A(x)$.

Definiția 2.1.2 [1] O mulțime fuzzy A a unei mulțimi univers incluse în spațiul Euclidian se numește convexă dacă și numai dacă:

$$(\forall u \in X)(\forall v \in X)(\forall w \in X)(\varphi_A(w) \geq \min(\varphi_A(u), \varphi_A(v)))$$

ori de câte ori $\exists \lambda \in [0, 1]$ astfel încât: $w = \lambda u + (1 - \lambda)v$ sau:

$$\forall x_1, x_2, x_3 \in X : x_1 \leq x_2 \leq x_3 \text{ obținem: } \varphi_A(x_2) \geq \min(\varphi_A(x_1), \varphi_A(x_3))$$

Convexitatea mulțimilor fuzzy joacă un rol important în definirea *partițiilor fuzzy*.

Definiția 2.1.3 Un tuplu $(A_1, \dots, A_n)$ cu $A_i \in X, i = \overline{1, n}$ se numește *partiție fuzzy* dacă:

$$\sum_{i=1}^n \varphi_{A_i}(x) = 1, A_i \neq \emptyset, A_i \neq X$$

Observația 2.1.1 O partiție fuzzy formată din mulțimi fuzzy normale și convexe nu conține mai mult de două mulțimi fuzzy suprapuse.

Fie X o mulțime referențiar.

Definiția 2.1.4 [1] Se numește *tăietura de prag α* sau α – *tăietura mulțimea crisp*:

$$[\varphi]_\alpha = \{x \in X \mid \varphi(x) \geq \alpha\}$$

Dacă inegalitatea este strictă se spune că α – *tăietura* este de tip tare și va fi notată cu $[\varphi]_{+\alpha}$.

Fie A o mulțime fuzzy de univers X .




Figura 2.2: Mărimi asociate mulțimilor fuzzy

Definiția 2.1.5 [1] Nucleul mulțimii A notat $Ker(A)$ este tăietura de prag 1 a mulțimii:

$$Ker(A) = \{x \in X \mid \varphi_A(x) = 1\}$$

Definiția 2.1.6 [1] Suportul mulțimii A notat $Supp(A)$ este tăietura strictă de nivel 0 a mulțimii A :

$$Supp(A) = \{x \in X \mid \varphi_A(x) > 0\}$$

Definiția 2.1.7 [1] Frontiera mulțimii A notată $Fr(A)$ este mulțimea crisp a elementelor ce au grad de apartenență intermediar între 0 și 1:

$$Fr(A) = \{x \in X \mid \varphi_A(x) \in (0, 1)\}$$

Definiția 2.1.8 [1] Înălțimea mulțimii A notată $h(A)$ reprezintă cea mai mare valoare luată de funcția sa de apartenență:

$$h(A) = \sup\{\varphi_A(x) \mid x \in X\}$$

2.2 Operații cu mulțimi fuzzy

Fie A și B două mulțimi fuzzy de univers X . Dacă $\varphi_A = \varphi_B$ atunci se spune că A și B sunt mulțimi fuzzy egale ($A = B$). Dacă $\varphi_A \leq \varphi_B$ atunci spunem că mulțimea A este inclusă în mulțimea B ($A \subseteq B$).

Funcția de apartenență a reuniunii $A \cup B$ este definită cu ajutorul funcțiilor φ_A și φ_B astfel [1]:

$$\begin{aligned}\varphi_{A \cup B}(x) &= \max(\varphi_A(x), \varphi_B(x)), \quad x \in X \\ \varphi_{\bigcup_{i \in I} A_i}(x) &= \sup\{\varphi_{A_i}(x) \mid i \in I\}, \quad x \in X\end{aligned}$$

Funcția de apartenență a intersecției $A \cap B$ este definită de asemenea cu ajutorul funcțiilor φ_A și φ_B [1]:

$$\begin{aligned}\varphi_{A \cap B}(x) &= \min(\varphi_A(x), \varphi_B(x)), \quad x \in X \\ \varphi_{\bigcap_{i \in I} A_i}(x) &= \inf\{\varphi_{A_i}(x) \mid i \in I\}, \quad x \in X\end{aligned}$$

Presupunem că A este o mulțime fuzzy normalizată. Funcția de apartenență a complementării mulțimii A , notată $C[A]$ este definită prin [1]:

$$\varphi_{C[A]}(x) = 1 - \varphi_A(x)$$

2.2.1 Principiul extensiei

De multe ori în modelarea fuzzy este necesar să fuzzificăm mulțimi crisp. Să considerăm două mulțimi crisp X și Y iar $f : X \rightarrow Y$ o funcție. Fie A o submulțime fuzzy de referențial X cu funcția de apartenență φ_A . Zadeh a propus o metodă pentru construirea de mulțimi fuzzy induse de funcții, metodă cunoscută sub numele de *principiul extensiei*.

Definiția 2.2.1 [1] *Principiul extensiei* Imaginea mulțimii A prin funcția f este mulțimea fuzzy $f(A)$ de referențial Y cu funcția de apartenență definită după cum urmează:

$$\varphi_{f(A)}(y) = \begin{cases} \sup_{x \in f^{-1}(y)} \varphi_A(x), & \text{dacă } f^{-1}(y) \neq \emptyset \\ 0, & \text{altfel} \end{cases}$$

Acest principiu este unul din elementele importante ale teoriei mulțimilor fuzzy. De exemplu, pentru o mulțime A de univers finit, principiul extensiei ne permite extensia unei funcții f de la punctele referențialului X la mulțimile fuzzy ale lui X [1]:

$$\begin{aligned}f(A) &= f(\varphi_A(x_1)/x_1 + \varphi_A(x_2)/x_2 + \dots + \varphi_A(x_n)/x_n) = \\ &\varphi_A(x_1)/f(x_1) + \varphi_A(x_2)/f(x_2) + \dots + \varphi_A(x_n)/f(x_n)\end{aligned}$$

Fie B o mulțime fuzzy de referențial Y cu funcția de apartenență φ_B . Imaginea inversă a mulțimii B prin f notată $f^{-1}(B)$ este mulțimea fuzzy de referențial X cu funcția de apartenență [1]:




Figura 2.3: Principiul extensiei aplicat în Exemplul 1.1

$$\varphi_{f^{-1}(B)}(x) = \varphi_B(f(x))$$

Exemplul 2.2.1 Să considerăm următorul tabel care indică salariile angajaților unei companii în funcție de vârsta lor:

varsta	20	25	30	35	40	45	50	55	60	65
salariu	600	600	800	1000	1000	1200	1200	1400	1400	1600

Ne propunem să determinăm care este salariul angajaților tineri folosind principiul extensiei. Pentru aceasta vom considera funcția $f : V \rightarrow S$ unde $V = \{20, 25, 30, 35, 40, 45, 50, 55, 60, 65\}$ iar $S = \{600, 800, 1000, 1200, 1400, 1600\}$ astfel încât $f(20)=600$, $f(25)=600$, $f(30)=800$, $f(35)=f(40)=1000$, $f(45)=f(50)=1200$, $f(55)=f(60)=1400$, $f(65)=1600$.

Vom defini mulțimea A ca fiind mulțimea fuzzy de univers V "angajați tineri". Deoarece V este o mulțime discretă vom putea scrie pe A sub forma: $A = \sum_{x \in V} \varphi_A(x)/x$:

$$A = 1/20 + 1/25 + 0.8/30 + 0.6/35 + 0.4/40 + 0.2/45 + 0/50 + 0/55 + 0/60 + 0/65$$

Pe baza mulțimii A și a funcției f construim mulțimea fuzzy B "salariul angajaților tineri". Avem că $B = f(A)$ ($\forall x \in V, f(x) \in S$). Obținem:

$$\varphi_B(y) = \varphi_{f(A)}(y) = \max_{x \in V \mid f(x)=y} \varphi_A(x)$$

$$\begin{aligned}
B = f(A) &= f(\varphi_A(20)/20 + \varphi_A(25)/25 + \varphi_A(30)/30 + \varphi_A(35)/35 + \varphi_A(40)/40 + \\
&\varphi_A(45)/45 + \varphi_A(50)/50 + \varphi_A(55)/55 + \varphi_A(60)/60 + \varphi_A(65)/65) \\
&= \varphi_A(20)/f(20) + \varphi_A(25)/f(25) + \varphi_A(30)/f(30) + \varphi_A(35)/f(35) + \varphi_A(40)/f(40) + \\
&\varphi_A(45)/f(45) + \varphi_A(50)/f(50) + \varphi_A(55)/f(55) + \varphi_A(60)/f(60) + \varphi_A(65)/f(65) = 1/600 + \\
&1/600 + 0.8/800 + 0.6/1000 + 0.4/1000 + 0.2/1200 + 0/1200 + 0/1400 + 0/1600 = \\
&1/600 + 0.8/800 + 0.6/1000 + 0.2/1200 + 0/1400 + 0/1600
\end{aligned}$$

Să considerăm acum mulțimea fuzzy C "salarii mici" de univers S :

$$C = 1/600 + 0.75/800 + 0.5/1000 + 0.25/1200 + 0/1400 + 0/1600$$

Vrem să definim mulțimea fuzzy "vârsta angajaților cu salarii mici". Această mulțime este de univers V cu funcția de apartenență $\varphi_{f^{-1}(C)}$ unde:

$$\varphi_{f^{-1}(C)}(x) = \varphi_C(f(x)).$$

$$\begin{aligned}
f^{-1}(C) &= \sum_{x \in V} \varphi_{f^{-1}(C)}(x)/x = \sum_{x \in V} \varphi_C(f(x))/x = \varphi_C(f(20))/20 + \\
&+ \varphi_C(f(25))/25 + \varphi_C(f(30))/30 + \varphi_C(f(35))/35 + \varphi_C(f(40))/40 + \\
&+ \varphi_C(f(45))/45 + \varphi_C(f(50))/50 + \varphi_C(f(55))/55 + \varphi_C(f(60))/60 + \\
&+ \varphi_C(f(65))/65 = 1/20 + 1/25 + 0.75/30 + 0.5/35 + 0.5/40 + 0.25/45 + \\
&+ 0.25/50 + 0/50 + 0/60 + 0/65
\end{aligned}$$

2.2.2 Numere fuzzy

Definiția 2.2.2 Un număr fuzzy A este o mulțime fuzzy a numerelor reale care aproximează un alt număr real și care are o funcție de apartenență convexă și continuă cu suport marginit.

Definiția 2.2.3 Un număr fuzzy A se numește număr fuzzy triunghiular cu centrul c , lățimea la stânga $\alpha > 0$, lățimea la dreapta $\beta > 0$, dacă funcția de apartenență are forma:

$$\varphi_A(x) = \begin{cases} 1 - \frac{c-x}{\alpha}, & c - \alpha \leq x \leq c \\ 1 - \frac{x-c}{\beta}, & c < x \leq c + \beta \\ 0, & \text{altfel} \end{cases}$$

Folosim pentru un număr fuzzy triunghiular notația $A = (c, \alpha, \beta)$ cu $\text{supp}(A) = (c - \alpha, c + \beta)$. Semnificația acestei mulțimi fuzzy cu centrul c este "numărul este aproximativ egal cu c ".




Figura 2.4: Numere fuzzy

Definiția 2.2.4 Un număr fuzzy A se numește număr fuzzy trapezoidal cu intervalul de toleranță $[c, d]$, lățimea la stânga $\alpha > 0$, lățimea la dreapta $\beta > 0$, dacă are următoarea funcție de apartenență:

$$\varphi_A(x) = \begin{cases} 1 - \frac{c-x}{\alpha}, & c - \alpha \leq x \leq c \\ 1, & c < x \leq d \\ 1 - \frac{x-d}{\beta}, & d < x \leq d + \beta \\ 0, & \text{altfel} \end{cases}$$

Folosim următoarea notație pentru un număr fuzzy triunghiular $A = (c, d, \alpha, \beta)$ pentru care $\text{supp}(A) = (c - \alpha, d + \beta)$. Semnificația lui A este ”numărul este aproximativ între c și d ”.

Un număr fuzzy este întotdeauna o mulțime fuzzy însă reciproca nu este tot timpul adevărată. Extinzând noțiunea de număr fuzzy putem defini noțiunea de *interval fuzzy*.

Definiția 2.2.5 Un interval fuzzy este o mulțime fuzzy cu aceleași restricții ca pentru numere fuzzy, cu excepția faptului că nucleul nu mai este restricționat la un singur punct.

Operații cu numere fuzzy

Fie A și B două numere fuzzy cu funcțiile de apartenență φ_A respectiv φ_B . Operațiile aritmetice elementare între două numere fuzzy se definesc astfel:

$$\varphi_{A(\star)B}(z) = \max\{\min(\varphi_A(x), \varphi_B(y)), z = x \star y\}$$

unde prin $\star$ notăm operațiile: $+$ (adunare), $-$ (scădere), $\cdot$ (înmulțire), $/$ (împărțire).

Operațiile logice $\wedge$ (și logic), $\vee$ (sau logic) se realizează astfel:

$$\varphi_{A(\wedge)B}(z) = \max\{\min(\varphi_A(x), \varphi_B(y)), z = \min\{x, y\}\}$$

$$\varphi_{A(\vee)B}(z) = \max\{\min(\varphi_A(x), \varphi_B(y)), z = \max\{x, y\}\}$$

Exemplul 2.2.2 Fie A_1 numărul fuzzy "în jur de 5" cu funcția de apartenență

$$\varphi_{A_1}(x) = \max(1 - \frac{1}{2}|x - 5|, 0)$$

și A_2 numărul fuzzy "în jur de 2" cu funcția de apartenență

$$\varphi_{A_2}(x) = \max(1 - |x - 2|, 0)$$

Se dorește calculul expresiei $A_1(+)A_2$.

Observăm că ambele numere A_1 și A_2 sunt numere fuzzy triunghiulare: $A_1 = (5, 2, 2)$, $A_2 = (2, 1, 1)$.


Din expresiile funcțiilor de apartenență obținem: $A_1=0.5/4 + 1/5 + 0.5/6$ iar $A_2 = 0/1 + 1/2 + 0/3$ de unde rezultă $A_1(+)A_2 = 0.5/6 + 1/7 + 0.5/8$ deci $A_1(+)A_2$ este numărul fuzzy triunghiular "în jur de 7", $A_1(+)A_2 = (7, 3, 3)$.

2.3 t -norme și t -conorme

Definiția 2.3.1 [1] O funcție $T : [0, 1] \rightarrow [0, 1]$ se numește t -normă dacă sunt adevărate toate proprietățile următoare:

- $T(x, 1) = x$, $\forall x \in [0, 1]$ condiția la limită
- $T(x_1, x_2) \leq T(x_3, x_4)$, $\forall x_1 \leq x_3, x_2 \leq x_4$ monotonie
- $T(x, y) = T(y, x)$, $\forall x, y \in [0, 1]$ comutativitate
- $T(T(x_1, x_2), x_3) = T(x_1, T(x_2, x_3))$, $\forall x_1, x_2, x_3 \in [0, 1]$ asociativitate

Din aceste proprietăți mai obținem $T(x, 0) = T(0, x) = 0$, $\forall x \in [0, 1]$. Exemple de t -norme [1]:


 Figura 2.5: Exemple de t -norme

- $T_{\min}(x, y) = \min(x, y) \stackrel{\text{not}}{=} T_0(x, y)$
- $T_{\text{Lukasiewicz}}(x, y) = \max\{0, x + y - 1\} \stackrel{\text{not}}{=} T_{\infty}(x, y)$
- $T_{\text{prod}}(x, y) = xy \stackrel{\text{not}}{=} T_1(x, y)$

Fie A și B două mulțimi fuzzy. În cazul în care aceste mulțimi sunt legate folosind operatorul lingvistic AND atunci vom reprezenta această relație folosind o t -normă. Cele mai utilizate t -norme sunt:


$$\text{minimum: } \varphi_{A \cap B}(x) = T(\varphi_A(x), \varphi_B(x)) = \min(\varphi_A(x), \varphi_B(x))$$

$$\text{produsul: } \varphi_{A \cap B}(x) = T(\varphi_A(x), \varphi_B(x)) = \varphi_A(x)\varphi_B(x)$$

Definiția 2.3.2 [1] O funcție $S : [0, 1] \rightarrow [0, 1]$ se numește t -conormă dacă sunt adevărate toate proprietățile următoare:

- $S(x, 0) = x, \forall x \in [0, 1]$ condiția la limită
- $S(x_1, x_2) \leq S(x_3, x_4), \forall x_1 \leq x_3, x_2 \leq x_4$ monotonie
- $S(x, y) = S(y, x), \forall x, y \in [0, 1]$ comutativitate
- $S(S(x_1, x_2), x_3) = S(x_1, S(x_2, x_3)), \forall x_1, x_2, x_3 \in [0, 1]$ asociativitate

Din proprietățile de mai sus obținem $S(x, 1) = S(1, x) = 1, \forall x \in [0, 1]$. Exemple de t -conorme:

Figura 2.6: Exemple de t -conorme

- $S_{\max}(x, y) = \max(x, y) \stackrel{\text{not}}{=} S_0(x, y)$
- $S_{\text{Lukasiewicz}}(x, y) = \min\{x + y, 1\} \stackrel{\text{not}}{=} S_{\infty}(x, y)$
- $S_{\text{prod}}(x, y) = x + y - xy \stackrel{\text{not}}{=} S_1(x, y)$

Fie A și B două mulțimi fuzzy. În cazul în care aceste mulțimi sunt legate folosind operatorul lingvistic OR atunci vom reprezenta această relație folosind o t -conormă. Cele mai utilizate t -conorme sunt:

$$\text{maximum: } \varphi_{A \cup B}(x) = S(\varphi_A(x), \varphi_B(x)) = \max(\varphi_A(x), \varphi_B(x)),$$

$$\text{suma probabilistă: } \varphi_{A \cup B}(x) = S(\varphi_A(x), \varphi_B(x)) = \varphi_A(x) + \varphi_B(x) - \varphi_A(x)\varphi_B(x)$$

$$\text{suma marginită: } \varphi_{A \cup B}(x) = S(\varphi_A(x), \varphi_B(x)) = \min(1, \varphi_A(x) + \varphi_B(x))$$

Definiția 2.3.3 [1] O funcție $n : [0, 1] \rightarrow [0, 1]$ se numește negație sau complement dacă satisface condițiile:

- $n(0) = 1$
- $n(1) = 0$
- dacă $u \geq v$ atunci $n(u) \leq n(v)$ adică n este descrescătoare

O negație n este *strictă* [1] dacă n este funcție strict descrescătoare și continuă. Uzual se utilizează negația standard $n(x) = 1 - x, \forall x \in [0, 1]$. În acest caz unei t -norme T i se poate asocia o t -conormă S prin:

$$S(x, y) = 1 - T(1 - x, 1 - y)$$

Utilitatea operației *negație* se poate observa în propoziția următoare:

Propoziția 2.3.1 [1] Fie T o t -normă și n o negație strictă atunci funcția S_n definită prin:

$$S_n(x, y) = n(T(n(x), n(y)))$$

reprezintă o t -conormă. Dacă T este min și $n(x) = 1 - x$ atunci S_n este max.

