

# REPREZENTAREA CUNOȘTINȚELOR “NECLARE” ȘI FOLOSIREA LOR

Drd. mat. Moise Maria

Institutul de Cercetări în Informatică

**Rezumat:** În prezent, asistăm la dezvoltarea cu succes a folosirii tehnicii de calcul în domeniul inteligenței artificiale, care constă în crearea de sisteme inteligente, bazate pe cunoștințe care încarcă să simuleze raționamentul uman.

Prințele sisteme bazate pe cunoștințe se regăsesc și sistemele expert, destinate pentru rezolvarea unor probleme dintr-un domeniu concret. Realizarea unor sisteme puternice și eficiente, bazate pe cunoștințe necesită o reprezentare corespunzătoare a acestora, orientată spre prelucrarea computerizată.

Pentru reprezentarea cunoștințelor se pot folosi următoarele modele: *sistemul de producții*, *bazat pe reguli de producție*; *modelul bazat pe teoria frame-urilor*; *modelul bazat pe rețele semantice*; *modelul logic*, bazat pe logica predicatelor de ordinul întâi.

Cunoașterea trăsăturilor și limitelor acestor modele de reprezentare și a mecanismului deductiv corespunzător de către proiectantul de sisteme, bazate pe cunoștințe, este absolut necesară, întrucât de selectarea rațională a acestor metode depinde obținerea soluțiilor optime scontante, și, în general, rentabilitatea acestor sisteme.

În viața de toate zilele, alături de cunoștințele care pot fi descrise cu precizie cu ajutorul modelelor de reprezentare amintite mai sus, se întâlnesc și cunoștințe “neclare”. În această lucrare se va aborda problema referitoare la reprezentarea cunoștințelor neclare, înștiindu-se asupra folosirii teoriei fuzzy în reprezentarea cunoștințelor imprecise a căror graniță nu este delimitată.

**Cuvinte cheie:** sistem de producții, frame, rețea semantică, logica propozițiilor, logica predicatelor de ordinul întâi, teoria fuzzy, nedeterminarea deducției etc.

## 1. Ce sunt cunoștințele?

După unii autori, ca H. Ueno și M. Ishizuka [13], cunoștințele se definesc ca “*rezultat obținut în urma cunoașterii*”, sau, mai detaliat, “*un sistem de judecăți cu organizare principală și unică, bazat pe o legitate obiectivă*”.

Din punct de vedere al inteligenței artificiale (Artificial Intelligence - AI) și al ingineriei cunoștințelor, definirea acestora este necesar să fie corelată cu deducția logică, ceea ce conduce la o altă definiție și anume: “*cunoștințele sunt informații formalizate la care se fac referiri, sau care sunt folosite în procesul concluziei logice*”.

Până nu de multă vreme, cunoștințele folosite pentru rezolvarea anumitor probleme dintr-un domeniu concret, se regăseau în programe aplicative, realizate cu ajutorul metodelor de programare procedurală, în limbaje de tip FORTRAN, COBOL, PASCAL etc. Aceste cunoștințe se înșueau, fie din cataloage speciale, referitoare la un domeniu concret, fie de la specialiști (experti). Este evident faptul că, cu cât gradul de complexitate al problemei de rezolvat este mai mare, cu

atât mai complicate devin programele aplicative, ceea ce contribuie la o elaborare greoaie a acestora.

Din punct de vedere al rezolvării problemelor dintr-un domeniu concret, cunoștințele se împart în cunoștințe “fapte” și cunoștințe “euristice”.

Prima grupă indică, de obicei, întâmplări, fenomene, observații etc. dintr-un domeniu concret.

Grupa a doua de cunoștințe se bazează pe experiența proprie a specialistului dintr-un anumit domeniu și reprezintă o acumulare de cunoștințe, ca urmare a unei practici de mai mulți ani. Aceste cunoștințe se regăsesc în sistemele expert sub forma următoare: *procedee de concentrare sau sinteză*, *procedee de detaliere sau analiză*, *procedee de îndepărțare a ideilor inutile*, *procedee de folosire a informației incerte etc.*

Dintr-un alt punct de vedere, cunoștințele se împart în: “*fapte*” (cunoștințe fapte) și “*reguli*” (cunoștințe pentru adoptarea de decizii). Prin “*fapte*” se subînțeleg cunoștințe de tipul “X este A”, caracteristice pentru modelele de reprezentare de tip rețea. Prin “*reguli*” se subînțeleg cunoștințele de tipul “IF-THEN”.

În afară de acestea, mai există meta-cunoștințe, ceea ce înseamnă cunoștințe despre cunoștințe.

Dacă ne referim la descrierea cu exactitate în reprezentare, cunoștințele se împart în: cunoștințe “clare” și cunoștințe “incerte”. Prima categorie poate fi descrisă cu ajutorul modelelor clasice de reprezentare (sistemul producțiilor, modelul bazat pe teoria frame-urilor, modelul bazat pe rețele semantice și modelul logic, bazat pe logica predicatelor de ordinul întâi). Reprezentarea celei de-a doua categorii de cunoștințe este mai dificilă și are la bază teoria probabilităților, logica nemonotonă sau teoria mulțimilor fuzzy.

Din categoria cunoștințelor “incerte” fac parte și cunoștințele “impure”, generate, fie de probleme incorrect puse, fie de probleme incomplete sau de probleme complexe.

Reprezentarea cunoștințelor este o metodologie de modelare și formalizare a acestora, în vederea prelucrării computerizate, iar folosirea cunoștințelor reprezintă tehnologia de deducție, adică de obținere a unei soluții în conformitate cu o anumită reprezentare de cunoștințe.