2.4 Relații fuzzy

O relație binară crisp $R(U, V)$ poate fi definită astfel:

$$\varphi_R(u, v) = \begin{cases} 1, & \text{daca } (u, v) \in R(U, V) \\ 0, & \text{altfel} \end{cases}$$

Fiind date mulțimile univers U și V atunci o relație fuzzy $R(U, V)$ este o submulțime fuzzy a lui $U \times V$:

$$R(U, V) = \{ ((u, v), \varphi_R(u, v)) \mid (u, v) \in U \times V, \varphi_R(u, v) \in [0, 1] \}$$

Exemplul 2.4.1 Să presupunem că vrem să definim conceptul "vehiculul x este aproape de vehiculul y " în condițiile în care ambele vehicule se deplasează pe un drum de 40 km. Fiecare poziție a vehiculului este definită considerându-se distanța dintre acesta și origine. Dacă dorim să definim acest concept în logica clasică, trebuie să stabilim într-un mod neambiguu ce înseamnă aproape sau departe în metrica considerată. Astfel, dacă o distanță de cel mult 30 km între cele două vehicule ne permite să spunem că vehiculele sunt aproape unul de celălalt atunci putem exprima relația crisp "vehiculul x este aproape de vehiculul y " prin intermediul următoarei matrici relaționale:

	$v_1 = 0$	$v_2 = 20$	$v_3 = 40$
$u_1 = 0$	1	1	0
$u_2 = 20$	1	1	1
$u_3 = 40$	0	1	1

unde prin u_1, u_2, u_3 notăm pozițiile vehiculului x iar prin v_1, v_2, v_3 pozițiile vehiculului y iar domeniul (discret) de valori pentru poziția fiecărui vehicul este $\{0, 20, 40\}$.

Dacă în schimb alegem să definim acest concept folosind o relație fuzzy $R(U, V)$ unde $U = V = \{0, 20, 40\}$ cu funcția de apartenență: $\varphi_R(u, v) = 1 - \frac{|u-v|}{40}$, $(u, v) \in U \times V$ atunci matricea relațională devine:

	$v_1 = 0$	$v_2 = 20$	$v_3 = 40$
$u_1 = 0$	1	1/2	0
$u_2 = 20$	1/2	1	1/2
$u_3 = 40$	0	1/2	1

O relație fuzzy este de fapt o mulțime fuzzy definită pe un spațiu produs, ceea ce ne permite să utilizăm operațiile de bază ale mulțimilor fuzzy și pe mulțimea relațiilor fuzzy. Astfel, dacă R_1 și R_2 sunt două relații fuzzy definite pe același spațiu produs $U \times V$ atunci *intersecția* și *reuniunea* lor pot fi definite astfel:

$$\varphi_{R_1 \cup R_2}(u, v) = S(\varphi_{R_1}(u), \varphi_{R_2}(v))$$

$$\varphi_{R_1 \cap R_2}(u, v) = T(\varphi_{R_1}(u), \varphi_{R_2}(v))$$

O relație fuzzy de univers $U \times V$ se numește [1]:

- *reflexivă* dacă $\varphi_R(u, u) = 1$, $\forall u \in U$
- *antisimetrică* dacă din $\varphi_R(u, v) > 0$ și $\varphi_R(v, u) > 0$ avem $u = v$
- *simetrică* dacă $\varphi_R(u, v) = \varphi_R(v, u)$
- *tranzitivă* dacă $R \circ R \subseteq R$

O relație fuzzy reflexivă, simetrică și tranzitivă se numește *relație fuzzy de ordine* [1].

Exemplul 2.4.2 Să presupunem că vrem să definim conceptul "vehiculul x este aproape de vehiculul y și vehiculul x este mai aproape de sfârșitul drumului decât y ". Prima parte a propoziției este relația definită în Exemplul 2.4.1. A doua parte a propoziției poate fi definită folosind următoarea relație fuzzy de același univers ca și precedentă:

	$v_1 = 0$	$v_2 = 20$	$v_3 = 40$
$u_1 = 0$	0.5	0.25	0
$u_2 = 20$	0.75	0.5	0.25
$u_3 = 40$	1	0.75	0.5

Cum ambele părți ale propoziției sunt definite pe același spațiu produs $U \times V$, întreaga propoziție poate fi calculată folosind o T -normă (minimum).

De fapt multe relații fuzzy sunt obținute prin combinări ale mulțimilor fuzzy. Pentru a face acest lucru posibil mulțimile fuzzy sunt mai întâi convertite la relații fuzzy care apoi sunt operate cu o normă. Primul pas este realizat folosind *principiul extensiei cilindrice* propusă de L. A. Zadeh.

Acest principiu este aplicat atunci când suntem interesați să adăugăm o nouă dimensiune unei relații fuzzy de n domenii pentru a obține o relație fuzzy de $n + 1$ domenii. În acest sens dacă avem o mulțime fuzzy X a cărei funcție de apartenență e definită pe universul U , $\varphi_X : U \rightarrow [0, 1]$ atunci extensia cilindrică a lui X pe $U \times V$ este relația fuzzy definită prin:

$$ce\ of\ X\ on\ U \times V = \{ ((u, v), \varphi_X(u, v)) \mid (u, v) \in U \times V \}$$

Astfel, gradul de apartenență a lui $u \in U$ este copiat la toate perechile (u, v) , $\forall v \in V$.

Operatorul complementar extensiei este cel de *proiecție*. Definim proiecția lui $U \times V$ pe U ca fiind mulțimea fuzzy:

$$proj\ of\ U \times V\ on\ U = \{ (u, v_{\max\{\varphi_R(u,v)\}}) \mid u \in U \}$$

Exemplul 2.4.3 Să presupunem că avem două mulțimi fuzzy $A =$ "viteza fluidului pe conductă este mare" și $B =$ "debitul fluidului pe conductă este mare" (vezi Figura 2.7). Cu aceste două mulțimi vrem să construim relația fuzzy "viteza fluidului pe conductă este mare când debitul fluidului este mare".

Viteza fluidului ia valori între 0 și 1 m/s iar debitul este definit pe o scară de la 0 la 15 m³/s . Deoarece funcțiile de apartenență ale mulțimilor A și B sunt funcții liniare vom considera domeniile (discrete) $U = \{0, 0.5, 0.7, 1\}$ pentru mulțimea A și $V = \{0, 7.5, 14, 15\}$ pentru mulțimea B .

Pentru început folosim principiul extensiei cilindrice pentru a construi relația fuzzy R_1 pornind de la mulțimea A și relația fuzzy R_2 pornind de la mulțimea B :




Figura 2.7: Cele două mulțimi fuzzy din Exemplul 2.4.3

<i>viteza\debit</i>					<i>viteza\debit</i>				
(R_1)	0	7.5	14	15	(R_2)	0	7.5	14	15
0	0	0	0	0	0	0	0.5	0.9	1
0.5	0.5	0.5	0.5	0.5	0.5	0	0.5	0.9	1
0.7	0.7	0.7	0.7	0.7	0.7	0	0.5	0.9	1
1	1	1	1	1	1	0	0.5	0.9	1

Relația fuzzy "viteza fluidului este mare când debitul acestuia este mare" se obține aplicând o *T*-normă relațiilor R_1 și R_2 și anume min. Vom obține:

viteza\debit	0	7.5	14	15
0	0	0	0	0
0.5	0	0.5	0.5	0.5
0.7	0	0.5	0.7	0.7
1	0	0.5	0.9	1

Să considerăm acum două relații binare definite pe spații produs diferite dar care au o mulțime comună: $R_1(U, V)$ și $R_2(V, W)$. Compunerea acestor două relații este relația $R(U, W)$ care în logica clasică este definită astfel:

$$R(U, W) = R_1(U, V) \circ R_2(V, W) = \{ (u, w) \in U \times W \mid \exists v \in V : (u, v) \in U \times V, (v, w) \in V \times W \}$$

În logica fuzzy compunerea a două relații binare definite pe spații produs diferite dar care au o mulțime comună se definește analog compunerii crisp:




Figura 2.8: Mulțimea fuzzy "diferența de presiune este mare"

$$R(U, W) = \{ ((u, w), \varphi_R(u, w)) \mid (u, w) \in U \times W \} \text{ unde}$$

$$\varphi_R(u, w) = S_v(T(\varphi_{R_1}(u, v), \varphi_{R_2}(v, w)))$$

Deși se poate folosi orice T -normă și S -normă cele mai multe compuneri de relații fuzzy binare folosesc *maximul* ca S -normă și *produsul* sau *minimul* drept T -normă:

- $\varphi_R(u, w) = \max\{\min(\varphi_{R_1}(u, v), \varphi_{R_2}(v, w)) \mid v \in V\}$ – compunerea *max-min*
- $\varphi_R(u, w) = \max\{\varphi_{R_1}(u, v) \bullet \varphi_{R_2}(v, w) \mid v \in V\}$ – compunerea *max-produs*

De multe ori astfel de compuneri mai sunt numite și *sup-star compuneri* unde operatorul *star* este o T -normă:

$$\varphi_R(u, w) = \sup\{\varphi_{R_1}(u, v) * \varphi_{R_2}(v, w) \mid v \in V\}$$

Exemplul 2.4.4 Vom considera din nou relația fuzzy din ultimul exemplu "viteza fluidului pe conductă e mare când debitul acestuia este mare" (R_1) și în plus relația "debitul fluidului pe conductă este mare când diferența de presiune este mare" (R_2) pentru a calcula: "viteza fluidului pe conductă este mare când diferența de presiune pe conductă este mare" (R) folosind o compunere *max-min*:

viteza\debit (R_1)	0	7.5	14	15	debit\presiune (R_2)	0	2.5	3.5	1
0	0	0	0	0	0	0	0	0	0
0.5	0	0.5	0.5	0.5	7.5	0	0.5	0.5	0.5
0.7	0	0.5	0.7	0.7	14	0	0.5	0.7	0.9
1	0	0.5	0.9	1	15	0	0.5	0.7	1




Figura 2.9: Variabila lingvistică vârstă

viteza\presiune		0	2.5	3.5	5
(R)					
=	0	0	0	0	0
	0.5	0	0.5	0.5	0.5
	0.7	0	0.5	0.7	0.7
	1	0	0.5	0.7	1

2.5 Variabile lingvistice

Spre deosebire de variabilele algebrice ale căror valori sunt numere, variabilele lingvistice au ca valori cuvinte sau secvențe de cuvinte în limbaj natural sau artificial. Mulțimea valorilor unei variabile lingvistice se numește *mulțimea termenilor* [1]. Fiecare element din mulțimea termenilor este o valoare fuzzy definită în raport cu o *variabilă de bază*. Valorile variabilei de bază definesc mulțimea univers U a tuturor valorilor fuzzy din mulțimea termenilor [1].

Definiția 2.5.1 [1] Se numește *variabilă lingvistică* sistemul $(x, T(x), U, G, M)$ unde:

- x este numele variabilei
- $T(x)$ mulțimea termenilor lingvistici (*termen lingvistic*: valoare ce are asociată o funcție de apartenență și care caracterizează o variabilă lingvistică)
- U mulțimea universului de discurs
- G gramatica care produce termenii lui $T(x)$

- M regula semantică care mapează termenii lui $T(x)$ la mulțimi fuzzy ale lui U

Exemplul 2.5.1 Să considerăm variabila lingvistică x cu numele *cantitate*:

$$x = (\text{cantitate}, T(\text{cantitate}), U, G, M)$$

- $T(\text{cantitate}) = \{\text{mult}, \text{foarte mult}, \text{foarte foarte mult}, \text{etc}\}$

- $U = [50, 100]$

- $G(\text{cantitate}) : T \rightarrow \text{mult} \mid \text{foarte } T$

- $M(\text{mult}) = \{ (u, \varphi_{\text{mult}}(u)) \mid u \in [50, 100] \}$ iar

$$\varphi_{\text{mult}}(u) = \begin{cases} 1, & \text{daca } u \in [90, 100] \\ (1 + \frac{90-u}{5})^{-2}, & u \in [50, 90] \end{cases}$$

În exemplul de mai sus termenul *mult* este utilizat ca variabilă de bază în $T(\text{cantitate})$. Astfel de termeni se numesc *termeni primari*. Adăugând modificatori la termenii primari obținem noi termeni - *termeni fuzzy*.

În general *modificatorii lingvistici* se împart în trei categorii:

- *aproximatori de mulțimi fuzzy*. Cu astfel de modificatori dintr-un scalar putem obține o mulțime fuzzy. Exemple de aproximatori: *aproape, în jurul, aproximativ, etc*
- *restrângere de mulțimi fuzzy*. Aceștia modifică forma funcției de apartenență. Exemple de astfel de modificatori: *sub, peste*
- *intensificare sau diminuare*. Și aceștia modifică funcția de apartenență după cum urmează:

$$\varphi(x \text{ modificat}) = \varphi(x)^n$$

- *intensificare (concentrare)*: *foarte* ($n=2$), *extrem de* ($n=3$), etc.
- *diminuare (dilatare)*: *aproape* ($n=1/2$), *în mare măsură* ($n=5/7$), etc

Un termen lingvistic de cele mai multe ori este format din:

- un termen primar: *bun, prost, vechi, rar, etc.*
- un modificador fuzzy: *foarte, aproape, în jur de, probabil, etc.*




Figura 2.10: Valori de adevăr fuzzy

2.5.1 Valori de adevăr fuzzy

Folosind modificatorii lingvistici Baldwin a definit pe multimea univers $V = \{v \mid v \in [0, 1]\}$ valorile de adevăr fuzzy. Mulțimea lor este:

$$T = \{\text{adevărat, foarte adevărat, aproape adevărat, absolut adevărat, ..., fals, absolut fals, îndeajuns de fals}\}$$

Aceste valori de adevăr fuzzy au funcțiile de apartenență după cum urmează:

$$\begin{aligned} \varphi_{\text{adevărat}}(v) &= v & \varphi_{\text{fals}}(v) &= 1 - \varphi_{\text{adevărat}}(v) \\ \varphi_{\text{foarte_adevărat}}(v) &= (\varphi_{\text{adevărat}}(v))^2 & \varphi_{\text{foarte_fals}}(v) &= (\varphi_{\text{fals}}(v))^2 \\ \varphi_{\text{aproape_adevărat}}(v) &= (\varphi_{\text{adevărat}}(v))^{1/2} & \varphi_{\text{aproape_fals}}(v) &= (\varphi_{\text{fals}}(v))^{1/2} \\ \varphi_{\text{absolut_adevărat}}(v) &= \begin{cases} 1, & v = 1 \\ 0, & \text{altfel} \end{cases} & \varphi_{\text{absolut_fals}}(v) &= \begin{cases} 1, & v = 0 \\ 0, & \text{altfel} \end{cases} \end{aligned}$$

pentru $v \in [0, 1]$.