În modelul bazat pe folosirea regulilor, cunoștințele sunt reprezentate printr-un ansamblu de reguli de tipul “IF-THEN” (CONDITIE-ACTIUNE), iar sistemele cu baze de cunoștințe, bazate pe aceste reguli se numesc sisteme de producții.

Modelul bazat pe teoria frame-urilor constă în reprezentarea arborescentă a cunoștințelor în unități de informație care regroupează mai multe rubrici (în engleză “slot”-uri [3]). Prin urmare, prin frame-uri pot fi reprezentate de structuri conceptuale de tip ierarhic “abstract-concret” sau “înțreg-part”.

În modelul rețelei semantice, cunoștințele sunt reprezentate sub formă unei rețele formată din noduri (în care se amplasează diferite concepte) și din arce care

corespond relațiilor și legăturilor dintre concepte.

Modelul logic se folosește pentru reprezentarea cunoștințelor în sistemul logicii predicatorilor de ordinul întâi și efectuarea deducțiilor cu ajutorul silogismului. Acest model se bazează pe formalismul matematic, care folosește formule - logice (numite atomi) și cuantificatorii existențiali și de universalitate.

Pentru ca sistemele inteligente să iasă din cadrul unor simple deducții simbolice și să se apropie că mai mult de gădirea omenească, sunt necesare metode de reprezentare a cunoștințelor incerte și un mecanism deductiv, capabil să funcționeze în mediul acestora.

## 2. Prelucrarea neclarității

Sensul termenului de "neclaritate" nu a fost încă suficient precizat. Omul dispune de cele mai diverse forme de cunoștințe, dar, deocamdată, nu este foarte lăptidă modul în care acestea sunt structurate în creierul său. Însă, pentru folosirea cunoștințelor de către calculator este necesar ca acestea să fie formatare și descrise. De fapt, în aceasta constă reprezentarea lor.

Cât timp cunoștințele nu sunt formatare și nici descrise, nu pot fi folosite nici neclaritățile, care nu sunt descrise preliminar într-o formă oarecare, dar care sunt generate în decursul procesului de prelucrare a cunoștințelor.

In ingineria cunoștințelor, neclaritățile se pot clasifica după cum urmează [13]:

- a) caracterul nedeterminat al deducțiilor;
- b) polisemantică;
- c) incertitudinea;
- d) incompletitudinea;
- e) imprecizia și ignoranța.

a) *Dirijarea nedeterminată a deducțiilor* este caracteristică pentru sistemele inteligenței artificiale, în care cunoștințele se acumulează fragmentar, iar sirul de deducții logice, care folosește aceste cunoștințe, nu se stabilește apriori. Pentru a pune în evidență elasticitatea și capacitatea intelectuale ale acestor sisteme au fost elaborate metode de căutare, care să dirijeze procesul deductiv. Astfel, s-au elaborat căutări euristice, care se bazează pe funcții euristice, dar care nu sunt totdeauna precise (au valori apriorice): de exemplu, algoritmul A, elaborat în primele etape de cercetare a inteligenței artificiale. Acesta poate fi folosit în problemele de căutare a căilor posibile în spațiul de stări, pornind de la starea inițială a problemei date, până la o stare finală, prin repetarea transformărilor posibile cu ajutorul operatorilor.

O altă metodă folosită pentru efectuarea deducțiilor o constituie utilizarea cunoștințelor, mai cu seamă a celor euristice.

De exemplu, *programul AM* [13], elaborat de D.B. Lenat, poate fi folosit pentru descoperirea de noțiuni noi în domeniul *numerelor întregi*. Acest program se bazează pe 115 noțiuni fundamentale ale teoriei mulțimilor, date

anterior și folosește 243 cunoștințe euristice.

Noțiunile create sunt prezentate sub formă de frame cu cîteva slot-uri. În fig. 1 este prezentată structura frame-ului NUMERE PRIME care se bazează pe acest program. Cunoștințele euristice sunt descrise prin reguli de tipul "IF THEN" cu care se completează sloturile corespunzătoare ale frame-ului.

DENUMIRE:	Numere prime
DEFINIRE:	
PROVENIENTA:	Număr cu divizori -(x)-2
CALCULUL	$\text{Prime}(x) \equiv (\forall z)$
PREDICATELOR:	$(z   x \Rightarrow z-1 \otimes z-x)$
ITERATII:	(pentru $x > 1$ ): For i from 2 to $\sqrt{x}$ ](i x), 2,3,4,5,7,11,13,17
EXEMPLE:	LIMITE: 2,3 LIMITE - NEADMISE: 0,1 ESEC: 12
GENERALIZARE:	Număr, Număr cu divizor număr par
SPECIALIZARE:	Număr cu divizor număr prim Numere IMPARE, Perechi de numere prime, Numere prime echivalente atașate
PRESUPUNERI:	Factorizare echivalentă, Ipoteza lui Goldbach, Cazul extrem de Numere Divizori
ANALOGII:	Numere cu număr maxim de divizori - caz extrem, opus Numerelor cu divizori, Descompunerea grupelor neprimare în grupe prime
INTERES:	Presupun asocierea Numere primare cu TEMPORAR și Număr cu divizori
VALOARE:	800

Figura 1. Frame-ul noțiunii "Numere Prime", obținut cu ajutorul programului AM

Așa cum se observă în figura 1 au fost definite următoarele sloturi: DEFINIRE, EXEMPLE, GENERALIZARE, SPECIALIZARE, PRESUPUNERI, ANALOGII, INTERES, VALOARE.

În acest exemplu, procesul de dirijare a deducției se bazează pe mecanismul "listei de cereri", prin care sarcinile care urmează să fie îndeplinite se înregistrează în listă, indicându-se "prioritatea interesului", iar sarcina care prezintă cel mai mare interes se selectează din listă și se îndeplinește.

b) *Polisemantica interpretării* este un fenomen obișnuit în înțelegerea limbajelor naturale și în recunoașterea vorbirii.

În cadrul limbajelor naturale, polisemantica cuvintelor, a subordonării lor, polisemantica pronumelor din context ridică mari probleme. De

obicei, înlăturarea polisemanticii se asigură pe seama unui context mai larg și a restricțiilor semantice.

De asemenea, interpretarea elementelor de descriere (contururi, domenii) din prelucrarea imaginilor are caracter polisemantic. Înlăturarea polisemanticii în interpretarea imaginilor se poate realiza prin "metoda relaxării", care folosește restricțiile locale drept cunoștințe. Un alt exemplu îl constituie înlăturarea polisemanticii în sistemul HEARSAY/II prin punerea de acord cu nivelele superioare. În acest sistem sunt prevăzute nivele de interpretare pentru sunete, silabe, cuvinte, grupe de cuvinte și fraze, iar structurarea dirijării procesului deductiv se face pe baza modelului *blackboard*.  
c) Din categoria cunoștințelor neclare fac parte și acelea, pentru care reprezentarea are două sensuri de "adevărat" sau "fals" ("1" sau "0"). De asemenea, există cunoștințe a căror veridicitate se exprimă procentual. În fizica tehnică de astăzi, astfel de cunoștințe se supun legilor lui Bayes, dar în ingeria cunoștințelor, *neclaritatea* nu poate fi reprezentată ca o probabilitate bayesiană.

O metodă destul de des întâlnită în *prelucrarea incertitudinii* o reprezentă metoda *coeficienților de probabilitate*. Această metodă a fost folosită mai întâi în sistemul MYCIN, după care s-a extins destul de mult, deși nu are o bază teoretică.

Ulterior a fost folosită teoria probabilistică a lui Dempster - Schafer, care se deosebește de probabilitatea Bayes, prin aceea că nu fixează valoarea probabilistică, dar poate reprezenta și *necunoașterea*.

O altă metodă pentru înlăturarea incertitudinii o reprezentă descompunerea problemelor cu date neclare în subprobleme, cunoscută sub denumirea de "descriere ierarhizată". Această metodă folosește pentru reprezentare legături de tip SI, SAU, COMB. În figura 2 este ilustrat un arbore pentru reprezentarea cunoștințelor incerte.

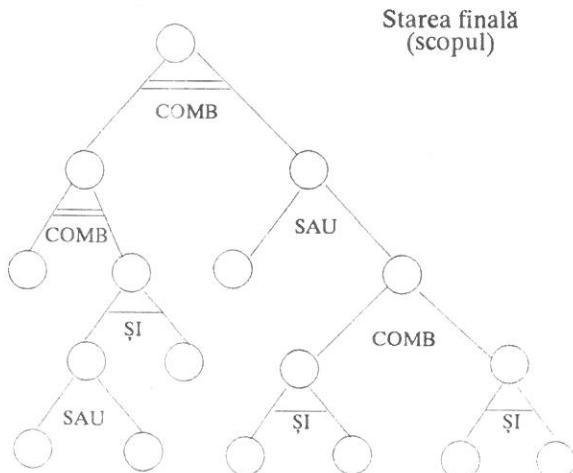


Figura 2. Arborele SI/SAU/COMB folosit în descrierea ierarhizată a cunoștințelor incerte

d) Este destul de dificil să se realizeze o descriere completă a problemelor din lumea înconjurătoare. Astfel, există numeroase cunoștințe a căror semnificație este incompletă. De exemplu "PĂSĂRELE ZBOARĂ" este o cunoștință reală, dar există și păsări care nu zboară, deci cunoștința de mai sus este incompletă. Prin ipoteza "realități închise" se poate considera că există cunoștințe "reale" (adevărate) și cunoștințe care nu pot fi determinate, adică "nereale", iar pentru afirmațiile care nu sunt nici reale nici false s-a convenit să fie considerate ca "false". De exemplu, în limbajul PROLOG, predicatul "NOT" are valoarea de adevăr, dacă pentru argumentele sale nu există o soluție.

e) Sunt destule situații în care, cu toate că problemele sunt corect formulate, interpretarea acestora generează diferite inexacități. De exemplu, cînd spunem "COPIL", nu rezultă clar dacă e vorba despre un copil "sub 2 ani", "mai mare de 4 ani" sau "peste 10 ani".

Pentru reprezentarea și folosirea acestor cunoștințe se utilizează teoria mulțimilor fuzzy.

### 3. Reprezentarea cunoștințelor cu ajutorul teoriei fuzzy

O metodă modernă de studiere a mulțimilor a căror graniță nu este precizată, se bazează pe teoria fuzzy, introdusă în 1965 de către Zadeh, și care este în continuă dezvoltare. În această lucrare se vor prezenta sumar conceptele de bază ale acestei teorii și se va arăta modalitatea de utilizare a acesteia pe un exemplu simplu.