Se observă că:

$$\begin{aligned} \varphi_{\text{foarte_adevărat}}(v) &\leq \varphi_{\text{adevărat}}(v) \leq \varphi_{\text{aproape_adevărat}}(v) \text{ și} \\ \varphi_{\text{foarte_fals}}(v) &\leq \varphi_{\text{fals}}(v) \leq \varphi_{\text{aproape_fals}}(v) \end{aligned}$$

2.6 Propoziții și implicații fuzzy

Logica fuzzy se ocupă cu stabilirea valorii de adevăr a propozițiilor fuzzy. O *propoziție fuzzy elementară* este de forma " x este A " unde $A \in T(x)$ sau $A \in CT(x)$ (prin $CT(x)$ notăm mulțimea termenilor x care au fost modificați) [1].

Din motive practice trebuie ca funcția de apartenență a termenului A să fie normalizată. Valoarea de adevăr a unei propoziții elementare " x este A " este definită prin intermediul lui $\varphi_A(x)$ [1].

O operație importantă în modelarea fuzzy este *implicația fuzzy*. O implicație între două propoziții fuzzy definește tot o propoziție fuzzy care se poate exprima condițional prin [1]:

$$\text{Dacă } x \text{ este } A \text{ atunci } y \text{ este } B$$

Această construcție se obține pornind de la [1]:

- două variabile lingvistice: $(x, T(x), U, G_x, M_x)$ și $(y, T(y), V, G_y, M_y)$
- $A \in T(x)$ o mulțime fuzzy de univers U
- $B \in T(y)$ o mulțime fuzzy de univers V .

Practic valoarea de adevăr a implicației fuzzy este definită de funcția de apartenență φ_R a unei relații R între mulțimile U și V . Mai precis [1]:

$$\varphi_R(u, v) = \Phi(\varphi_A(u), \varphi_B(v))$$

Definiția implicației în logica propozițională consideră că o propoziție este falsă dacă și numai dacă antecedentul este fals și concluzia adevărată. Funcția Φ se alege astfel încât dacă A și B sunt mulțimi crisp atunci implicația fuzzy să fie similară celei din logica bivalentă.

Există patru clase importante de implicații fuzzy:

- *S-implicații*: bazate pe $p \rightarrow q = \neg p \vee q = S(n(\varphi(p), \varphi(q)))$
- *QL-implicații*: bazate pe $p \rightarrow q = \neg p \vee (p \wedge q) = \neg(p \wedge \neg(p \wedge q)) = n(T(\varphi(p), n(T(\varphi(p), \varphi(q))))))$

QL-implicațiile (Quantum Logic) modelează condiții de forma:

$$\text{"dacă ... atunci ... altfel"}$$

Aceste implicații sunt bazate pe $p \rightarrow q = \neg p \vee (p \wedge q) = \neg(p \wedge \neg(p \wedge q)) = n(T(\varphi(p), n(T(\varphi(p), \varphi(q)))))$

În acest fel structura ”dacă x este A atunci y este B altfel y este D ” se poate interpreta:

$$(x, y) \in (A \times B) \cup (C[A] \times D)$$

deci $\varphi_R(x, y) = S(T(\varphi_A(x), \varphi_B(y)), T(\varphi_{C[A]}(x), \varphi_D(y))) = S(T(\varphi_A(x), \varphi_B(y)), T(n(\varphi_A(x)), \varphi_D(y)))$.

Dacă $T(n(\varphi_A(x)), \varphi_D(y)) = n(\varphi_A(x))$, adică dacă $\varphi_D(y) = 1$ atunci obținem:

$$\varphi_R(x, y) = S(T(\varphi_A(x), \varphi_B(y)), n(\varphi_A(x))) = n(T(\varphi_A(x), n(T(\varphi_A(x), \varphi_B(y)))))$$

- *R-implicațiile* bazate pe $p \rightarrow q = \sup\{r \in [0, 1] \mid (p \wedge r) \leq q\}$ sau $p \rightarrow q = \sup\{r \in [0, 1] \mid T(\varphi(p), r) \leq \varphi(q)\}$
- *t-norm implicațiile* bazate pe $p \rightarrow q = p \wedge q$ (falsă în logica booleană!)

Deși implicațiile *t – norm*, cum ar fi implicația *Mamdani* nu se verifică pentru mulțimi crisp ele sunt totuși cele mai utilizate în logica fuzzy.

În tabelul de mai jos sunt prezentate cele mai utilizate implicații fuzzy [1]:

Nume	Funcție	Clasa
Reichenbach	$1 - \varphi_A(u) + \varphi_A(u)\varphi_B(v)$	S
Lukasiewicz	$\min(1, 1 - \varphi_A(u) + \varphi_B(v))$	S, R bazat pe: $(A \rightarrow B) = (\neg A) \vee B$
Gödel	$\begin{cases} 1, & \text{dacă } \varphi_A(u) \leq \varphi_B(v) \\ \varphi_B(v), & \text{altfel} \end{cases}$	R modus ponens generalizat
Gaines	$\begin{cases} 1, & \text{dacă } \varphi_A(u) \leq \varphi_B(v) \\ 0, & \text{altfel} \end{cases}$	R
Kleene-Dienes	$\max(1 - \varphi_A(u), \varphi_B(v))$	S, QL bazat pe: $(A \rightarrow B) = (\neg A) \vee B$
Zadeh	$\max(1 - \varphi_A(u), \min(\varphi_A(u), \varphi_B(v)))$	QL bazat pe: $(A \rightarrow B) = (\neg A) \vee (A \wedge B)$
Mamdani	$\min(\varphi_A(u), \varphi_B(v))$	T
Larsen	$\varphi_A(u)\varphi_B(v)$	

2.6.1 Modus ponens generalizat

Schema de raționament modus ponens generalizat este următoarea:

Premiza: u is A^*

Regula: IF u is A THEN v is B

Consecința: v is B^*

Mulțimea fuzzy A^* din premiză poate să fie diferită de mulțimea A din regulă, însă ambele mulțimi A și A^* trebuie să fie definite pe același univers. La fel pentru B și B^* . Pentru exemplificare să considerăm următoarea regulă:

Dacă persoana X este scundă atunci aceasta nu va fi un bun jucător de basket.

și premiza:

X are 168 cm în înălțime.

În logica crisp o regulă poate fi aplicată dacă și numai dacă premiza ei este identică cu antecedentul regulei iar rezultatul acestei operații este concluzia regulei. Însă în logica fuzzy o regulă este aplicată atâta timp cât gradul de apartenență al valorii lingvistice din premiză la mulțimea fuzzy din antecedentul regulei este nenul.

Astfel, în această regulă de raționament avem:

- o relație fuzzy $A \rightarrow B$ unde:

$$A \rightarrow B = \{((u, v), \varphi_{A \rightarrow B}(u, v)) \mid (u, v) \in U \times V\}$$

iar U și V sunt mulțimile univers pentru A respectiv B .

- o mulțime fuzzy A^* a cărei funcție de apartenență $\varphi_{A^*}(u)$ este cunoscută, $u \in U$
- și vrem să obținem mulțimea fuzzy B^* adică valorile funcției $\varphi_{B^*}(v)$, cu $v \in V$.

Mulțimea B^* este rezultatul compunerii dintre A^* și $A \rightarrow B$, adică:

$$B^* = A^* \circ (A \rightarrow B)$$

de unde rezultă:

$$B^* = \{(v, \sup_u (\varphi_{A^*}(u) \star \varphi_{A \rightarrow B}(u, v))) \mid v \in V\}$$

unde prin operatorul $\star$ notăm orice T -normă.

Exemplul 2.6.1 Să considerăm următoarea regulă:

Dacă presiunea este mare atunci volumul este mic.

Definim mulțimea fuzzy "presiunea este mare" prin $A = 0/1 + 0.2/3 + 0.7/6 + 1/10$ și mulțimea fuzzy "volumul este mic" prin $B = 1/1 + 0.6/10 + 0/50$.

Pentru implicația $A \rightarrow B$ vom folosi implicația Mamdani $\varphi_{A \rightarrow B}(u, v) = \min(\varphi_A(u), \varphi_B(v))$. Astfel matricea relației $A \rightarrow B$ este:

volum\presiune	1	3	6	10
1	0	0.2	0.7	1
10	0	0.2	0.6	0.6
20	0	0	0	0

Să considerăm acum premiza: "presiunea este de 3 bar", ceea ce ne permite să scriem: $A^* = 0/1 + 1/3 + 0/6 + 0/10$. Cum A^* nu este mulțimea A vom aplica metoda *modus ponens generalizat* pentru a obține concluzia B^* :

$$\varphi_{B^*}(v) = \max_u(\min(\varphi_{A^*}(u), \varphi_{A \rightarrow B}(u, v)))$$

și vom avea: $B^* = 0.2/1 + 0.2/10 + 0/20$.

În schimb pentru premiza "presiunea este de 10 bar", deci pentru $A^* = 0/1 + 0/3 + 0/6 + 1/10$ vom avea $B^* = 1/1 + 0.6/10 + 0/20$.

2.7 Sisteme fuzzy

Raționamentele în logica fuzzy utilizează mulțimi fuzzy pentru reprezentarea și manipularea cunoștințelor incerte. Un *sistem de control fuzzy* utilizează o colecție de funcții de apartenență și reguli pentru a raționa pe baza cunoștințelor date. Valorile crisp care reprezintă intrările unui astfel de sistem sunt transformate în valori fuzzy pentru a putea fi folosite în aplicarea regulilor sistemului, reguli ce sunt formulate prin intermediul expresiilor lingvistice. Cele mai multe sisteme fuzzy transformă și concluzia lingvistică obținută în valoare crisp.





Figura 2.11: Arhitectura unui controler fuzzy

Figura 2.12: O partiție fuzzy a intervalului $[-1, 1]$

Arhitectura unui sistem fuzzy pentru controlul proceselor - *controler fuzzy* este prezentată în Figura 2.11.

Așa cum se observă în figura de mai sus componentele unui controler fuzzy sunt:

- *modulul de fuzzificare* care transformă valorile de intrare crisp în mulțimi fuzzy pentru a putea calcula valoarea de adevăr a premisei fiecărei reguli din baza de reguli pentru intrarea dată. În general intrările unui sistem fuzzy sunt valori crisp (valori *singleton*). În acest caz acest modul va transforma valoarea de intrare în *mulțime fuzzy impuls (singleton)*.

De exemplu valoarea 10 din mulțimea univers $U = \{2, 5, 10, 15\}$ va fi transformată în mulțimea fuzzy impuls A de univers U astfel:

$$A = 0/2 + 0/5 + 1/10 + 0/15$$

În multe aplicații practice se normalizează domeniul intrărilor folosindu-se următorul tip de partiție: NB (negativ mare), NM (negativ mediu), NS (negativ mic), ZE (zero), PS (pozitiv mic), PM (pozitiv mediu), PB (pozitiv mare).

- *modulul de inferență* calculează valoarea de adevăr a premizelor din baza de

reguli în raport cu datele de intrare și aplică valorile obținute concluziilor corespunzătoare obținându-se astfel câte o mulțime fuzzy de ieșire pentru fiecare regulă.

- *modulul de agregare* combină toate mulțimile fuzzy asignate concluziilor regulilor de către modulul de inferență pentru a forma o singură mulțime fuzzy.
- *modulul de defuzzificare* are rolul de a converti mulțimea fuzzy obținută de modulul de agregare la o valoare crisp care va fi valoarea de ieșire a sistemului pentru intrarea dată.

Există mai multe tipuri de sisteme fuzzy:

- sisteme fuzzy MIMO (*Multiple Input Multiple Output*)
- sisteme fuzzy MISO (*Multiple Input Single Output*)

Așa cum am precizat, un sistem fuzzy conține o mulțime de reguli pe baza cărora se fac raționamentele. Regulile unui sistem fuzzy formează baza de reguli sau pe scurt *R*-baza. Fiecare regulă fuzzy este formată din două propoziții fuzzy: premiza și concluzia. Aceste propoziții conțin variabile lingvistice conectate prin intermediul operatorilor lingvistici *and*, *or* Totuși marea majoritate a sistemelor fuzzy bazate pe reguli folosesc doar operatorul lingvistic *and* în premisele regulilor în timp ce concluzia este formată dintr-o singură valoare lingvistică (sisteme MISO). În cele ce urmează vom exemplifica componentele și schemele de raționament ale sistemelor fuzzy de clasă MISO și anume ale sistemelor de tipul Two-Input/ Single-Output.

2.7.1 Two-Input/Single-Output fuzzy sistem

Forma generală a unui controler fuzzy de clasă Two-Input/Single-Output este următoarea:

Input: x is A' and y is B'

R₁ IF u is A_1 and v is B_1 THEN w is C_1

else R₂ IF u is A_2 and v is B_2 THEN w is C_2

...

else R_p IF u is A_n and v is B_m THEN w is C_k

Output: w is C'

unde u și v sunt variabile lingvistice reprezentând stările procesului modelat de sistem iar w este variabila lingvistică de control a sistemului. A_i, B_j și C_k sunt valorile lingvistice ale variabilelor u, v respectiv w de univers U, V, W pentru $i=\overline{1, n}$ $j=\overline{1, m}$ și $k=\overline{1, s}$.

Un astfel de sistem fuzzy necesită o bază de reguli (*R-bază*) de $n \times m$ reguli unde n reprezintă numărul de valori ale variabilei u iar m reprezintă numărul de valori ale variabilei v .

O regulă fuzzy:

R: IF u is A_i and v is B_j THEN w is C_k

este implementată ca o relație de implicație fuzzy și este definită după cum urmează:

R: $(A_i \text{ and } B_j) \rightarrow C_k$

$$\varphi_R(u, v, w) = \varphi_{(A_i \wedge B_j \rightarrow C_k)}(u, v, w) = [\varphi_{A_i}(u) \wedge \varphi_{B_j}(v)] \rightarrow \varphi_{C_k}(w)$$

unde A_i and B_j este o submulțime fuzzy $A_i \times B_j$ în $U \times V$ iar R este o relație de implicație fuzzy pe $U \times V \times W$.

Regula compozițională de inferență

Să considerăm o regulă fuzzy din *R-baza* sistemului fuzzy considerat și inferența sa (GMP - modus ponens generalizat):

Input: u is A' and v is B'

R: IF u is A and v is B THEN w is C

Output: w is C'

$A \subset U, B \subset V, C \subset W, u \in U, v \in V, w \in W$. Vom interpreta această regulă ca o implicație $A \times B \rightarrow C$ care este definită pe mulțimea produs $U \times V \times W$.

$$R: A \times B \rightarrow C \text{ sau } R = A \times B \times C$$

Când sistemul de inferență primește intrarea (A', B') atunci ieșirea C' este obținută printr-o inferență notată cu operatorul de compunere $\circ$ astfel:

$$C' = (A', B') \circ R$$




Figura 2.13: Mulțimea de ieșire C' corespunzătoare intrărilor crisp u_0 și v_0

Zadeh a numit acest proces de inferență prin *regula compozițională de inferență*. Inferența în sistemele fuzzy este determinată de doi factori: “operatorul de implicație” și “operatorul de compunere”. Pentru implicație cei mai des folosiți operatori sunt:

- *implicația Mamdani*: operatorul *min*
- *implicația Larsen*: operatorul *produs*

Pentru compunere de asemenea avem doi operatori foarte utilizați:

- *compunerea Mamdani*: *max-min*
- *compunerea Larsen*: *max-produs*

Propoziția 2.7.1 Pentru inputuri singleton mulțimea de ieșire C' este determinată de minimul gradelor de potrivire ale mulțimilor fuzzy A și B pentru intrările date. Dacă intrările sunt valori singleton $A' = u_0$ și $B' = v_0$ și notăm $\alpha = \min\{\varphi_A(u_0), \varphi_B(v_0)\}$ atunci rezultatul relației de implicație fuzzy R este:

- $\varphi_{C'}(w) = \alpha \wedge \varphi_C(w)$ dacă folosim implicația Mamdani
- $\varphi_{C'}(w) = \alpha \bullet \varphi_C(w)$ dacă folosim implicația Larsen

Demonstrație. Cum $C' = (A', B') \circ R = (A', B') \circ (A \text{ and } B \rightarrow C) = [A' \circ (A \rightarrow C)] \cap [B' \circ (B \rightarrow C)]$ rezultă că avem:

$$\begin{aligned} \varphi_{C'}(w) &= \min\{u_0 \circ (\varphi_A(u) \rightarrow \varphi_C(w)), v_0 \circ (\varphi_B(v) \rightarrow \varphi_C(w))\} = \\ &= \min\{\varphi_A(u_0) \rightarrow \varphi_C(w), \varphi_B(v_0) \rightarrow \varphi_C(w)\} \end{aligned}$$

1. Dacă utilizăm operatorul de implicație fuzzy Mamdani:

$$\begin{aligned}\varphi_{C'}(w) &= \min\{\min\{\varphi_A(u_0), \varphi_C(w)\}, \min\{\varphi_B(v_0), \varphi_C(w)\}\} = \min\{\min\{\varphi_A(u_0), \varphi_B(v_0)\}, \\ \varphi_C(w)\} &= \min\{\alpha, \varphi_C(w)\} = \alpha \wedge \varphi_C(w)\end{aligned}$$

2. Dacă utilizăm operatorul de implicație fuzzy Larsen:

$$\begin{aligned}\varphi_{C'}(w) &= \min\{\varphi_A(u_0) \bullet \varphi_C(w), \varphi_B(v_0) \bullet \varphi_C(w)\} = \min\{\varphi_A(u_0), \varphi_B(v_0)\} \bullet \varphi_C(w) = \\ \alpha \bullet \varphi_C(w) &\end{aligned} \quad \square$$

Propoziția 2.7.2 Pentru intrarea fuzzy (A', B') mulțimea de ieșire C' este determinată de minimul gradelor de potrivire ale lui (A', A) și (B', B) . Astfel, dacă intrarea este perechea de mulțimi fuzzy (A', B') atunci gradul de potrivire α este dat de minimul dintre (A', A) și (B', B) , deci:

$$\alpha = \min\{\max_u(\varphi_{A'}(u) \wedge \varphi_A(u)), \max_v(\varphi_{B'}(v) \wedge \varphi_B(v))\}$$

iar mulțimea de ieșire C' este definită astfel:

1. $\varphi_{C'}(w) = \alpha \wedge \varphi_C(w)$ dacă folosim implicația Mamdani
2. $\varphi_{C'}(w) = \alpha \bullet \varphi_C(w)$ dacă folosim implicația Larsen

Demonstrație. Cum $C' = [A' \circ (A \rightarrow C)] \cap [B' \circ (B \rightarrow C)]$ obținem:

$$\varphi_{C'}(w) = \min\{\varphi_{A'}(u) \circ (\varphi_A(u) \rightarrow \varphi_C(w)), \varphi_{B'}(v) \circ (\varphi_B(v) \rightarrow \varphi_C(w))\}$$

1. Dacă folosim operatorii Mamdani *min* pentru implicație și *max-min* pentru compunere avem:

$$\begin{aligned}\varphi_{C'}(w) &= \min\{\varphi_{A'}(u) \circ \min_u\{\varphi_A(u), \varphi_C(w)\}, \varphi_{B'}(v) \circ \min_v\{\varphi_B(v), \varphi_C(w)\}\} = \min \\ \{\varphi_{A'}(u) \circ (\varphi_A(u) \wedge \varphi_C(w)), \varphi_{B'}(v) \circ (\varphi_B(v) \wedge \varphi_C(w))\} &= \min\{\max_u \min_u\{\varphi_{A'}(u), \varphi_A(u) \wedge \\ \varphi_C(w)\}, \max_v \min_v\{\varphi_{B'}(v), \varphi_B(v) \wedge \varphi_C(w)\}\} &= \min\{\max_u(\varphi_{A'}(u) \wedge \varphi_A(u)) \wedge \varphi_C(w), \\ \max_v(\varphi_{B'}(v) \wedge \varphi_B(v)) \wedge \varphi_C(w)\} &= \min\{\max_u(\varphi_{A'}(u) \wedge \varphi_A(u)), \max_v(\varphi_{B'}(v) \wedge \varphi_B(v))\} \wedge \\ \varphi_C(w) &= \alpha \wedge \varphi_C(w)\end{aligned}$$

2. Dacă folosim operatorii Larsen *produs* pentru implicație și *max-produs* pentru compunere avem:




Figura 2.14: Mulțimea de ieșire C' corespunzătoare intrărilor fuzzy A' și B'

$$\begin{aligned} \varphi_{C'}(w) &= \min\{\varphi_{A'}(u) \circ (\varphi_A(u) \bullet \varphi_C(w)), \varphi_{B'}(v) \circ (\varphi_B(v) \bullet \varphi_C(w))\} = \min\{\max_u \\ &\min_u(\varphi_{A'}(u), \varphi_A(u)) \bullet \varphi_C(w), \max_v \min_v(\varphi_{B'}(v) \bullet \varphi_B(v)) \bullet \varphi_C(w)\} = \min\{\max_u(\varphi_{A'}(u) \\ &\wedge \varphi_A(u)) \bullet \varphi_C(w), \max_v(\varphi_{B'}(v) \wedge \varphi_B(v)) \bullet \varphi_C(w)\} = \min\{\max_u(\varphi_{A'}(u) \wedge \varphi_A(u)), \max_v \\ &(\varphi_{B'}(v) \wedge \varphi_B(v))\} \bullet \varphi_C(w) = \alpha \bullet \varphi_C(w) \end{aligned}$$

2.7.2 Inferența fuzzy într-o R -bază a unui sistem fuzzy Two-Input/Single-Output

În această secțiune vom extinde regula compozițională de inferență la un set de p reguli. Astfel vom considera:

Input: (A', B')

$R = \bigcup_{l=1}^p R_l$ unde $R_l : (A_i \text{ and } B_j) \rightarrow C_k$

Output: C'

Propoziția 2.7.3 Mulțimea de ieșire C' este rezultatul procesului de agregare a tuturor concluziilor $C'_l = (A', B') \circ R_l$, $l=1, \overline{p}$ obținute în urma aplicării celor p reguli din R -bază pentru intrarea (A', B') .

$$C' = (A', B') \circ R = (A', B') \circ \bigcup_{l=1}^p R_l = \bigcup_{l=1}^p (A', B') \circ R_l = \bigcup_{l=1}^p C'_l$$

Demonstrație. Într-adevăr relația $C' = (A', B') \circ \bigcup_{l=1}^p R_l$ este echivalentă cu:

$$\varphi_{C'}(w) = [\varphi_{A'}(u), \varphi_{B'}(v)] \circ \max_{u,v,w} \{\varphi_{R_1}(u, v, w), \dots, \varphi_{R_p}(u, v, w)\}$$

Înlocuind operatorul de compunere $\circ$ cu operatorul $\max$ - $\min$ obținem:

$$\varphi_{C'}(w) = \max_{u,v} \min_{u,v} \{[\varphi_{A'}(u), \varphi_{B'}(v)], \max_{u,v,w} \{\varphi_{R_1}(u, v, w), \dots,$$




Figura 2.15: Reprezentarea grafică a metodei de inferență Mamdani

$$\varphi_{R_p}(u, v, w) = \max_{u,v} \max_{u,v,w} \{ \min_{u,v} \{ [\varphi_{A'}(u), \varphi_{B'}(v)], \varphi_{R_l}(u, v, w) \}, \dots, \min_{u,v} \{ [\varphi_{A'}(u), \varphi_{B'}(v)], \varphi_{R_p}(u, v, w) \} \}$$

Dar $\max_{u,v} \min_{u,v} \{ [\varphi_{A'}(u), \varphi_{B'}(v)], \varphi_{R_l}(u, v, w) \} = (\varphi_{A'}(u), \varphi_{B'}(v)) \circ \varphi_{R_l}(u, v, w) = \varphi_{C'_l}(w)$ cu $l = \overline{1, p}$ așa încât vom avea:

$$\varphi_{C'}(w) = \max_w \{ \varphi_{C'_1}(w), \dots, \varphi_{C'_p}(w) \} \text{ deci } C' = \bigcup_{l=1}^p C'_l. \quad \square$$

Pentru simplitate vom considera în cele ce urmează că sistemul conține numai două reguli în bază și anume:

R₁ IF u is A_1 and v is B_1 THEN w is C_1

else R₂ IF u is A_2 and v is B_2 THEN w is C_2

Notăm cu α_1, α_2 gradul de potrivire al intrărilor în raport cu premiza primei, respectiv a celei de-a doua reguli din bază. Motorul de inferență al unui controler fuzzy poate fi implementat folosindu-se diverse metode de inferență. Cele mai cunoscute sunt: *Mamdani*, *Larsen*, *Tsukamoto* și *TSK* (Takagi-Sugeno-Kang). Ele vor fi prezentate în cele ce urmează.

Metoda Mamdani

Această metodă folosește operatorul *min* pentru implicație și operatorul *min-max* pentru compunere. Așa cum s-a arătat

$$\varphi_{C'_i}(w) = \alpha_i \wedge \varphi_{C_i}(w) \text{ cu } i = \overline{1, 2}$$

iar mulțimea de ieșire a sistemului C' este reuniunea mulțimilor C'_1 și C'_2 . Grafic, ieșirea unui sistem cu două reguli ce folosește metoda de inferență Mamdani este prezentată în Figura 2.15.




Figura 2.16: Reprezentarea grafică a metodei de inferență Larsen

Mulțimea rezultat C' este o mulțime fuzzy și drept consecință dacă dorim să obținem un control deterministic trebuie să defuzzificăm această mulțime.

Metoda Larsen

Această metodă folosește operatorul *produs* pentru implicație și operatorul *max-produs* pentru compunere. După cum s-a demonstrat mai sus

$$\varphi_{C'_i}(w) = \alpha_i \bullet \varphi_{C_i}(w) \text{ cu } i = \overline{1, 2}$$

iar mulțimea de ieșire a sistemului C' este reuniunea mulțimilor C'_1 și C'_2 . Grafic, ieșirea unui sistem cu două reguli ce folosește metoda de inferență Larsen este prezentată în Figura 2.16.

Metoda Tsukamoto

În această metodă concluzia fiecărei reguli este reprezentată printr-o mulțime fuzzy care are ca funcție de apartenență $\varphi_{C_i}(w)$ o funcție monotonă. De aceea ieșirea fiecărei reguli este o valoare crisp w_i această valoare calculându-se în funcție de gradele de potrivire α_i ale intrărilor în raport cu valorile lingvistice din premisele R -bazei.

$$w_i = \varphi_{C_i}^{-1}(\alpha_i) \text{ cu } i = \overline{1, 2}$$

Rezultatul final este media ponderată a ieșirilor fiecărei reguli.

$$w_0 = \frac{\alpha_1 w_1 + \alpha_2 w_2}{\alpha_1 + \alpha_2}$$




Figura 2.17: Reprezentarea grafică a metodei de inferență TSK

Cum rezultatul aplicării fiecărei reguli din bază este o valoare crisp, modelul Tsukamoto combină aceste ieșiri crisp într-o medie ponderată obținându-se pentru concluzia finală tot o valoare crisp. În consecință, folosindu-se această metodă se elimină consumul de timp necesar defuzzificării.

Metoda TSK

Această metodă a fost propusă de Takagi, Sugeno și Kang. O regulă fuzzy în acest model are forma:

$$\text{IF } u \text{ is } A \text{ and } v \text{ is } B \text{ THEN } w = f(u, v)$$

unde A și B sunt mulțimi fuzzy iar $f(u, v)$ este o funcție crisp. De obicei $f(u, v)$ este un polinom de variabile u și v de aceea această metodă necesită intrări singleton.

Să presupunem că cele două reguli ale R -bazei au următoarea formă:

$$R_1 : \text{IF } u \text{ is } A_1 \text{ and } v \text{ is } B_1 \text{ THEN } w_1 = f_1(u, v) = p_1 u + q_1 v + r_1$$

$$R_2 : \text{IF } u \text{ is } A_2 \text{ and } v \text{ is } B_2 \text{ THEN } w_2 = f_2(u, v) = p_2 u + q_2 v + r_2$$

unde p_i, q_i, r_i sunt constante.

Valoarea obținută în urma aplicării regulii R_i pentru intrarea singleton u_0 și v_0 este valoarea crisp $f_i(u_0, v_0)$ cu gradul de potrivire α_i . Rezultatul agregării acestor ieșiri este dat de media ponderată:

$$w_0 = \frac{\alpha_1 f_1(u_0, v_0) + \alpha_2 f_2(u_0, v_0)}{\alpha_1 + \alpha_2} = \frac{\alpha_1 w_1 + \alpha_2 w_2}{\alpha_1 + \alpha_2}$$

La fel ca și metoda Tsukamoto ieșirea w_0 nu necesită defuzzificare fiind o valoare crisp.




Figura 2.18: Defuzzificare

2.7.3 Metode de defuzzificare

Pentru sistemele fuzzy care obțin concluzia finală sub forma unei mulțimi fuzzy se pune de multe ori problema conversiei acesteia la o valoare crisp. Această conversie fuzzy-crisp este realizată de modulul de defuzzificare.

Două din cele mai utilizate tehnici de defuzzificare sunt *metoda centrului de greutate* (center of gravity: COG) și *media maximului* (mean of maxima: MOM).

În metoda centrului de greutate valoarea crisp de ieșire este variabila a cărei apartenență la mulțimea fuzzy de ieșire se află în centrul de greutate al valorilor funcției de apartenență.

$$y_{COG} = \frac{\int x\varphi(x)dx}{\int \varphi(x)dx}$$

Folosind media maximului valoarea crisp de ieșire se alege din mulțimea valorilor care au apartenență maximă la mulțimea fuzzy care este supusă defuzzificării.

Exemplificare:

Considerăm sistemul fuzzy cu două intrări și o singură ieșire care modelează relația:

$$\frac{\text{presiune-volum}}{\text{temperatura}} = \text{const}$$

care pe baza valorilor de intrare pentru temperatură și volum calculează valoarea corespunzătoare presiunii.

Înainte de a proiecta regulile sistemului trebuie să definim variabilele fuzzy: *temperatura*, *volum* și *presiune*. Astfel definim variabila lingvistică *temperatura* prin sistemul $(t, T(t), U, G_t, M_t)$ unde:

- $U=[0,120]$ măsurat în grade Celsius

- $T(t) = \{mică, sub\ medie, medie, peste\ medie, mare\}$ - mulțimea termenilor variabilei t
- $G_t(t) : \begin{array}{l} t \rightarrow mică|medie|mare \\ t \rightarrow sub\ t|peste\ t, dacā\ t = medie \end{array}$
- $M_t(mică) = \{ (u, \varphi_{mică}(u)) \mid u \in [0, 120] \}$

$$\varphi_{mică}(u) = \begin{cases} 1, & dacā\ u \in [0, 20] \\ \frac{40-u}{20}, & dacā\ u \in [20, 40] \\ 0, & altfel \end{cases}$$

$$M_t(medie) = \{ (u, \varphi_{medie}(u)) \mid u \in [0, 120] \}$$

$$\varphi_{medie}(u) = \begin{cases} \frac{u-40}{20}, & dacā\ u \in [40, 60] \\ \frac{80-u}{20}, & dacā\ u \in [60, 80] \\ 0, & altfel \end{cases}$$

$$M_t(mare) = \{ (u, \varphi_{mare}(u)) \mid u \in [0, 120] \}$$

$$\varphi_{mare}(u) = \begin{cases} \frac{u-80}{20}, & dacā\ u \in [80, 100] \\ 1, & dacā\ u \in [100, 120] \\ 0, & altfel \end{cases}$$

$$M_t(sub\ medie) = \{ (u, \varphi_{sub\ medie}(u)) \mid u \in [0, 120] \}$$



$$\varphi_{sub\ medie}(u) = \begin{cases} \varphi_{medie}(u + 20) + 1, & dacā\ u \in [20, 40] \\ \varphi_{medie}(u + 20) - 1, & dacā\ u \in [40, 60] \\ 0, & altfel \end{cases}$$

$$M_t(peste\ medie) = \{ (u, \varphi_{peste\ medie}(u)) \mid u \in [0, 120] \}$$

$$\varphi_{peste\ medie}(u) = \begin{cases} \varphi_{medie}(u - 20) - 1, & dacā\ u \in [60, 80] \\ \varphi_{medie}(u - 20) + 1, & dacā\ u \in [80, 100] \\ 0, & altfel \end{cases}$$

Variabila lingvistică *volum* este definită prin sistemul: $(v, T(v), V, G_v, M_v)$ unde:

- $V = \{10, 15, 30\}$
- $T(v) = \{mic, mediu, mare\}$
- $G_v(v) : v \rightarrow mic\ |mediu\ |mare$

Figura 2.19: Variabila lingvistică *temperatura*Figura 2.20: Variabila lingvistică *presiunea*

- $M_v(mic) = 1/10 + 0.6/15 + 0/30$

$$M_v(mediu) = 0.6/10 + 1/15 + 0/30$$

$$M_v(mare) = 0/10 + 0.4/15 + 1/30$$

Variabila lingvistică *presiunea* se definește de o manieră asemănătoare celei folosite în cazul variabilei *temperatura*: $(p, T(p), W, G_w, M_w)$ unde:

- $W=[0,60]$ măsurat în N/m^2
- $T(p)=\{mică, sub\ medie, medie, peste\ medie, mare\}$

Deoarece intrările *temperatura* și *volum* au mulțimea termenilor de 5, respectiv 3 elemente obținem că *R*-baza sistemului trebuie să aibă 5×3 relații câte una pentru fiecare posibilă combinație de intrări. Considerând următoarele notații pentru valorile lingvistice folosite de sistem: S (mică), BM (sub medie), M (mediu), AM (peste medie), B (mare) atunci setul complet de reguli al sistemului este:

<i>volum\temp</i>	S	BM	M	AM	B
S	<i>S</i>	<i>S</i>	<i>M</i>	<i>AM</i>	<i>B</i>
M	<i>S</i>	<i>S</i>	<i>BM</i>	<i>M</i>	<i>M</i>
B	<i>S</i>	<i>S</i>	<i>S</i>	<i>S</i>	<i>BM</i>

Vom prezenta inferența în acest sistem considerând intrările crisp: $t_0 = 77^\circ C$ și $v_0 = 10m^3$. Observăm că:

$$\varphi_{medie}(t_0) = 0.15, \varphi_{peste_medie}(t_0) = 0.85$$

$$\varphi_{mic}(v_0) = 1, \varphi_{mediu}(v_0) = 0.6$$

Rezultă că următoarele reguli vor fi aplicate:

$$R_{13} : \text{IF } t \text{ este } medie \text{ AND } v \text{ este } mic \text{ THEN } p \text{ este } medie \Rightarrow \alpha_{13} = \min(\varphi_{medie}(t_0), \varphi_{mic}(v_0)) = \min(0.15, 1) = 0.15$$

$$R_{14} : \text{IF } t \text{ este } peste_medie \text{ AND } v \text{ este } mic \text{ THEN } p \text{ este } peste_medie \Rightarrow \alpha_{14} = \min(\varphi_{peste_medie}(t_0), \varphi_{mic}(v_0)) = \min(0.85, 1) = 0.85$$

$$R_{23} : \text{IF } t \text{ este } medie \text{ AND } v \text{ este } mediu \text{ THEN } p \text{ este } sub_medie \Rightarrow \alpha_{23} = \min(\varphi_{medie}(t_0), \varphi_{mediu}(v_0)) = \min(0.15, 0.6) = 0.15$$

$$R_{24} : \text{IF } t \text{ este } peste_medie \text{ AND } v \text{ este } mediu \text{ THEN } p \text{ este } medie \Rightarrow \alpha_{24} = \min(\varphi_{peste_medie}(t_0), \varphi_{mediu}(v_0)) = \min(0.85, 0.6) = 0.6$$

Așa cum am spus există două tipuri de implicație foarte des folosite: implicația *Mamdani* și implicația *Larsen*.