#### 3.1. Mulțimi fuzzy și funcția de apartenență

Dacă se consideră o mulțime completă U, care conține un domeniu problematic, mulțimea fuzzy F a lui U se determină prin funcția de apartenență.

$$\mu_F : U \rightarrow [0,1] \quad \mu_F(u) \in [0,1], u \in U \quad (3.1.)$$

Dacă  $U = (u_1, u_2, \dots, u_n)$ , mulțimea fuzzy F este aditivă și se folosește notația:

$$F = \sum_{i=1}^n \mu_F(u_i) / u_i \quad (3.2.)$$

Dacă U este o mulțime continuă, atunci se folosește notația:

$$F = \int_U \mu_F(u) / u \quad (3.3.)$$

În care, semnificația simbolului "+" și "S" prezintă deosebiri față de cea tradițională din matematică.

Pentru mulțimile fuzzy se pot defini următoarele concepții:

- complementariate

$$\bar{F} = \sum_{i=1}^n (1 - \mu_F(u_i)) / u_i \quad (3.4.)$$

sau

$$\mu_{\bar{F}}(u) = 1 - \mu_F(u) \quad (3.5.)$$

- reuniune

$$F \cup G = \sum_{i=1}^n (\mu_F(u_i) \vee \mu_G(u_i)) / u_i \quad (3.6.)$$

(unde  $a \vee b = \max \{a, b\}$ )

sau

$$\mu_{F \cup G}(u) = \mu_F(u) \vee \mu_G(u) \quad (3.7.)$$

- intersecție

$$F \cap G = \sum_{i=1}^n (\mu_F(u_i) \wedge \mu_G(u_i)) / u_i \quad (3.8.)$$

(unde  $a \wedge b = \min \{a, b\}$ )

sau

$$\mu_{F \cap G}(u) = \mu_F(u) \wedge \mu_G(u) \quad (3.9.)$$

Pentru exemplificare, se consideră o mulțime de oameni, a căror vîrstă este cuprinsă între 0-100 ani. Se poate presupune că aceasta reprezintă o mulțime completă. Pentru această mulțime se definesc următoarele mulțimi fuzzy:

$F_1$  = "tînăr",  $F_2$  = "adult",  $F_3$  = "bâtrîn"  
și funcțiile de apartenență sunt ilustrate în figura 3.

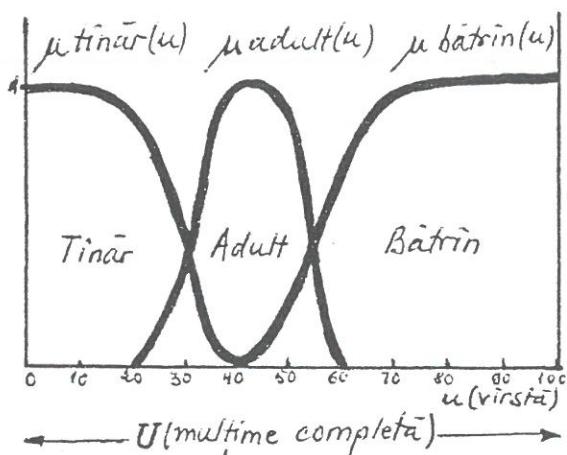


Figura 3. Mulțimi fuzzy și funcțiile de apartenență

Așa cum se observă în figura 3, funcțiile de apartenență se determină astfel

$$tînăr = \mu_{F_1}(u) = 1/0 + 1/10 + 0.8/20 + 0.3/30$$

$$adult = \mu_{F_2}(u) = 0.5/30 + 1/40 + 0.5/50 \quad (3.10)$$

$$bâtrîn = \mu_{F_3}(u) = 0.4/50 + 0.8/60 + 1/70 + 1/80 + 1/90$$

Pentru mulțimea de neclaritate "tînăr" și "adult" se pot determina:

$$\text{tînăr} = \mu_{\bar{F}_1}(u) = \frac{0.2}{20} + \frac{0.7}{30} + \frac{1}{40} + \frac{1}{50} + \frac{1}{60} + \frac{1}{70} + \frac{1}{80} + \frac{1}{90}$$

$$(\text{tînăr} \cup \text{adult}) = \mu_{F_1 \cup F_2}(u) = \frac{1}{0} + \frac{1}{10} + \frac{0.8}{20} +$$

$$+ \frac{0.5}{30} + \frac{1}{40} + \frac{0.5}{50}$$

$$(\text{tînăr} \cap \text{adult}) = \mu_{F_1 \cap F_2}(u) = \frac{0.3}{30}$$

### 3.2. Relații fuzzy

Pentru efectuarea deducțiilor bazate pe cunoștințe, reprezentate cu ajutorul mulțimilor fuzzy este necesar să se cunoască relațiile fuzzy.

O relație fuzzy  $R$ , dintre o mulțime completă  $U$  și o mulțime completă  $V$ , care conține două domenii problematice, este dată de o submulțime a produsului cartezian  $U \times V$  și se exprimă astfel:

$$R = \sum_{i=1}^l \sum_{j=1}^m \mu_R(u_i, v_j) / (u_i, v_j) \quad (3.12.)$$

$$U = \{u_1, u_2, \dots, u_n\}$$

$$V = \{v_1, v_2, \dots, v_m\}$$

In cazul cunoștințelor-reguli de tipul "IF  $F$ , THEN  $G$ ", care folosesc mulțimile fuzzy  $F$  ( $F \subset U$ ) și  $G$  ( $G \subset V$ ), relația fuzzy dintre  $U$  și  $V$  se va exprima astfel:

$$R = F \times G = \sum_{i=1}^l \sum_{j=1}^m \mu_F(u_i) \wedge \mu_G(v_j) / (u_i, v_j) \quad (3.13.)$$

sau

$$\mu_R(u, v) = \mu_F(u) \wedge \mu_G(v) \quad (3.14.)$$

Revenind la exemplele de mai sus, fie  $U$  și  $V$  domeniile problematice:

$$U = V = \{1, 2, 3, 4\}$$

Putem determina mulțimile fuzzy,  $F$  = mică și  $G$  = mare, astfel:

$$F = \text{mică} = \frac{1}{1} + \frac{0.6}{2} + \frac{0.1}{3} + \frac{0}{4} \quad (3.15.)$$

$$G = \text{mare} = \frac{0}{1} + \frac{0.1}{2} + \frac{0.6}{3} + \frac{1}{4}$$

Dacă există "cunoștință - regulă"

<<dacă  $u$  mică, atunci  $v$  mare>> (sau  $F \Rightarrow G$ ), atunci se pot construi relațiile fuzzy astfel:

$$R = \begin{matrix} & \rightarrow & v_1 \\ & \downarrow & \\ u_i & 1 & \left[ \begin{matrix} 1 & 2 & 3 & 4 \\ 0 & 0.1 & 0.6 & 1 \\ 0 & 0.1 & 0.6 & 0.6 \\ 0 & 0.1 & 0.1 & 0.1 \\ 0 & 0 & 0 & 0 \end{matrix} \right] \end{matrix} \quad (3.16.)$$

unde elementele  $(u_i, v_j)$  ale matricei sunt reprezentate

de valorile elementelor  $(u_i, w_j)$  din relația 3.13

În procesul deductiv, pe baza sirului de reguli se poate realiza o *compunere a relațiilor fuzzy*. Fie R o relație fuzzy din domeniul U în domeniul V, iar S o relație fuzzy din domeniul V în domeniul W, atunci relația fuzzy din domeniul U în domeniul W se definește ca o compunere a relațiilor R cu S astfel:

$$R \circ S = \sum_{i=1}^l \sum_{k=1}^n \sum_{v_j \in V} \mu_R(u_i, v_j) \wedge \mu_S(v_j, w_k) / \mu_{R \circ S}(u_i, w_k) \quad (3.17.)$$

Semnul “o” reprezintă compunerea max - min, astfel semnul “v” înseamnă luarea valorii maxime pentru toți  $v_j$ , iar semnul “ $\wedge$ ” înseamnă luarea unui minim.

În exemplul prezentat, pentru  $W = \{1, 2, 3, 4\}$ , putem determina următoarele mulțimi fuzzy:  $F(\subset V) =$  nu este mică și  $H(\subset W) =$  foarte mare astfel:

$$\bar{F} = \text{nu este mică} = \frac{0}{1} + \frac{0,4}{2} + \frac{0,9}{3} + \frac{1}{4} \quad (3.18.)$$

$$H = \text{foarte mare} = \frac{0}{1} + \frac{0}{2} + \frac{0,5}{3} + \frac{1}{4}$$

Dacă există “cunoștință - regulă”

<< dacă  $v$  nu este mică, atunci  $w$  este foarte mare >> sau ( $F \Rightarrow H$ ), în conformitate cu formula 3.13, relația S din V în W se determină astfel:

$\rightarrow w_k$

$$S = \downarrow \begin{matrix} 1 & 2 & 3 & 4 \\ 1 & 0 & 0 & 0 & 0 \\ 2 & 0 & 0 & 0,4 & 0,4 \\ 3 & 0 & 0 & 0,5 & 0,9 \\ 4 & 0 & 0 & 0,5 & 1 \end{matrix} \quad (3.19)$$

Dacă cu formula 3.17 alegem max-min, relația fuzzy R (formula 3.16), atunci din cele două cunoștințe:

<< Dacă  $u$  este mic, atunci  $v$  este mare >>

<< Dacă  $v$  nu este mic, atunci  $w$  este foarte mare >> putem construi următoarea relație fuzzy din U în W astfel:

$$R \circ S = \vee_{v \in V} \vee_{w \in W} \{\mu_R(u, v) \wedge \mu_S(v, w)\} =$$

$$= \left[ \begin{array}{cccc} 0 & 0,1 & 0,6 & 1 \\ 0 & 0,1 & 0,6 & 0,6 \\ 0 & 0,1 & 0,1 & 0,1 \\ 0 & 0 & 0 & 0 \end{array} \right] \circ \left[ \begin{array}{cccc} 0 & 0 & 0 & 0 \\ 0 & 0 & 0,4 & 0,4 \\ 0 & 0 & 0,5 & 0,9 \\ 0 & 0 & 0,5 & 1 \end{array} \right] =$$

$$= \downarrow \begin{matrix} u_i & 0 & 0 & 0,5 & 1 \\ 0 & 0 & 0,5 & 0,6 \\ 0 & 0 & 0,1 & 0,1 \\ 0 & 0 & 0 & 0 \end{matrix} \quad (3.20)$$

### 3.3. Deducții fuzzy

Deduția tradițională sau regula separării este deducția Q din P, după regula  $P \Rightarrow Q$ , care se exprimă astfel:

$$\begin{array}{c} P \Rightarrow Q \\ P \\ \hline Q \end{array} \quad (3.21.)$$

Acest simbol este folosit în cazul relațiilor fuzzy deductive, în cazul în care cunoștințele sunt mulțimi fuzzy  $F_1, G_1, F_2, G_2$ .