Implicația Mamdani

$$\varphi_{OUTPUT\ R13}(p) = 0.15 \wedge \varphi_{medie}(p)$$

$$\varphi_{OUTPUT\ R14}(p) = 0.85 \wedge \varphi_{peste_medie}(p)$$

$$\varphi_{OUTPUT\ R23}(p) = 0.15 \wedge \varphi_{sub_medie}(p)$$

$$\varphi_{OUTPUT\ R24}(p) = 0.6 \wedge \varphi_{medie}(p)$$

Implicația Larsen

$$\varphi_{OUTPUT\ R13}(p) = 0.15 \bullet \varphi_{medie}(p)$$

$$\varphi_{OUTPUT\ R14}(p) = 0.85 \bullet \varphi_{peste_medie}(p)$$

$$\varphi_{OUTPUT\ R23}(p) = 0.15 \bullet \varphi_{sub_medie}(p)$$

$$\varphi_{OUTPUT\ R24}(p) = 0.6 \bullet \varphi_{medie}(p)$$

pentru $p \in [0, 60]$.

Așa cum s-a precizat concluzia finală și anume concluzia corespunzătoare celor patru reguli care au fost aplicate este reuniunea concluziilor parțiale:

$$\varphi_{OUTPUT}(p) = \varphi_{OUTPUT\ R13}(p) \cup \varphi_{OUTPUT\ R14}(p) \cup \varphi_{OUTPUT\ R23}(p) \cup \varphi_{OUTPUT\ R24}(p)$$

Aceste mulțimi fuzzy de ieșire pot fi defuzificate în cazul în care se dorește ca ieșirea sistemului să fie de aceeași natură cu intrarea acestuia - și anume o valoare crisp.




Figura 2.21: Ieșirea sistemului folosind implicația *Mamdani* (a) și *Larsen* (b)

Vom aplica metoda de defuzificare COG pentru mulțimea fuzzy obținută cu implicația Mamdani și avem:

$$y_{COG} = \frac{\int x\varphi(x)dx}{\int \varphi(x)dx}$$

$$\int \varphi(x)dx = \int_{10}^{11.5} \left(\frac{x}{10} - 1\right)dx + \int_{11.5}^{21.5} 0.15dx + \int_{21.5}^{26} \left(\frac{x}{10} - 2\right)dx + \int_{26}^{34} 0.6dx + \int_{34}^{35} \left(4 - \frac{x}{10}\right)dx + \int_{35}^{38.5} \left(\frac{x}{10} - 3\right)dx + \int_{38.5}^{41.5} 0.85dx + \int_{41.5}^{50} \left(5 - \frac{x}{10}\right)dx = 20.175$$

$$\int x\varphi(x)dx = \int_{10}^{11.5} \left(\frac{x^2}{10} - x\right)dx + \int_{11.5}^{21.5} 0.15xdx + \int_{21.5}^{26} \left(\frac{x^2}{10} - 2x\right)dx + \int_{26}^{34} 0.6xdx + \int_{34}^{35} \left(4x - \frac{x^2}{10}\right)dx + \int_{35}^{38.5} \left(\frac{x^2}{10} - 3x\right)dx + \int_{38.5}^{41.5} 0.85xdx + \int_{41.5}^{50} \left(5x - \frac{x^2}{10}\right)dx = 383.725$$

Deci obținem: $y_{COG} = 19.01$

Bibliografie

- [1] **Ion Vaduva, Grigore Albeanu** *Introducere in Modelarea Fuzzy*, Editura Universității din București, 2004
- [2] **L.A. Zadeh** *Fuzzy Sets* Information and control, vol. 8, pp. 338 - 353, 1965
- [3] **R. Yager** *Fuzzy logic in control*, Ph. D. dissertation, Technical University of Delft, 1995
- [4] **Carles Garigga Berga** *A new approach to the synthesis of intelligible fuzzy models from input-output data*, Ph. D. dissertation, Universitat Ramon Llull, 2005
- [5] **R. Jang, C. T. Sun, E. Mizutani** *Neuro-Fuzzy and Soft-Computing*, First Edition, Prentice Hall, 1997
- [6] **F. Chevré, F. Guély** *Fuzzy Logic*, Cahier technique no. 191, 1998
- [7] **D. Dubois, H. M. Prade**, *Fuzzy sets and systems: theory and applications*, New-York Academic Press, 1980
- [8] Department of Computing Science, Umea University, Sweden, *Fuzzy Systems - Lecture notes*

Capitolul 3

Sisteme fuzzy pentru control inteligent

3.1 Mulțimi vagi

Noțiunea de *mulțime vagă* a fost introdusă în matematică și teoria sistemelor de L.A. Zadeh în 1965 sub denumirea de *mulțime fuzzy* care în traducere înseamnă mulțime neclară, estompată și se folosește cu sensul de *vag*, *imprecis*. Acestui domeniu îi sunt consacrate deja lucrări fundamentale recunoscute.

Pornind de la concepția clasică cu privire la mulțime și element al unei mulțimi, se poate susține că noțiunea de *mulțime fuzzy* reprezintă o abordare dintr-un unghi diferit a conceptului de mulțime, mai precis, între apartenența unui element la o mulțime și nonapartenență există o serie de situații tranzitorii, de natura continuă, caracterizate de așa-numitele *grade de apartenență*.

Definiția 3.1.1 Fie X o mulțime oarecare. Se numește mulțime fuzzy (în X) rezultatul unei aplicații $F : X \rightarrow [0, 1]$.

Mulțimea fuzzy F este caracterizată de funcția de apartenență: $m_F : X \rightarrow [0, 1]$.




Figura 3.1: Funcția de apartenență triunghiulară

3.1.1 Funcții de apartenență tipice

Pentru descrierea fuzzy a unor fenomene și procese, aplicațiile $m_F(x)$ pot admite diferite exprimări analitice. Câteva dintre acestea sunt consacrate în aplicații datorită unor facilități legate de calculabilitate și ușurința implementării hardware/software. Pentru exemplificare vom considera că funcțiile sunt definite pe intervalul $[a, b]$ și $c = (a + b)/2$.

Funcția de apartenență triunghiulară

Expresia analitică a acestei funcții de apartenență este identică cu ecuația dreptei ce trece prin punctele de coordonate $(a, 0)$ și $(c, 1)$ pentru $x \in [a, c]$ și cu ecuația dreptei ce trece prin punctele de coordonate $(c, 1)$ și $(b, 0)$, pentru $x \in (c, b]$. Deci:

$$m(x) = \begin{cases} (x - a)/(c - a), & a \leq x \leq c \\ 1 - (x - c)/(b - c), & c < x \leq b \end{cases}$$

În cazul în care $c = (a + b)/2$ relația se poate scrie compact sub forma:

$$m(x) = 1 - 2 \frac{|x - c|}{b - a}$$

Funcția de apartenență trapezoidală

Expresia analitică a acestei funcții de apartenență se obține simplu observând că trapezul rezultă prin intersecția unui triunghi de forma celui din Figura 3.1, având înălțimea $h_t > 1$ și dreapta de ecuație $m(x) = 1$. Astfel:

$$m(x) = \min \left[1, h_t \left(1 - 2 \frac{|x - c|}{b - a} \right) \right], \text{ cu } h_t > 1.$$




Figura 3.2: Funcția de apartenență trapezoidală




Figura 3.3: Funcția de apartenență parabolică

Funcția de apartenență parabolică

O parabolă având axa de simetrie verticală și vârful în punctul (x_0, m_0) de pe această axă este descrisă de ecuația:

$$m(x) - m_0 = -2p(x - x_0)^2$$

Din condițiile ca parabola să aibă vârful în punctul $(c, 1)$ și să intersecteze axa absciselor în punctele de coordonate $(a, 0)$ și $(b, 0)$ rezultă expresia analitică a funcției de apartenență parabolică din Figura 3.3. Aceasta este:

$$m(x) = 1 - 4 \left(\frac{x-c}{b-a} \right)^2$$

Funcția de apartenență tip armonic

O variantă a acestora se poate construi cu ajutorul funcției sinusoidale de amplitudine 1 și fază 0:

$$m(x) = \sin(x), \text{ cu } x \in [0, \pi],$$

pentru care, punând condițiile $m(c) = 1$ și $m(a) = m(b) = 0$ rezultă expresia analitică:



Figura 3.4: Funcția de apartenență de tip *clopot*

Figura 3.5: Funcții de apartenență de tip saturație

$$m(x) = \sin\left(\pi \frac{x-a}{a-b}\right), \text{ cu } x \in [a, b]$$

având reprezentarea grafică similară cu cea din Figura 3.3.

Funcția de apartenență de tip clopot

Expresia analitică a funcției de tip ”*clopotul lui Gauss*” caracterizată prin dispersia σ , amplitudinea A și centrată pe dreapta de ecuație $x = x_0$ este:

$$m(x) = Ae^{-\frac{(x-x_0)^2}{2\sigma^2}}$$

Pentru funcția de apartenență din Figura 3.4 cu amplitudinea $A = 1$, dispersia $\sigma = b - a$ și centrată pe dreapta de ecuație $x = c$, se obține expresia:

$$m(x) = e^{-\frac{(x-c)^2}{2(b-a)^2}}$$

Funcții de apartenență de tip saturație

Acestea se definesc ca funcții de tip rampă la dreapta sau la stânga, cuplate în partea extremă cu porțiunea de saturație. Exprimarea analitică a acestor funcții de apartenență se face pe intervale, după cum urmează:

$$m(x) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & x > b \end{cases} \quad \text{sau} \quad m(x) = \begin{cases} 1, & x < a \\ -\frac{x-a}{b-a}, & a \leq x \leq b \\ 0, & x > b \end{cases}$$

Dependența liniară de pe intervalul $[a, b]$ poate fi înlocuită cu oricare alt tip de funcție (polinomială, exponențială, etc.) asigurându-se trecerea (cu derivata continuă) de la valorile 0 și/sau 1 la valorile apropiate.

3.1.2 Operații cu mulțimi fuzzy

Operațiile uzuale din teoria clasică a mulțimilor se pot reface în cazul mulțimilor fuzzy în termenii funcției de apartenență:

- mulțimea vidă $\emptyset \subseteq X$ este caracterizată de $m_{\emptyset}(x) = 0, x \in X$
- mulțimea totală X este caracterizată de $m_X(x) = 1, x \in X$
- două mulțimi fuzzy sunt egale, dacă funcțiile lor de apartenență sunt egale, adică:
 $M = N \Leftrightarrow m_M = m_N$
- mulțimea fuzzy M este conținută în mulțimea fuzzy N , adică: $M \subseteq N \Leftrightarrow m_M \leq m_N$ (relația de ordine punctuală între funcții)
- între mulțimile M și N se definesc operațiile:
reuniune: $M \cup N$ cu $m_{M \cup N}(x) = \max(m_M(x), m_N(x))$
intersecție: $M \cap N$ cu $m_{M \cap N}(x) = \min(m_M(x), m_N(x))$
complementară: C_M , cu $m_{C_M}(x) = 1 - m_M(x)$
- *produsul algebric* al mulțimilor M și N , notat $M \cdot N$ este caracterizat de funcția de apartenență: $m_{M \cdot N} = m_M \cdot m_N$
- *suma algebrică* a mulțimilor M și N , notată $M + N$ este caracterizată de funcția de apartenență: $m_{M+N} = m_M + m_N$

3.1.3 Evenimente fuzzy, probabilitate și entropie

Se numește *eveniment fuzzy* în spațiul euclidian n -dimensional R^n , o mulțime fuzzy $E \subseteq R^n$, a cărei funcție de apartenență, m_E , este măsurabilă Borel.

Se numește *probabilitate* a unui eveniment fuzzy E , funcția definită astfel:

$$P(E) = \int_R m_E(x) dP(x)$$

Două evenimente fuzzy se numesc *independente*, dacă: $P(E \cdot F) = P(E) \cdot P(F)$

Se numește *entropie* a mulțimii fuzzy $A \subset X = \{x_1, \dots, x_n\}$ mărimea:

$$I^P(A) = - \sum m_A(x_i) \cdot p_i \cdot \ln p_i$$

unde $P = \{p_1, \dots, p_n\}$ reprezintă distribuția de probabilități.

Se numește *entropie totală* expresia:

$$I_t = - \sum p_i \cdot \ln p_i + \sum p_i S(m_A(x_i)),$$

unde $S(m_A(x_i))$ reprezintă o măsură a gradului de incertitudine.

Observație: I_t se poate interpreta drept media totală de incertitudine de a prevedea elementul lui X , care apare dintr-o experiență (proces) aleator și de a lua o decizie (notată cu 0 sau 1) asupra acestui element.

Mulțimi fuzzy temporale

Mulțimile fuzzy variabile în timp reprezintă un concept cu aplicare în formularea criteriilor pentru luarea deciziilor și reflectă caracterul *dinamic* al acestor procese. Caracterul temporal al mulțimilor fuzzy este exploatat practic în cadrul sistemelor fuzzy adaptive.

Definiția 3.1.2 Fie $\{X(t)\}_{t \in T}$ o familie de mulțimi și $\{A(t)\}_{t \in T}$ submulțimi fuzzy, $A(t) \subseteq X(t)$. Numim familia $\{A(t)\}_{t \in T}$ mulțime fuzzy dependentă de timp.

Funcția de apartenență se definește: $m_{A(t)} : X(t) \rightarrow [0, 1]$, $t \in T$ iar scopul principal al introducerii variabilei de timp este de a analiza situații în care pași ale problemei se modifică în timp.

3.2 Logica fuzzy de tip lingvistic

Logica fuzzy este o generalizare a logicii clasice bivalente, înlocuind caracterul discret al acesteia (în 0 și 1) cu unul de natură continuă. Fundamentul logicii fuzzy îl constituie așa-numitele *logici polivalente* introduse și studiate de J. Lukasiewicz, în urma unor cercetări legate de studiul modalităților.

Presupunând că $V_1, V_2, \dots, V_n$ sunt variabile logice, în logica fuzzy acestea iau valori în intervalul $[0,1]$.

Definiția 3.2.1 Orice variabilă V_i este o formulă fuzzy.

Dacă $P, Q, \dots$ sunt formule în logica fuzzy, valorile logice (de adevăr) ale compuselor $P \vee Q, P \wedge Q, \bar{P}$ se stabilesc astfel:

$$A(P \vee Q) = \max(A(P), A(Q))$$

$$A(P \wedge Q) = \min(A(P), A(Q))$$

$$A(\bar{P}) = 1 - A(P)$$

$$A(P \rightarrow Q) = \min(1 - A(P) + A(Q), 1)$$

Observație. Este evident că acest mod de a vedea lucrurile coincide cu cel din logica bivalentă, unde $A(P) \in \{0, 1\}$, oricare ar fi propoziția P .

Logica fuzzy este de tip logică continuă, deoarece variabilele logice iau valori de adevăr în intervalul $[0,1]$. Acest fapt atrage existența unor elemente particulare cu privire la *variabilele lingvistice*: relație de *implicație fuzzy* și noțiunea de *inferență fuzzy*.

Un alt tip de logică continuă a fost propusă de H. Reichenbach și se definește astfel:

$$A(P \vee Q) = A(P) + A(Q) - A(P) \cdot A(Q)$$

$$A(P \wedge Q) = A(P) \cdot A(Q)$$

$$A(\bar{P}) = 1 - A(P)$$

$$A(P \rightarrow Q) = 1 - A(P) + A(P) \cdot A(Q)$$

3.2.1 Variabile lingvistice

Variabilele fuzzy sunt mărimi fuzzy asociate celor deterministe. Echivalentul valorii scalare în sens determinist este pentru o variabilă fuzzy *gradul lingvistic (eticheta, atributul)* asociat acesteia. Astfel, așa cum pentru logica bivalentă, valorii deterministe "1" i se

asociază atributul ADEVARAT, iar lui "0" eticheta FALS, în logica fuzzy, pentru variabila deterministă *număr real pozitiv* variabila lingvistică asociată poate fi, de exemplu, *distanța* dintre două puncte, care poate avea gradele lingvistice MICĂ, MEDIE, MARE sau FOARTE MICĂ, MICĂ, MEDIE, MARE, FOARTE MARE. Domeniul de valori ale mărimii deterministe se numește *univers de discurs*.