Deduția  $G_2$  din  $F_2$  efectuată pe baza regulei  $F_1 \Rightarrow G_1$ , se exprimă astfel:

$$\begin{array}{c} F_1 \Rightarrow G_1 \\ F_2 \\ \hline G_2 \end{array} \quad (3.22.)$$

Această notație are o caracteristică esențială: mulțimile  $F_1$  și  $F_2$  nu trebuie să coincid obligatoriu. Dacă mulțimile  $F_1$  și  $F_2$  nu coincid, dar sunt apropiate, atunci ele pot fi comparate și se obține deducția  $G_2$  în sfera lor de concordanță. Prin urmare, deducțiile fuzzy se efectuează astfel:

- se determină mai întâi relația fuzzy, din regula  $F_1 \Rightarrow G_1$ ; dacă există un sir de mai multe reguli, atunci se aplică procedeul “max - min” în 3.17.
- deducția  $G_2$  se determină pe baza mulțimii fuzzy  $F_2$  și a relației R

$$G_2 = F_2 \circ R = \sum_{i=1}^m \sum_{u_i \in U} \sum_{v_j \in V} \mu_{F_2}(u_i) \wedge \mu_R(u_i, v_j) / v_j \quad (3.23.)$$

unde

$$\begin{array}{c} F_1, F_2 \subset U \\ G_1, G_2 \subset V \end{array} \quad (3.24.)$$

$$V = \{v_1, v_2, \dots, v_m\}$$

Să analizăm exemplul concret prezentat mai sus.

$$U = V = \{1, 2, 3, 4\}$$

$$F_1(\subset U) = \text{mică} = \frac{0}{1} + \frac{0,6}{2} + \frac{0,1}{3} + \frac{0}{4} \quad (3.25.)$$

$$G_1(\subset V) = \text{mare} = \frac{0}{1} + \frac{0,1}{2} + \frac{0,6}{3} + \frac{1}{4}$$

Pe lîngă acestea, fie

$$F_2 = \text{aprox. } 2 = \frac{0,3}{1} + \frac{1}{2} + \frac{0,3}{2} + \frac{0}{4} \quad (3.26.)$$

în condițiile,

<< dacă  $u$  este mică, atunci  $v$  este mare >>,  $(F_1 \Rightarrow G_1)$ , <<  $u$  aprox. 2 >> ( $F_2$ )

Să determinăm << cine este  $v$ ? >>

Din aceste reguli, determinăm relația R din U în domeniul V astfel:

$$R = \left[ \begin{array}{cccc} 0 & 0,1 & 0,6 & 1 \\ 0 & 0,1 & 0,6 & 0,6 \\ 0 & 0,1 & 0,1 & 0,1 \\ 0 & 0 & 0 & 0 \end{array} \right] \quad (3.27.)$$

În conformitate cu formula 3.23, determinăm

concluzia G2, astfel:

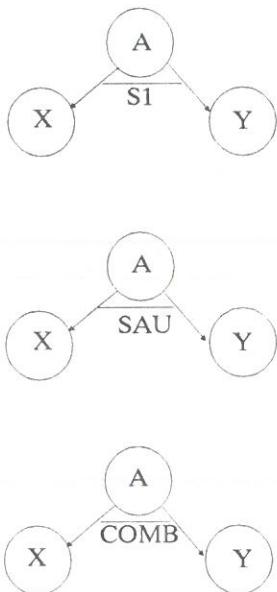
$$G2 = F2 \circ R =$$

$$= [0,3 \ 1 \ 0,3 \ 0] \cdot \begin{bmatrix} 0 & 0,1 & 0,6 & 1 \\ 0 & 0,1 & 0,6 & 0,6 \\ 0 & 0,1 & 0,1 & 0,1 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (3.28.)$$

$$= [0,0,1 \ 0,6 \ 0,6]$$

$$\text{Aici, } F2 \left( = \frac{0,3}{1} + \frac{1}{2} + \frac{0,3}{3} + \frac{0}{4} \right)$$

este reprezentată de matricea  $[0,3 \ 1 \ 0,3 \ 0]$ . În matricea finală fiecare element "j" reprezintă valoarea de apartenență a lui  $v_j$  la mulțimea G2.



**Figura 4. Reprezentarea cunoștințelor cu ajutorul regulilor, bazate pe legăturile SI, SAU, COMB**

Deci răspunsul este <<v este G>>, unde:

$$G2 = \frac{0}{1} + \frac{0,1}{2} + \frac{0,6}{3} + \frac{0,6}{4}$$

Cu alte cuvinte, răspunsul este <<pînă la ce grad este mare>>. Aproximativ aceeași concluzii le putem obține și noi. Logica fuzzy este o variantă a unor astfel de deducții fuzzy.

#### 4. Logica incertă

Logica incertă se bazează pe teoria mulțimilor incerte, în care formulele logice pot lua valori reale, cuprinse în intervalul  $[0,1]$ .

În logica incertă *autenticitatea* se reprezintă printr-o valoare adevărată, cuprinsă între 0 și 1, iar valorile atribuite regulilor [figura 4] sunt adevărate.

În figura 4 este ilustrată descrierea cunoștințelor incerte

cu ajutorul regulilor folosite în sistemele de producții.

Regula: DACĂ X și Y,  
ATUNCI A cu C1

Regula: DACĂ X sau Y,  
ATUNCI A cu C2

(Dacă X și Y nu pot fi îndeplinite simultan, atunci regula de mai sus se poate descompune în două reguli separate)

Regula: DACĂ X,  
ATUNCI A cu C21

Regula: DACĂ Y,  
ATUNCI A cu C22

Regula 1: DACĂ X,  
ATUNCI A cu C31

Regula 2: DACĂ Y,  
ATUNCI A cu C33

$C_1, C_2, C_{21}, C_{22}, C_{31}, C_{33}$  - reprezintă gradele de certitudine acordate regulilor.