Fiecărui atribut al unei variabile lingvistice îi este asociat o funcție de apartenență, a cărei valoare (în sens determinist) indică nivelul de încredere cu ajutorul căruia unei valori deterministe i se poate asocia acel atribut al variabilei lingvistice. De exemplu, considerând pentru variabila lingvistică *distanța* trei grade lingvistice: MICĂ, MEDIE, MARE, asociem acestora funcții de apartenență tipice, așa cum se arată în Figura 3.6. Se observă că funcția de apartenență pentru gradul lingvistic MICĂ este o dreaptă, care indică faptul că între 0 și 10 km distanțele sunt considerate mici, cu diferite niveluri de încredere situate între 0 și 1: cu cât valoarea deterministă este mai aproape de 0, cu atât gradul de apartenență al acesteia la eticheta respectivă este mai mare.

Similar, pentru gradul lingvistic MEDIE se consideră nivelul maxim de apartenență la această categorie, corespunzător valorii 10 km. Valorile mai mici sau mai mari decât aceasta duc la scăderea nivelului de încredere relativ la atributul MEDIE. Gradul lingvistic MARE se aplică distanțelor mai mari de 10 km, cu niveluri de încredere din ce în ce mai ridicate, pe măsură ce valoarea crește până la 20 de km, iar pentru orice valoare peste aceasta, distanța este considerată MARE cu nivelul de încredere maxim.

Pentru funcțiile de apartenență din Figura 3.6 se poate afirma, de exemplu, că o distanță având valoarea 5 km este MICĂ cu nivelul de încredere (valoarea funcției de apartenență) $m_{MICA}(5) = 0.50$ dar este și MEDIE cu nivelul de încredere $m_{MEDIE}(5) = 0.44$ și este și MARE cu nivelul de încredere 0. Numărul atributelor unei variabile lingvistice și funcțiile lor de apartenență depind de natura aplicației.

3.2.2 Implicații pentru logica fuzzy

În logica fuzzy implicația este o operație de compunere a formulelor (variabilelor) fuzzy, în sensul corelării a două categorii de evenimente, denumite *premise*, respectiv *consecințe*. Implicația fuzzy este similară, dar nu corespunde pe deplin compunerii funcțiilor din cazul determinist și se referă la evaluarea gradelor lingvistice ale unei submulțimi fuzzy Q , care este consecința logică sau funcțională a unei submulțimi

Figura 3.6: Variabila lingvistică *distanța* cu trei valori lingvistice

fuzzy P . Rezultatul unei implicații fuzzy este, de asemenea, o submulțime fuzzy notată $Q' \equiv P \rightarrow Q$, care are aceleași grade lingvistice ca și Q , dar funcțiile ei de apartenență, ce exprimă gradul de adevăr $A(Q') \equiv A(P \rightarrow Q)$, rezultă în urma unor calcule algebrice efectuate asupra valorilor funcțiilor de apartenență corespunzătoare gradelor lingvistice ce compun implicația fuzzy. Prin urmare, considerând formulele fuzzy:

$P : x \text{ este } MARE$

$Q : y \text{ este } MIC$

unde x , respectiv y , reprezintă variabila deterministă aparținând universului de discurs al submulțimii P , respectiv Q , se exprimă implicația fuzzy:

$Q' \equiv P \rightarrow Q \Leftrightarrow \text{DACĂ } x \text{ este } MARE, \text{ ATUNCI } y \text{ este } MIC$

Considerând $m_P(x)$, respectiv $m_Q(y)$, funcțiile de apartenență ce caracterizează mulțimile fuzzy P și Q , se pune problema determinării funcției de apartenență $m_{Q'}(x, y) = m_{P \rightarrow Q}(x, y)$.

Cele mai utilizate definiții ale implicației fuzzy sunt:

a) implicația în sens Mamdani:

$$m_{P \rightarrow Q}(x, y) = \text{MIN}[m_P(x), m_Q(y)]$$

b) implicația booleană:

$$m_{P \rightarrow Q}(x, y) = \text{MAX}[1 - m_P(x), m_Q(y)]$$

c) implicația Zadeh I:

$$m_{P \rightarrow Q}(x, y) = \text{MIN}[1, 1 - m_P(x) + m_Q(y)]$$

d) implicația Zadeh II:




Figura 3.7: Efectul operatorilor “concentrator” și “dilatator”

$$m_{P \rightarrow Q}(x, y) = \text{MIN}\{\text{MAX}[m_P(x), m_Q(y)], 1 - m_P(x)\}$$

e) implicația Larsen:

$$m_{P \rightarrow Q}(x, y) = m_P(x) \times m_Q(y)$$

3.2.3 Operatori pentru logica fuzzy

Combinarea mai multor variabile fuzzy, în conformitate cu o anumită logică, conduce la apariția unor expresii fuzzy cu mai mulți termeni, legați prin operații logice elementare (AND, OR, NOT).

Așa cum s-a aratat deja, gradele de apartenență fuzzy pot fi combinate cu ajutorul operatorilor de compunere fuzzy propuși de Zadeh:

$$m_A \text{ AND } m_B = \min(m_A, m_B)$$

$$m_A \text{ OR } m_B = \max(m_A, m_B)$$

$$\text{NOT } m_A = 1 - m_A$$

Dezvoltarea impetuoasă a aplicațiilor practice în domeniul sistemelor fuzzy a condus la găsirea altor operatori, similari celor utilizați la combinarea probabilităților:

- operatorul ”produs”: $m_A \text{ AND } m_B = m_A \cdot m_B$
- operatorul ”suma”: $m_A \text{ OR } m_B = m_A + m_B - m_A \cdot m_B$

Pentru a facilita modificările care se impun asupra funcțiilor de apartenență în diferite aplicații, au fost creați doi operatori singulari, unici în logica fuzzy, denumiți

“concentrator”, respectiv “dilatator”. Un operator de concentrare comprimă funcția de apartenență, iar un operator de dilatare realizează o expandare a acesteia. Majoritatea lucrărilor în domeniu definesc principalii operatori de acest tip sub forma:

$$\begin{aligned} CONC(m) &= m^2 \\ DIL(m) &= m^{1/2} \end{aligned}$$

Efectul acestor operatori asupra unei funcții de apartenență de referință $m(x)$ este ilustrat în Figura 3.7.

3.3 Metodologia de sinteză a automatelor fuzzy

Etapele metodei de sinteză a automatului (controlerului) fuzzy pot fi structurate astfel:

- identificarea **relațiilor funcționale** pe structura dată a unui sistem de control
- stabilirea variabilelor (parametrilor) de lucru
- completarea structurii cu elemente impuse de modelul fuzzy

Deși până acum abordarea fuzzy a proceselor de control nu este pe deplin fundamentată ca teorie de sine stătătoare, numeroase aplicații constituie fie o alternativă la problemele de automatizare clasice, fie soluții practice inedite în diverse domenii.

Majoritatea lucrărilor în domeniu adoptă următoarele faze tipice ale algoritmului de modelare fuzzy:

1. descrierea bazei euristice a problemei
2. alegerea variabilelor de intrare-ieșire
3. stabilirea mulțimilor fuzzy și a valorilor lingvistice asociate acestora
4. întocmirea bazelor de reguli pentru inferențe fuzzy
5. stabilirea procedeeleor de fuzificare, realizare a inferențelor logice și de defuzificare a ieșirilor




Figura 3.8: Arhitectura unui controler fuzzy

6. adoptarea mecanismelor de defuzificare
7. descrierea mecanismelor de adaptare și a schemelor de învățare
8. în forma finală, sistemele fuzzy pot fi implementate sub formă cablată (hardware) în structuri dedicate sau programabile de uz general

3.3.1 Baza euristică a algoritmului

În cadrul acestei faze se urmărește o descriere cât mai completă și fidelă a procesului. Este evident că volumul informației ce trebuie furnizată este direct proporțional cu complexitatea problemei. Orice încercare de formalizare a descrierii proceselor conduce implicit la neglijarea unor aspecte, departând astfel modelul de realitate. Prin urmare apare natural să se pornească cu descrierea procesului în *termeni lingvistici* ca fiind forma primară, cea mai flexibilă și cu grad mare de completitudine în modelarea evenimentelor. Prin operații de structurare a descrierii lingvistice și aplicarea logicii predicatelor de ordinul întâi, modelele lingvistice constituie baza sistemelor cu IA.

Sistemele fuzzy sunt în esență, modele numerice care exploatează cunoștințe structurate sub forma unor aserțiuni logice (cu valoare de *regulă*). Așadar, procesul admite în prima fază o descriere lingvistică “grosieră” care ulterior trece prin anumite filtre logice, sub formă de raționamente sau judecăți, rezultând un pachet de cunoștințe cu grad mai mare de structurare, ce concentrează cvasitotalitatea informațiilor despre proces. Inițial, rolul de judecător îl are expertul uman (sau grupul de specialiști) și numai

acesta hotărăște asupra aspectelor ce pot fi minimalizate sau omise în descrierea problemei.

În cadrul acestei etape, descrierea lingvistică nu poate fi exhaustivă, dar este esențială pentru trecerea la celelalte faze ale algoritmului de sinteză a sistemului fuzzy. Tabloul euristic al întregii probleme se va completa în faza întocmirii bazelor de reguli fuzzy, precum și la adoptarea mecanismelor de funcționare adaptivă.

3.3.2 Definirea variabilelor de lucru

Pe baza fluxului informațional și a schemei sistemului se urmărește alegerea ca variabile de lucru a acelor parametri fizici care sunt direct accesibili pe baza măsurătorilor cu ajutorul senzorilor sistemului. Acești parametri pot fi: coordonate de poziție, viteze de deplasare, forțe, cupluri de forțe, presiuni, temperaturi, curenți electrici, etc. constituind *variabilele de stare* ale sistemului de control. Aceste mărimi fizice vor fi tratate ca variabile fuzzy. Din mulțimea variabilelor de stare se selecționează submulțimea *variabilelor de comandă* acestea fiind considerate variabile de ieșire. Complementara acestei submulțimi rezultă drept mulțimea *variabilelor de intrare*. Se presupune că, în general, parametri de intrare pot fi accesibili sistemului pe trei căi: măsurători directe, estimarea prin calcul, furnizarea ca valori apriorice.

După cum s-a aratat, un atribut major al modelelor fuzzy este acela că nu necesită cunoașterea explicită a modului în care variabilele de ieșire depind de cele de intrare. Acest lucru este esențial pentru fenomenele complexe deoarece relațiile de interacțiune sunt, în general, nedeterminate și neliniare, și ca atare mai greu de modelat cu instrumente matematice clasice.

Un alt aspect este acela că variabilele de lucru, privite ca semnale informaționale, pot fi *continue* sau *discrete* în funcție de modul furnizării lor de către senzorii sistemului de urmărire. Vom face observația ca modul de prelucrare a informației de către algoritmul fuzzy impune tratarea secvențială a mărimilor ca în orice structură de calcul numeric, în ciuda faptului că în etapa operării cu reguli, modelele fuzzy se comportă ca procesoare paralele. Eșantionarea variabilelor de lucru se produce fie pe baza perioadei ΔT de achiziție a informației de la senzori, fie datorită modului secvențial de lucru al algoritmului fuzzy cu perioadă de răspuns (cvasiconstantă) δt care depinde de complexitatea calculului (model & context). De acest aspect se va ține seama la pregătirea

programului și a datelor de simulare. În cele ce urmează vom considera dependența funcțională în domeniul timp ca fiind discretă, de forma:

$$t_k = t_{k-1} + \delta t, k = 1, \dots, N$$

Universul de discurs al variabilelor fuzzy alese este mulțimea numerelor reale $\mathbf{R}$ dar din considerente tehnice aceasta se restricționează la intervale continue finite. În continuare problema se completează din punct de vedere euristic prin definirea mulțimilor fuzzy asociate variabilelor de lucru, cu ajutorul unor *valori lingvistice* alese convenabil.

Se menționează că nu este esențială codificarea în sine a nivelurilor respective, ci doar numărul și suportul lor intuitiv, care se bazează pe schema de modelare a procesului.

Stabilirea mulțimilor fuzzy asociate variabilelor de lucru se realizează prin adoptarea *funcțiilor de apartenență*. În general, adoptarea formei funcțiilor de apartenență precum și repartizarea nivelurilor fuzzy exprimate prin valori lingvistice, pe domeniile de definiție ale variabilelor de lucru constituie o problemă ce ține de experiența și intuiția analistului de proces. S-a arătat că funcțiile de apartenență pot fi alese dintr-o gamă largă de forme fără ca aceasta să influențeze semnificativ răspunsul sistemului fuzzy. Din acest punct de vedere se alege de obicei forme liniare, definind triunghiuri sau trapeze, care necesită calcule mai simple. Algoritmii fuzzy sunt flexibili în ceea ce privește alegerea limitelor nivelurilor fuzzy asociate valorilor lingvistice și implicit a gradului lor de *suprapunere*. Cu alte cuvinte, este important modul de distribuție (repartiție) a nivelurilor lingvistice pe universul de discurs al variabilei fuzzy. În general, această problemă se rezolvă prin încercări, în scopul obținerii celui mai avantajos răspuns al sistemului fuzzy în raport cu un criteriu impus. Problema este abordată în cadrul mecanismelor cu funcționare *adaptivă*. În acest caz avem de a face cu mulțimi fuzzy dependente de timp. Prin urmare, funcțiile de apartenență vor fi definite într-o formă generală, flexibilă, pentru a permite particularizarea lor în funcție de context. În acest sens, operatorii CONcentrator și DILatator își dovedesc utilitatea. Ma mult decât atât, cei doi operatori sunt o particularizare a principiului de obținere a noilor funcții de apartenență pornind de la o formă dată, numită *funcție de apartenență de bază*. Astfel, considerând, de exemplu, că valoarea fuzzy MICĂ este definită de funcția de apartenență $m_{MICA}(x) = f(x)$ putem aplica un nou subnivel fuzzy - FOARTE ca o

funcție oarecare H_{FOARTE} de funcția de bază $H_{FOARTE}(f(x))$. Atunci, în mod recursiv se pot defini niveluri fuzzy suplimentare:

$$\begin{aligned} m_{FOARTE_MICA}(x) &= H_{FOARTE}(m_{MICA}(x)) \\ m_{FOARTE_FOARTE_MICA}(x) &= H_{FOARTE}(H_{FOARTE}(m_{MICA}(x))) \end{aligned}$$

3.3.3 Baza de reguli pentru inferențe fuzzy

Un *sistem fuzzy* se definește în general ca fiind o relație funcțională trasată între două spații multi-dimensionale unitare:

$$S : I^n \rightarrow I^p$$

în care spațiul n -dimensional unitar I^n cuprinde toate cele n submulțimi fuzzy ale variabilelor de intrare, iar spațiul p -dimensional I^p conține toate cele p submulțimi fuzzy ale variabilelor de ieșire. Această asociere între spații de mulțimi fuzzy este consacrată sub denumirea *Fuzzy Associative Memories* (FAMs) însa în această lucrare vom folosi denumirea de *Baze de Reguli Fuzzy* (BRF).

Practic, orice sistem poate fi considerat drept o relație intrare-iesire al cărei răspuns se prezintă ca o funcție generică *iesiri* = $f(\text{intrari})$. Această funcție constituie fundamentul modelului de bază al sistemelor, care în general reprezintă o exprimare matematică a modului de lucru al acestora. Un sistem bazat pe reguli poate aproxima orice funcție continuă cu oricâte variabile, cu o precizie oricât de bună.

Consistența unei BRF poate fi dedusă pe baza datelor privind punctele de funcționare a sistemului. Aceste date sunt accesibile prin monitorizarea sistemului existent în funcțiune, al unuia similar sau pe baza unui model analitic. Sistemele fuzzy prezintă o strânsă interdependență între funcțiile de apartenență ale variabilelor din sistem și BRF.

Astfel, o BRF se construiește prin punerea în legătură (corelare) logică a mulțimilor fuzzy asociate variabilelor de ieșire cu mulțimile fuzzy ale variabilelor de intrare. În acest scop se pornește de la strategia generală de descriere a procesului, care eventual se defalcă în substrategii specifice anumitor etape de control. Un rol important îl au aici metodele euristice și tehnicile ingineriei de cunoștințe.