Dacă  $t_x$  și  $t_y$  reprezintă valori adevărate ale premiselor X și Y ale unei reguli, atunci valoarea adevărată a lui  $t_{\text{premisi}}^{\text{regulă}}$ , în cazul legăturilor SI, SAU din figura 4 se determină astfel:

$$t_{\text{regulă}} = \min \{t_x, t_y\} - \text{pentru legătura SI}$$

$$t_{\text{regulă}} = \max \{t_x, t_y\} - \text{pentru legătura SAU}$$

Dacă în cazul general există o valoare adevărată, atribuită regulei, atunci valoarea adevărată  $t_A$  corespunzătoare deducției, se determină astfel:

$$t_A = \min \{t_{\text{premisi}}, t_{\text{regulă}}\}.$$

#### 5. Concluzie

În această lucrare, nu a fost posibilă prezentarea tuturor metodelor de prelucrare a "neclarităților". S-a făcut o prezentare destul de succintă a problemelor întâlnite în ingineria cunoștințelor pentru prelucrarea neclarităților. S-a abordat problema referitoare la reprezentarea cunoștințelor ale căror granițe nu sînt precizate (cunoștințe imprecise sau ignorante). În acest caz, tehniciile de reprezentare și stabilire a relațiilor de interdependență se bazează pe teoria fuzzy. Pentru conceptele introduse, a fost prezentat un exemplu simplu în vederea înțelegерii modalității de determinare a mulțimilor și relațiilor fuzzy.

Bazele teoretice ale reprezentării cunoștințelor incerte și ale polisemei, precum și rezultatele obținute în acest domeniu vor fi prezentate în articolele următoare. Selectarea uneia sau alteia dintre metodele de reprezentare și folosire a cunoștințelor depinde evident de natura problemei concrete și de intuiția specialistului.

Pentru problemele complexe, în care sunt prezente și corelate cele cinci tipuri de neclarități, cercetările privind metodele de prelucrare rămîn deschise.

## Bibliografie

1. ALEXANDER, I.: *La conception des systèmes intelligents*. Hermes Ed., Londres et Paris, 1985, pp.127-192.
2. ARAI, E., IWATA, K.: Product Design Logic for an Intelligent Product Modelling System. In: R&CIM, vol.4, nos.3/4, 1988, pp.32- 35.
3. BENCHIMOL, G., LEVINE, P., POMEROL, J.C.H.: *Système expert dans l'entreprise*. Hermes Ed. Paris, 1990, pp.10-280.
4. BERRY, D.C.: The Problem of Implicit Knowledge. In: Expert Systems, Aug.1987, pp.17-21.
5. BRACHMAN, R.J., LEVESQUE, H.J.: Readings in Knowledge Representation . Morgan Kaufmann, Palo Alto, Calif., 1985, pp.32- 41.
6. BREMER, M.: Expert Systems in Business: a British Perspective. In: Journal Expert Systems, May, 1988, pp.15-19.
7. COHEN, P.R.: Heuristic Reasoning about Uncertainty: An AI Approach. Pitman, Boston, Mass., 1985, pp.35-41.
8. DAVIS, R., BUCHANAN, B.G., SHORTLIFFE, E.: Meta-Level Knowledge,in Rule - Based Expert Systems. Addison - Wesley, Reading, Mass., 1985, pp.192-223.
9. DERMOTA, P.: Réalisation d'un système basé sur la connaissance pour l'aide à la répartition des Wayons Vides. Le 3-ème cycle de l'Université P. et M. Curie, Paris, France, 1987.
10. FARRENY, H.: Les systèmes experts - Principes et exemples, Cependantes Editions, Toulouse, 1988, pp.57-112.
11. GINSBERG, A.: Automatic Refinement of Expert Knowledge Bases. Morgan Kaufmann, Palo Alto, Calif., 1988, pp.250-283.
12. HAYES - ROTH, F., WATERMAN, D.A., LENAT, D.B.: Building Expert Systems. Addison - Wesley, Reading, Mass., 1983, pp.115- 175.
13. ISHIZUKA, M., UENO, H. ş.a.: Knowledge Representation and Use. Omsha, Tokyo, 1987, pp.201-260.
14. ITO, Y., SHINNO, H., SAITO, H.: A Proposal for CAD/CAM Interface with Expert Systems. In: R&CIM, vol.4, nos.3/4, 1988, pp.15-21.
15. KEUNG - CHI, Ng., ABRAMSON, B.: Uncertainty Management in Expert Systems. In: IEEE, April 1990, Japan, pp.29-45.
16. KLIVE, P.J., DOLINS, S.D.: Designing Expert Systems: A Guide to Selecting Implementation Techniques. John Wiley & Sons, New York, 1989, pp.15-30.
17. MITCHELL, T., STEINBERG, L., SCHULMAN, J.: A Knowledge - Based Approach to Design. In: IEEE, Trans. Pattern Analysis and Machine Intelligence, Sept, 1985, pp.37-45.
18. MITTAL, S., ARAYA, A.: A Knowledge - Based Framework for Design. In: Proceedings of the 5th National Conf. AAAI, vol.2, Morgan Kaufmann, Palo Alto, Calif. Aug., 1986, pp.27-32.
19. MOISE, M., FLORESCU, G.: Mathematical Models in Knowledge Representation and Knowledge Base in Technology. In: Preprints of the 11th Prague Conference on Information Theory Statistical Decision Function and Random Processes, Prague, 1990, pp.289-290.
20. MOISE, M., FLORESCU, G.: Mathematical Modelling in Decision Making and Choice of Strategy in Technological Processes. In: Preprints of the 11th Prague Conference on Information Theory Statistical Decision Function and Random Processes, Prague, 1990, pp.290-291.
21. MOISE, M.: Modelarea matematică ierarhizată a proceselor tehnologice în construcții de mașini. Workshop - Modelare și Simulare , organizat de RO-AMSE, București, sept. 1991.
22. MOISE, M.: Modele de reprezentare a cunoștințelor. Folosirea lor. Workshop - Modelare și Simulare, Organizat de RO-AMSE, București, sept. 1991.
23. MOISE, M. ş.a.: Sistem interactiv pentru generarea automată a tehnologiilor. In: Cibernetica Aplicativă și Revoluția Tehnico- Stiințifică, Editura Academiei, 1988, pp.252-257.
24. NILSSON, N.J.: Principles of Artificial Intelligence. Tioga Publishing, Palo Alto, Calif.,1980, pp.210-225.
25. SMITH, R.G.: On the Development of Commercial Expert Systems. In: AI Magazine, vol.5, no.3, 1984, pp.12-17.
26. SPUR, F., KRAUSE, L.: Automatizarea proiectării în construcții de mașini. Verlag München Wien, 1987, pp.360-372.
27. STEFIK, M.ş.a.: Architecture of Expert Systems. In: Building Expert Systems, Addison-Wesley, Reading, Mass., 1983, pp.112-117.
28. SUZUKI, H., KIMURA, F., ş.a.: A Product Modelling System for Constructing Intelligent CAD and CAM Systems. In: R&CIM, vol.4, nr.3/4, pp.483-489.
29. TVETKOV, V.D.: Modelarea sistemică-structurală și automatizarea proceselor tehnologice, Minsk, 1979, pp.260-290.
30. ZARUBIN, V.M., PAVLOV, V.V.: Automatizarea sistemului de proiectare a proceselor tehnologice în construcții de mașini, Moscova, 1988, pp.23-37.
31. WATERMAN D.A.: A Guide to Expert Systems, Addison-Wesley, Reading, Mass., 1986,pp.152-170.

# EUROLAN'93

Ecole d'été organisée par l'Université "Al.I.Cuza" de Iași, l'Université Paris-Sud XI et l'Université des Sciences et Techniques de Lille, qui aura lieu à Iași, en Roumanie, du 18 au 29 juillet 1993 sur le thème:

**TRAITEMENT DU LANGAGE NATUREL  
et  
PROGRAMMATION LOGIQUE**  
**NATURAL LANGUAGE PROCESSING  
and  
LOGIC PROGRAMMING**

Les conférences suivantes ont été déjà confirmées: /The list of invited conferences includes:

1. **La sémantique de Prolog**  
par Jean Paul Delahaye (LIFL - Lille 1)
2. **Transformation de programmes et interprétation abstraite pour Prolog**  
par Philippe Devienne (LIFL - Lille 1)
3. **Grammaires d'unification et traduction automatique**  
par Dominique Estival (ISSCO - Genève)
4. **Méthodes connexionnistes pour le TLN**  
par Daniel Memmi (LIMSI - CNRS, Orsay)
5. **L'analyse syntaxique du langage naturel, problèmes de parsing,  
architectures adaptables pour l'analyse du langage**  
par Gerard Sabah (LIMSI-CNRS, Orsay)
6. **La génération du langage naturel**  
par Michael Zock (LIMSI-CNRS, Orsay)

Frais d'inscription /registration fee:

- inscriptions universitaires /university registrations: 1000 FF
- inscriptions industriels /industrial registrations: 3000 FF
- personnes accompagnantes /accompanying persons: 500 FF

Les frais de voyage et de subsistance seront supportés par l'institution du participant./Travel and subsistence expenses should be covered by the home institution.

Des sommes limitées seront offertes pour supporter (partiellement ou totalement) la participation des sollicitants des pays de l'Europe de l'Est, sur le choix des organisateurs après l'analyse des requêtes formulées./Limited funds are available to cover (partially or totally) the fees for participants from Eastern Europe countries. The organisers will decide on a base of a written request.

Pour recevoir les annonces suivantes et s'inscrire à l'Ecole retournez au comité d'organisation une copie du formulaire suivant, dûment rempli, pas plus tard que le 1<sup>er</sup> mai 1993. /In order to receive the forthcoming announcements and register to the Summer School, please send a filled in copy of the following form to the organizing committee, not later than May, the 1<sup>st</sup> 1993:

Nom/Name : . . . . .

Age : . . . . . Sex : . . . . .

Institution : . . . . .

Adresse/Address : . . . . .

Telephone : . . . . . Fax : . . . . . E-mail : . . . . .

Pour tout renseignement concernant l'organisation, s'adresser à:/ For any information concerning the organization you should address to:

Dan Cristea  
Universitatea "Al.I.Cuza" Iași  
Facultatea de Informatică  
Str. G-ral Berthelot 16  
6600 Iași  
Romania  
Tel: (40) 98 142230  
Fax: (40) 98 146330

Jean Pierre Steen  
Université de Lille 1  
LIFL - URA 369 CNRS  
Bât. M.3 - Cité Scientifique  
59655 Villeneuve d'Ascq Cedex  
France  
Tel: (33) 20 43 42 60  
Fax: (33) 20 43 65 66  
E-mail: steen@FRCITL81.bitnet