Strategia de control se exprimă în termeni lingvistici pe baza cărora se formează *inferențe logice* care vor constitui regulile BRF (asocieri logice). Inferența este operația

logică care permite trecerea de la premisă la concluzie pe baza raționamentelor formale. Schema generală a inferenței este următoarea:

$$\boxed{\text{PREMISA}} \xrightarrow{\text{INFERENȚĂ}} \boxed{\text{CONCLUZIE}}$$

Practic, o regulă apare când există o *premisă* cu privire la un eveniment, care implică sau atrage o anumită *consecință logică (concluzie)*. În general, orice proces fizic poate fi modelat pe baza descrierii sale prin reguli. Aceasta presupune stabilirea unui set de premise și identificarea mulțimii consecințelor (practic se realizează o identificare a unei mulțimi de relații de tip cauză-efect). Prin urmare, o regulă se exprimă prin compunerea premiselor P_i ($i = \overline{1, \dots, n}$) cu ajutorul operatorilor logici consacrați (notați generic cu simbolul $\otimes$) și echivalarea rezultatului cu consecința C , adică:

$$P_1 \otimes P_2 \otimes \dots \otimes P_n = C$$

3.4 Implementarea software a algoritmilor fuzzy

În momentul de față înțelegem prin algoritm o metodă generală de rezolvare a unui anumit tip de problemă, care se poate implementa pe calculator. În acest context un algoritm este esența absolută a unei rutine. Algoritmul care stă la baza automatului fuzzy cuprinde, pe lângă partea logică, și o parte algebrică. Este deci un algoritm de tip mixt, organizat ca o succesiune finită de pași, cuprinzând mai multe operații specifice. Acestea îndeplinesc în totalitate condițiile de bază pentru a fi implementate pe calculator, adică sunt *definite* și *efective*. Conform celebrei ecuații a lui N. Wirth:

$$\text{algoritmi} + \text{structuri de date} = \text{programe}$$

un program este format dintr-un ansamblu de proceduri, privite ca și cutii negre și un ansamblu aferent de date asupra cărora operează procedurile.

Forma pe care o capătă algoritmul într-o implementare pe calculator este subordonată *stilului de programare* și depinde în special de tipul limbajului. Acceptând standardul de programare structurată, se prezintă în Figura 3.9 schema logică a algoritmului fuzzy pentru un sistem de control. La ieșire programul afișează valori numerice din proces la momentul curent sau, opțional, reprezentări grafice.




Figura 3.9: Schema logică a unui controler fuzzy

Implementarea software a automatului fuzzy poate fi realizată și în baza unui *algoritm paralel*. Calculul paralel conferă o dimensiune nouă construcției de algoritmi și programe. Se subliniază că programarea paralelă nu este o simplă extensie a programării seriale și ca nu toți algoritmi secvențiali pot fi paralelizați.

3.4.1 Structura unui automat fuzzy

În cazul implementărilor de tip software sinteza automatelor (controlerelor) fuzzy este suficient de flexibilă, fiind practic o problemă de emulare a fazelor tipice ale algoritmului, pentru modelul problemei date. Abilitatea de a programa o problemă este în acest caz foarte importantă. O facilitată deosebită o oferă, în acest scop, pachetele de programe dedicate (tools-urile) pentru proiectarea sistemelor fuzzy. Totuși sunt necesare câteva considerații, de care trebuie să se țină seama la structurarea unui sistem de

control fuzzy, indiferent de forma sub care va fi implementat.

Configurarea unui controler fuzzy, destinat conducerii unui proces, ține seama de descompunerea convențională a dinamicii acestuia, corespunzătoare strategiilor de evoluție adoptate în etapa de modelare.

Din punct de vedere al comenzii, controlerul fuzzy va fi structurat pe canale de comandă în funcție de tipul sistemului dinamic controlat: *single-input/single-output* (SISO), *multiple-input/multiple-output* (MIMO). Problema independenței canalelor de comandă se analizează în contextul existenței cuplajului informațional. Interdependența canalelor este impusă de metodologia conducerii procesului de control ținându-se seama de ea la descrierea bazei euristice a problemei și în etapa de alcătuire a bazei de reguli. Acest lucru este important, mai ales la implementarea software, deoarece modul de procesare a informației este tributار principiului secvențial de operare și a posibilităților limitate de paralelizare a calculelor.

Posibilitățile de implementare direct hardware a sistemelor fuzzy sunt în prezent o realitate datorită apariției circuitelor logice fuzzy (CLF), a mașinilor elementare pentru efectuarea de inferențe fuzzy (MEIF) și a circuitelor pentru generarea funcțiilor caracteristice cu grad de apartenență comandat. Aceste sisteme microelectronice se regăsesc în structura procesoarelor fuzzy dedicate sau de uz general.

Componentele software asociate procesoarelor fuzzy sunt:

- editorul pentru definirea variabilelor I/O, a funcțiilor de apartenență și pentru editarea regulilor; de asemenea editorul permite utilizatorului să specifice universul de discurs, rezoluția datelor de intrare și dimensiunea datelor
- compilatorul pentru generarea codului obiect al procesorului
- depanatorul (debuggerul) ce permite execuția pas cu pas și monitorizarea programelor
- simulatorul pentru simularea sistemului fuzzy în buclă închisă și afișarea grafică a rezultatelor
- instrumente de export pentru aplicații fuzzy generate cu procesorul, către alte medii de simulare

Producția de procesoare fuzzy destinate unor controlere de uz general nu exclude însă implementarea software a algoritmilor fuzzy pe sistemele de calcul de uz comun, ca etapă de cercetare-proiectare în realizarea modelelor fizice.

3.4.2 Proiectarea sistemelor fuzzy cu MATLAB

În mediul software de tip Matlab există toolbox-uri specializate pentru analiza și proiectarea unor sisteme de control inteligent, din care face parte și Fuzzy Logic Toolbox (FLT). Acest toolbox este format dintr-un ansamblu de fișiere Matlab (pe doua subdirectoare: FUZZY și FUZZYDEMOS) cu ajutorul cărora se abordează etapele caracteristice sintezei unui sistem bazat pe inferențe fuzzy (FIS).

Subdirectorul FUZZY conține fișiere de tip function, grupate pe următoarele categorii de funcții și operații specifice:

- Funcții pentru interfața grafică cu utilizatorul (GUI); funcții pentru editarea sistemului de inferențe fuzzy (FIS), a funcțiilor de apartenență (FA) și a regulilor utilizate, a diagramelor de inferențe și a suprafețelor de control asociate; funcții pentru comanda de generare FIS (prin fuzificare - definirea unei FA pentru fiecare variabilă implicată în reguli de tip fuzzy, prin defuzificare - pe baza estimării inferențelor fuzzy, precum și prin transferul de parametri între funcții și variabile, respectiv prin evaluarea generică a FA și vizualizarea suprafeței de control); funcții pentru implementarea altor rutine (FIS de tip Sugeno, clustere de tip C-means etc.)
- Operații referitoare la diferența a două FA cu diferite forme (sigmoidală, Gauss, pi, trapezoidală, triunghiulară, Z, S, inclusiv combinații ale lor), la concatenarea matricelor, la discretizarea FIS-ului, la evaluarea de FA multiple, la editarea liniilor de text, inclusiv help-uri active

Subdirectorul FUZZYDEMOS (FUZZY LOGIC TOOLBOX DEMOS) conține diferite aplicații demonstrative pentru funcții și operații fuzzy de bază, precum și modele fuzzy complete ale unor sisteme de control inteligent.




Figura 3.10: Funcția GAUSSMF

Exemple de funcții și operații

Funcții de comandă pentru interfața grafică cu utilizatorul

FUZZY pentru ediatrea FIS-ului

MFEDIT pentru editarea funcțiilor de apartenență

RULEEDIT pentru editarea regulilor

SURFVIEW vizualizarea suprafețelor de control

RULEVIEW vizualizarea regulilor (RULEVIEW(FIS)) și a diagramelor de inferență fuzzy pentru o matrice FIS - RULEVIEW('FILENAME')

Funcții de apartenență (FA)

GAUSSMF(x , PARAMS) - FA de tip Gauss cu flancuri simetrice, unde PARAMS= [c d] este un vector ce determină forma și poziția FA prin parametrul de dispersie - s și de medie - c :

$$GAUSSMF(x, [s \ c]) = \exp\left[-\frac{(x-c)^2}{2s^2}\right]$$

Exemplu:

```
x = (0:0.1:10)';
y1=gaussmf(x, [0.5 5]);
y2=gaussmf(x, [1 5]);
y3=gaussmf(x, [2 5]);
y4=gaussmf(x, [3 5]);
subplot(321); plot(x, [y1 y2 y3 y4], 'k');
```

TRIMF(x , PARAMS) - FA de tip triunghi, unde PARAMS = [A B C] este un vector cu trei elemente, care precizează punctele de discontinuitate:




Figura 3.11: Funcția TRIMF

$$TRIMF(x, [A \ B \ C]) = \begin{cases} 0, & x \leq A \\ \frac{x-A}{B-A}, & A < x \leq B \\ \frac{C-x}{C-B}, & B < x \leq C \\ 0, & C < x \end{cases}$$

De remarcat că această FA are întotdeauna o înălțime unitară. Pentru a genera o FA triunghiulară cu dimensiune subunitară se va utiliza comanda TRIMF.

Exemplu:

```
x=(0:0.1:10);
y1=trimf(x,[3 4 5]);
y2=trimf(x,[2 4 7]);
y3=trimf(x,[1 4 9]);
subplot(321), plot(x, [y1 y2 y3], 'k');
```

TRAPMF(x, PARAMS) - FA de tip trapez, unde PARAMS = [A B C D] este un vector de patru elemente, care precizează punctele de discontinuitate ale funcției:

$$TRAPMF(x, [A \ B \ C \ D]) = \begin{cases} 0, & x \leq A \\ \frac{x-A}{B-A}, & A < x \leq B \\ 1, & B < x \leq C \\ \frac{D-x}{D-C}, & C < x \leq D \\ 0, & D < x \end{cases}$$

Dacă avem $A < B < C < D$ funcția de apartenență este trapezoidală. Dacă $A < D$ și $B \geq C$, această FA va avea o formă triunghiulară cu baza AD și vârful definit de coordonatele:

$$\left(\frac{BD-AC}{D-C+B-A}, 1 - \frac{B-C}{D-C+B-A} \right)$$

Exemplu:

```
x=(0:0.1:10);
```




Figura 3.12: Funcția TRAPMF

```

y1=trapmf(x, [2 3 7 9]);
y2=trapmf(x, [3 4 6 8]);
y3=trapmf(x, [4 5 5 7]);
y4=trapmf(x, [5 6 4 6]);
subplot(321),plot(x, [y1 y2 y3 y4], 'k');

```

Funcții de comanda pentru FIS

NEWFIS - creează o nouă matrice FIS (Fuzzy Inference System)

Moduri de apelare:

- **FIS=NEWFIS(*FisName*)** - creează un FIS de tip Mamdani cu numele *FisName*
- **FIS=NEWFIS(*FisName*, *FisType*, *andMethod*, *orMethod*, *impMethod*, *aggMethod*, *defuzzMethod*)**. Implicit parametrii sunt setați astfel: *FisType* la tipul 'Mamdani', *andMethod* - 'min', *orMethod* - 'max', *impMethod* - 'min', *aggMethod* - 'max', *defuzzMethod* - 'centroid'.

ADDVAR - adaugă o variabilă lingvistică la FIS. Variabilelor li se aplică indici în ordinea în care sunt adăugate. Variabilele de intrare și de ieșire sunt numărate independent.

Modul de apelare:

FIS2=ADDVAR(*FIS1*, *varType*, *varName*, *varRange*)

Efectul apelării: adaugă variabila specificată prin *varName* la variabilele lingvistice din *FIS1* unde:

- *varType* specifică tipul variabilei: 'input' sau 'output'
- *varRange* precizează domeniul variabilei

Exemplu:

```
a=newfis('control');
```




Figura 3.13: Variabila lingvistică “eroare”

```
a=addvar(a, 'input', 'eroare', [-1 1]);
getfis(a, 'input', 1);
```

Rulând secvența de program de mai sus se obține:

```
Name=eroare
NumMFs=0
MFLabels=
Range=[-1 1]
```

ADDMF adaugă o funcție de apartenență la FIS.

Modul de apelare:

```
FIS2=ADDMF(FIS1, varType, varIndex, mfName, mfType, mfParams)
```

Efectul apelării: adaugă o FA la FIS1 specificând:

- *mfName*: numele funcției de apartenență
- *varType*: tipul variabilei ('input' sau 'output')
- *varIndex*: indicele variabilei
- *mfType*: forma FA
- *mfParams*: parametrii funcției de apartenență

Exemplu:

```
a=newfis('control');
a=addvar(a, 'input', 'eroare', [-1 1]);
a=addmf(a, 'input', 1, 'negativa', 'trimf', [-1 -0.5 0]);
a=addmf(a, 'input', 1, 'zero', 'trimf', [-0.5 0 0.5]);
a=addmf(a, 'input', 1, 'pozitiva', 'trimf', [0 0.5 1]);
subplot(211),plotmf(a, 'input', 1);
```

Rezultatul rulării acestui fisier Matlab este prezentat în Figura 3.13:

ADDRULE - adaugă reguli la FIS.

Modul de apelare:

`FIS2=ADDRULE(FIS1,ruleList)`

Efectul apelării: adaugă regulile date de variabila *ruleList* la FIS1, unde *ruleList* este o listă cu mai multe rânduri, fiecare dintre acestea reprezentând o regulă dată.

Dacă sistemul are M intrări și N ieșiri, trebuie definite în lista de reguli M+N+2 coloane. Primele M coloane se refera la intrările sistemului, iar următoarele N coloane se refera la ieșirile sistemului. Fiecare coloană conține un număr care se referă la indexul FA al variabilelor de intrare și ieșire. Coloana M+N+1 conține ponderea care este aplicată la regula respectivă și este un număr între 0 și 1. Coloana M+N+2 conține 1 dacă operatorul fuzzy pentru compunerea regulilor este AND și 2 dacă acesta este OR.

Exemplu:

```
a=newfis('control');
a=addvar(a, 'input', 'eroare', [-1 1]);
a=addmf(a, 'input', 1, 'negativa', 'trimf', [-1 -0.5 0]);
a=addmf(a, 'input', 1, 'zero', 'trimf', [-0.5 0 0.5]);
a=addmf(a, 'input', 1, 'pozitiva', 'trimf', [0 0.5 1]);
a=addvar(a, 'input', 'var_eroare', [-1 1]);
a=addmf(a, 'input', 2, 'negativa', 'trimf', [-1 -0.5 0]);
a=addmf(a, 'input', 2, 'zero', 'trimf', [-0.5 0 0.5]);
a=addmf(a, 'input', 2, 'pozitiva', 'trimf', [0 0.5 1]);
a=addvar(a, 'output', 'comanda', [0 2]);
a=addmf(a, 'output', 1, 'mica', 'trimf', [0 0.5 1]);
a=addmf(a, 'output', 1, 'medie', 'trimf', [0.5 1 1.5]);
a=addmf(a, 'output', 1, 'mare', 'trimf', [1 1.5 2]);
ruleList=[1 1 3 1 2;2 1 3 1 2;3 1 2 1 2;1 2 3 1 2;2 2 2 1 2;
3 2 1 1 2;1 3 2 1 2;3 3 1 1 2];
a=addrule(a, ruleList);
writefis(a,'control');
showrule(a);
```

Se obține setul de reguli (ponderate unitar):

1. If (eroare is negativa) or (var_eroare is negativa) then (comanda is mare) (1)
2. If (eroare is zero) or (var_eroare is negativa) then (comanda is mare) (1)
3. If (eroare is pozitiva) or (var_eroare is negativa) then (comanda is medie) (1)
4. If (eroare is negativa) or (var_eroare is zero) then (comanda is mare) (1)

5. If (eroare is zero) or (var_eroare is zero) then (comanda is medie) (1)
6. If (eroare is pozitiva) or (var_eroare is zero) then (comanda is mica) (1)
7. If (eroare is negativa) or (var_eroare is pozitiva) then (comanda is medie) (1)
8. If (eroare is pozitiva) or (var_eroare is pozitiva) then (comanda is mica) (1)

DEFUZZ - realizează defuzificarea pentru un FIS.

Modul de apelare:

valDefuzz=DEFUZZ(*x*, *mf*, *type*)

Efectul apelării: returnează în variabila *valDefuzz* valoarea defuzificată a unei FA de tip *mf*, utilizând strategia de defuzificare precizată de *type*. Valoarea obținută este abscisa:

- centrului de greutate al ariei pentru *type*='centroid' (tipul implicit)
- bisectoarea ariei pentru *type*='bisector'
- media maximelor pentru *type*='mom'
- celui mai mic dintre maxime, pentru *type*='som'
- celui mai mare dintre maxime, pentru *type*='lom'

Exemplu:

```
x=-10:0.1:10
mf=trapmf(x, [-10 -8 -2 7]);
plot(x, mf, 'b');
axis([min(x) max(x) 0 1.2]);
hold on;
type='centroid';
xx=defuzz(x, mf, type);
plot(xx, 0.0, 'b*');
text(xx, 0.1, type, 'hor', 'center', 'ver', 'top', 'color', 'b');
type='bisector';
xx=defuzz(x, mf, type);
plot(xx, 0.0, 'r*');
text(xx, 0.2, type, 'hor', 'center', 'ver', 'top', 'color', 'r');
type='mom';
xx=defuzz(x, mf, type);
plot(xx, 0.0, 'm*');
text(xx, 0.1, type, 'hor', 'center', 'ver', 'top', 'color', 'm');
type='som';
```




Figura 3.14: Efectul funcției DEFUZZ

```
xx=defuzz(x, mf, type);
plot(xx, 0.0, 'c*');
text(xx, 0.15, type, 'hor', 'center', 'ver', 'top', 'color', 'c');
type='lom';
xx=defuzz(x, mf, type);
plot(xx, 0.0, 'g*');
text(xx, 0.1, type, 'hor', 'center', 'ver', 'top', 'color', 'g');
hold off;
```

În Figura 3.14 se prezintă rezultatele obținute la defuzificarea unei FA de tip TRAPMF cu metodele: *centroid*, *bisector*, *lom*, *som* și *mom*.

3.4.3 Aplicație. Sistem fuzzy pentru analiză spațială

Una din cele mai importante caracteristici ale sistemelor de informare geografică (SIG) este interpretarea și rezolvarea problemelor spațiale. În general, cercetătorii folosesc pachete de statistici de interfață SIG pentru analiza spațială. Alte căi ale analizei datelor spațiale s-au bazat pe logică, automate celulare, rețelele neuronale și tehnicile inteligenței artificiale (precum sistemele bazate pe informații/ cunoștințe).

Deși câteva din tehnicile IA au fost folosite pentru analiza datelor spațiale, este foarte dificil ca un non-expert în tehnicile IA să dezvolte și să folosească un sistem hibrid între tehnicile SIG și IA. Motivul este acela că majoritatea tehnicilor IA necesită abilități de programare ale computerului pentru a folosi cunoștințele în sistem. Totuși, un sistem bazat pe reguli este cea

mai folosită tehnică în IA pentru un sistem hibrid cu SIG deoarece are o structură optimă pentru derivarea unui răspuns.

Programele timpurii, precum DENDRAL și MYCIN, au demonstrat posibilitatea simulării modalității în care experții, precum chimiștii sau fizicienii, își rezolvă problemele. După aceste succese, multe sisteme expert au fost dezvoltate pentru aplicații tehnice din diverse domenii.

Sistemul de control fuzzy pe care l-am implementat utilizând mediul de programare MATLAB poate fi folosit pentru recunoașterea obiectelor dintr-o fotografie spațială. În funcție de caracteristicile pe care utilizatorul le introduce pentru un anumit detaliu din fotografie sistemul stabilește dacă acesta este:

- lac
- râu
- teren arabil
- parc
- cartier rezidențial
- stradă
- corp industrial

Există patru elemente de bază pentru interpretarea fotografiilor aeriene:

- *textura* este frecvența schimbărilor de ton în cadrul fotografiilor
- *valoarea spectrală* reprezintă densitatea strălucirii. Este o înregistrare de reflectare a luminii de la suprafața pământului pe fotografie
- *aria* se stabilește în raport cu a celorlaltor obiecte din fotografie.
- *conturul* reflectă cât de regulat sau neregulat este detaliul în cauză

Folosind aceste patru elemente au fost construite regulile din cadrul sistemului. Mai întâi *conturul* și *valoarea spectrală* sunt folosite pentru a separa utilitățile urbane de alte elemente precum lacuri sau terenuri. *Textura* este folosită pentru a separa râurile de terenuri, corpurile industriale de cele de locuințe iar *aria* ne permite să stabilim mărimea obiectului vizat în raport cu celelalte.

Baza de reguli a sistemului

Așa cum am spus, pe baza celor patru caracteristici ale detaliilor ce pot apărea într-o fotografie spațială au fost construite regulile controlerului fuzzy. Acestea sunt:

1. If (**contour** is regular) and (**texture** is very_unsmooth) and (**spectral** is medium) and (**area** is medium) then (**Structure** is Residential)
2. If (**contour** is regular) and (**texture** is v_unsmooth) and (**spectral** is medium) and (**area** is large) then (**Structure** is Residential)
3. If (**contour** is regular) and (**texture** is unsmooth) and (**spectral** is deep) and (**area** is medium) then (**Structure** is Park)
4. If (**contour** is regular) and (**texture** is unsmooth) and (**spectral** is deep) and (**area** is small) then (**Structure** is Park)
5. If (**contour** is regular) and (**texture** is smooth) and (**spectral** is light) and (**area** is medium) then (**Structure** is Industrial)
6. If (**contour** is regular) and (**texture** is smooth) and (**spectral** is light) and (**area** is large) then (**Structure** is Industrial)
7. If (**contour** is very_regular) and (**texture** is smooth) and (**spectral** is deep) and (**area** is large) then (**Structure** is Arable Field)
8. If (**contour** is very_regular) and (**texture** is smooth) and (**spectral** is deep) and (**area** is very_large) then (**Structure** is Arable Field)
9. If (**contour** is regular) and (**texture** is very_smooth) and (**spectral** is medium) and (**area** is large) then (**Structure** is Car Road)
10. If (**contour** is irregular) and (**texture** is very_smooth) and (**spectral** is deep) and (**area** is medium) then (**Structure** is River)
11. If (**contour** is very_irregular) and (**texture** is very_smooth) and (**spectral** is deep) and (**area** is small) then (**Structure** is Lake)

După cum se observa *valoarea spectrală* separă unitățile urbane de cele naturale (parcuri, terenuri, râuri). Dacă avem structuri artificiale, ca de exemplu cartiere rezidențiale sau zone industriale atunci acestea sunt diferențiate în primul rând după *textură*. Structurile liniare care pot fi râuri sau strazi sunt diferențiate după *contur*.

Un exemplu de figură spațială care este folosită în această versiune a sistemului fuzzy pentru analiza spațială și pe baza căreia se pot face raționamentele implementate în regulile de mai sus este cea din Figura ??.

Sunt câteva limitari în aplicarea acestui sistem bazat pe reguli. Mai întâi, dacă un diagnostic tipic sau o sarcină complexă trebuie executată, sunt necesare câteva sute de reguli. Dacă regulile necesita mai multe cunoștințe în domenii variate, s-ar putea ca regulile să fie dificil de construit datorită diverselor aspecte din cadrul domeniilor.

În al doilea rând, un sistem expert bazat pe reguli nu poate folosi experiențele ce au fost

folosite în rezolvarea problemelor similare. Desi o problema este aceeași sau similară cu cea veche, utilizatorii trebuie să răspundă din nou la toate întrebările în acest sistem bazat pe reguli. Nu există nici o modalitate de a salva un caz similar în sistemul bazat pe reguli. Menținerea cunoștințelor într-un sistem bazat pe reguli este în mod normal un proces manual ce necesită achiziționarea unor cunoștințe suplimentare.

În al treilea rând, nu există excepții în ceea ce privește regulile. Regulile trebuie să explice cunoștințele, întrebările exacte, și răspunsurile exacte. Nu este permis ca utilizatorii să facă greșeli în răspunsuri. Pentru a depăși aceste limitări, există și alte cai de acces în inteligența artificială: raționamentul bazat pe model (RBM) (Davis și Hamscher, 1986) sau raționamentul bazat pe caz (RBC) (Slade, 1991).

Totuși, sistemele bazate pe reguli sunt mult mai indicate pentru rezolvarea problemelor atunci când este dificil să aduni date despre caz (Althoff și alții 1994). Într-un sistem expert, cunoștințele pot fi mai ușor implementate în sistemele bazate pe reguli decât în sistemele RBC deoarece regulile pot fi construite printr-o structură de raționament foarte simplă (structura dacă-atunci) și într-un limbaj natural.

3.4.4 Sistem fuzzy pentru analiza spațială - Interfață

Ca și întreg controlerul fuzzy și interfața acestuia este proiectată folosind mediul de programare Matlab. Au fost implementate cinci ferestre de dialog după cum urmează:

Prima fereastră de dialog sau fereastră care este afișată atunci când lansăm în execuție programul are rolul:

- de a afișa fotografia pe baza căreia se vor face raționamente
- de a porni setul de întrebări pe baza cărora se vor obține valorile (crisp) pentru variabilele lingvistice utilizate în premisele regulilor
- după ce setul de întrebări a fost epuizat și s-au obținut valorile necesare raționamentului fuzzy prin intermediul acestei ferestre putem afla rezultatul (concluzia)

Odată ce am apăsăm pe butonul "Start Reasoning" va fi afișat dialogul ce ne permite selectarea valorii pentru variabila lingvistică *arie*.

Această fereastră afișează funcțiile de apartenență corespunzătoare valorilor acestei variabile: *small*, *medium*, *large*, *very large* și un control de tip *listbox* ce permite selectarea valorii numerice corespunzătoare ariei detaliului pentru care dorim să se efectueze raționamentul. Prin acest control de tip *listbox* utilizatorul va alege o valoare numerică cât mai apropiată de valoarea ariei obiectului vizat.

Astfel, obiectele sunt considerate "mici" daca au aria pana in 10000m^2 , obiectele "medii" se presupune ca au aria cuprinsa intre 8000m^2 si 40000m^2 , etc.

De asemenea se afiseaza fotografia initiala insa filtrata astfel incat utilizatorul sa poata compara mai usor dimensiunea obiectului vizat cu a celorlaltora. Filtrarea consta in afisarea tuturor detaliilor in nunate ale aceleiasi culori si estomparea neregularitatilor acestora.

Urmatoarea fereastră afisată corespunde variabilei "contour". Funcțiile de apartenență ale acestei variabile corespund valorilor: *very irregular, irregular, regular, very regular*.

Spre deosebire de dialogul anterior, în această fotografie inițială este afisată astfel încât neregularitățile în conturul detaliilor sunt puse în evidență:

Cea de-a treia fereastră afisată corespunde variabilei "texture". Funcțiile de apartenență ale acestei variabile corespund valorilor: *very unsmooth, unsmooth, smooth, very smooth*.

În fereastră corespunzătoare variabilei "texture" fotografia este modificată astfel încât toate neregularitățile sunt evidențiate: și anume nu numai conturul în plan ci și conturul spațial (tri-dimensional):

Ultima fereastră corespunde variabilei "spectral value" conținând funcțiile de apartenență ale celor trei valori ale acesteia: *deep, medium* și *light*.

Fotografia de această dată este modificată astfel încât petele de culoare sunt intensificate sau întunecate mai tare după caz.

Pentru exemplificare vom considera următorul detaliu în fiecare din cele 5 figuri afisate în cadrul programului (prima fiind cea inițială și celelalte patru corespunzând fiecărei caracteristici în parte):

Astfel dacă vom alege pentru variabila *area* valoarea numerică crisp 40000, pentru variabila *contour* valoarea numerică 0.9, pentru variabila *texture* valoarea 1 iar pentru *spectral value* valoarea crisp 0.7 atunci se va aplica următoarea regulă:

IF AREA is large, CONTOUR is very regular, TEXTURE is very smooth, SPECTRAL VALUE is medium THEN CAR ROAD

deci se va confirma că detaliul în cauză este o stradă.

3.4.5 Sistem fuzzy pentru analiza spațială - Implementarea

Fisierul de reguli *spatial.m*:

```
a=newfis('spatial');
a.input(1).name='contour'
a.input(1).range=[0 1];
a.input(1).mf(1).name='v_irreg';
```

```
a.input(1).mf(1).type='trapmf';
a.input(1).mf(1).params=[0 0 0.2 0.4];
a.input(1).mf(2).name='irreg';
a.input(1).mf(2).type='trapmf';
a.input(1).mf(2).params=[0.2 0.4 0.4 0.6];
a.input(1).mf(3).name='reg';
a.input(1).mf(3).type='trapmf';
a.input(1).mf(3).params=[0.4 0.6 0.6 0.8];
a.input(1).mf(4).name='v_reg';
a.input(1).mf(4).type='trapmf';
a.input(1).mf(4).params=[0.6 0.8 1 1];
a.input(2).name='texture'
a.input(2).range=[0 1];
a.input(2).mf(1).name='v_unsmooth';
a.input(2).mf(1).type='trapmf';
a.input(2).mf(1).params=[0 0 0.2 0.4];
a.input(2).mf(2).name='unsmooth';
a.input(2).mf(2).type='trapmf';
a.input(2).mf(2).params=[0.2 0.4 0.4 0.6];
a.input(2).mf(3).name='smooth';
a.input(2).mf(3).type='trapmf';
a.input(2).mf(3).params=[0.4 0.6 0.6 0.8];
a.input(2).mf(4).name='v_smooth';
a.input(2).mf(4).type='trapmf';
a.input(2).mf(4).params=[0.6 0.8 1 1];
a.input(3).name='spectral';
a.input(3).range=[0 1];
a.input(3).mf(1).name='light';
a.input(3).mf(1).type='trapmf';
a.input(3).mf(1).params=[0 0 0.25 0.5];
a.input(3).mf(2).name='medium';
a.input(3).mf(2).type='trapmf';
a.input(3).mf(2).params=[0.25 0.5 0.5 0.75];
a.input(3).mf(3).name='deep';
a.input(3).mf(3).type='trapmf';
```

```
a.input(3).mf(3).params=[0.5 0.75 1 1];
a.input(4).name='area'
a.input(4).range=[1000 110000];
a.input(4).mf(1).name='small';
a.input(4).mf(1).type='trapmf';
a.input(4).mf(1).params=[1000 1000 5000 10000];
a.input(4).mf(2).name='medium';
a.input(4).mf(2).type='trapmf';
a.input(4).mf(2).params=[8000 20000 30000 40000];
a.input(4).mf(3).name='large';
a.input(4).mf(3).type='trapmf';
a.input(4).mf(3).params=[30000 50000 80000 100000];
a.input(4).mf(4).name='v_large';
a.input(4).mf(4).type='trapmf';
a.input(4).mf(4).params=[80000 100000 110000 110000];
a.output(1).name='Structure';
a.output(1).range=[0 7];
a.output(1).mf(1).name='Lake';
a.output(1).mf(1).type='trapmf';
a.output(1).mf(1).params=[0 0.5 0.5 1];
a.output(1).mf(2).name='River';
a.output(1).mf(2).type='trapmf';
a.output(1).mf(2).params=[1 1.5 1.5 2];
a.output(1).mf(3).name='Arable Field';
a.output(1).mf(3).type='trapmf';
a.output(1).mf(3).params=[2 2.5 2.5 3];
a.output(1).mf(4).name='Park';
a.output(1).mf(4).type='trapmf';
a.output(1).mf(4).params=[3 3.5 3.5 4];
a.output(1).mf(5).name='Residential';
a.output(1).mf(5).type='trapmf';
a.output(1).mf(5).params=[4 4.5 4.5 5];
a.output(1).mf(6).name='Car Road';
a.output(1).mf(6).type='trapmf';
a.output(1).mf(6).params=[5 5.5 5.5 6];
```

```
a.output(1).mf(7).name='Industrial';
a.output(1).mf(7).type='trapmf';
a.output(1).mf(7).params=[6 6.5 6.5 7];
a.rule(1).antecedent=[3 1 2 2];
a.rule(1).consequent=[5];
a.rule(1).weight=1;
a.rule(1).connection=1;
a.rule(2).antecedent=[3 1 2 3];
a.rule(2).consequent=[5];
a.rule(2).weight=1;
a.rule(2).connection=1;
a.rule(3).antecedent=[3 2 3 2];
a.rule(3).consequent=[4];
a.rule(3).weight=1;
a.rule(3).connection=1;
a.rule(4).antecedent=[3 2 3 1];
a.rule(4).consequent=[4];
a.rule(4).weight=1;
a.rule(4).connection=1;
a.rule(5).antecedent=[3 3 1 2];
a.rule(5).consequent=[7];
a.rule(5).weight=1;
a.rule(5).connection=1;
a.rule(6).antecedent=[3 3 1 3];
a.rule(6).consequent=[7];
a.rule(6).weight=1;
a.rule(6).connection=1;
a.rule(7).antecedent=[4 3 3 3];
a.rule(7).consequent=[3];
a.rule(7).weight=1;
a.rule(7).connection=1;
a.rule(8).antecedent=[4 3 3 4];
a.rule(8).consequent=[3];
a.rule(8).weight=1;
a.rule(8).connection=1;
```

```
a.rule(9).antecedent=[3 4 2 3];  
a.rule(9).consequent=[6];  
a.rule(9).weight=1;  
a.rule(9).connection=1;  
a.rule(10).antecedent=[2 4 3 2];  
a.rule(10).consequent=[2];  
a.rule(10).weight=1;  
a.rule(10).connection=1;  
a.rule(11).antecedent=[1 4 3 1];  
a.rule(11).consequent=[1];  
a.rule(11).weight=1;  
a.rule(11).connection=1;  
writefis(a,'spatial');
```

Bibliografie

- [1] **Ion Iancu** *Rules-Based Reasoning Under Uncertainty and Imprecision*, Subseries of Research Notes in Computer Science, vol. 304, Editura Universitaria Craiova, 2010
- [2] **Emil Sofron, Nicu Bizon, Silviu Ionita, Radian Raducu** *Sisteme de control fuzzy*, Editura ALL, 1998
- [3] **Ion Vaduva, Grigore Albeanu** *Introducere in Modelarea Fuzzy*, Editura Universitatii din Bucuresti, 2004