

## Sistem de învățare bazat pe un model hibrid de cunoștințe

Vasile MAZILESCU, Dan CAPRITA

Catedra de Contabilitate și Informatica Economica, Universitatea "Dunărea de Jos" Galați

*This article refers the problem to gradual capture by a human agent a specific fuzzy knowledge model using a learning system based on the classical model of diagnosis. For this, we have used the parsimonious covering theory proposed by Peng and Reggia taking into account like a learning problem a planning problem. The goal of this research is represented by the design and implementation of the learning system, using the basic methods of Artificial Intelligence. The system was implemented and tested, experimentally obtaining a prototype as well as a series of results that confirm the conceptual elements on which this system relies on.*  
**Keywords:** diagnosis, fuzzy planning, sequential learning.

### Introducere

Preocuparea centrală în majoritatea formelor de învățare, este cea de achiziție incrementală, de modificare, consolidare și adaptare a modelelor de cunoștințe specifice domeniului problemei. În sens larg, învățarea poate fi împărțită în două categorii ([2]): i) *supravegheata*: fiecărei instanțe de antrenament i se asignează clasificarea corectă de către un "profesor"; ii) *nesupravegheata*: nu există instanțe de antrenament iar algoritmi de învățare trebuie să găsească clasificări semnificative.

Sistemul de învățare este bazat pe un model hibrid de cunoștințe (SIMHC), fiind elaborat și testat la nivel de prototip. Învățarea este *supravegheată*, scopul acesteia fiind ca agentul care învață (agentul uman) să asimileze cunoștințe privind rezolvarea unei probleme specifice de planificare astfel încât acesta să devină pe cât posibil autonom pe un orizont de timp impus  $t_f$  (timp de învățare). Modelul de cunoștințe este hibrid întrucât sunt utilizate în paralel în procesul de învățare două tipuri de modele de cunoștințe care contribuie la realizarea abilității de învățare în cadrul SIMHC:

- modelul de cunoștințe fuzzy specific problemei supusă învățării ([6])
- modelul de discriminare a situației curente specifice, folosind reprezentarea sub formă de rețea în conformitate cu [8].

În particular, în cele ce urmează, învățarea va desemna procesul de transfer al cunoștințelor structurate privind rezolvarea unei probleme

de planificare sub forma unor modele de cunoștințe  $M_0, \dots, M_k$  care semnifică instanțe ale problemei. Existența unui număr de modele de cunoștințe de tipul  $M_0 \subset M_1 \subset \dots \subset M_k$  (1) semnifică un proces gradual și incremental al învățării, un proces secvențial de transfer de cunoștințe ([3]).

Sistemul de învățare SIMHC constă din:

- *procesul sau problema* (notat P și reprezentată o problemă de planificare), caracterizat printr-o anumită structură și dinamică, cu un scop bine precizat, scop care este "mostenit" și de scopul sistemului bazat pe cunoștințe. Acesta reprezintă problema sau domeniul problemei, fiind înglobat în  $M_{j|j=0,k}$ ;
- *un subsistem expert* (SEC) care are înglobat în el mai multe modele de cunoștințe (crisp și fuzzy) ale procesului precum și toate componentele de bază ale unui sistem bazat pe cunoștințe;
- *un subsistem de diagnoză* (SD) înglobat în structura SIMHC, care pornind de la un set de manifestări furnizează ipoteze sau explicații ale acestora. Pe baza explicațiilor generate, SD activează un anumit model intern al procesului utilizat de sistemul expert. Dacă aceste explicații sunt valide, atunci ele reprezintă cuantumul de cunoștințe care permite avansul problemei de învățare în sensul relației (1).

### Caracteristicile de bază ale teoriei acoperirii reduse

Elementele importante ale teoriei acoperirii reduse a lui Peng și Reggia care au constituit baza

conceptuala a SD sunt prezentate sumar în conformitate cu lucrarea [8].

**Definitia 1.** (Formularea problemei de diagnoza) *O problema de diagnoza P este un 4-tuplu  $\langle D, M, C, M^+ \rangle$  unde:*

- $D = \{d_1, d_2, \dots, d_n\}$  o multime finita, nevida, de obiecte numite *dezordini*;
- $M = \{m_1, m_2, \dots, m_k\}$  o multime finita, nevida, de obiecte numite *manifestari*;
- $C \subseteq D \times M$  o relatie cu domeniul( $C$ ) =  $D$  si codomeniul( $C$ ) =  $M$ , numita cauze;
- $M^+ \subseteq M$  o submultime distincta a lui  $M$  care reprezinta multimea manifestarilor prezente.

**Definitia 2.** (Solutia problemei de diagnoza) Multimea  $D_1 \subseteq D$  este o *acoperire* a lui  $M_j \subseteq M$  daca  $M_j \subseteq \text{efecte}(D_1)$ . Utilizând notiunea de acoperire ce formalizeaza termenul imprecis de “justificare cauzala pentru” se poate defini unul dintre cele mai importante concepte ale teoriei acoperirii reduce, cel de explicatie a diagnosticului.

**Definitia 3.** O multime  $E \subseteq D$  este o *explicatie* a lui  $M^+$  pentru o problema  $P = \langle D, C, M, M^+ \rangle$  daca si numai daca  $E$  acopera pe  $M^+$  si  $E$  satisface criteriul dat de reduce. De notat este faptul ca notiunea de explicatie consta din trei conditii: cea de acoperire (fiecare manifestare din  $M^+$  trebuie sa fie cauzal asociata cu anumiti membri a lui  $E$ ); acoperirea sa fie redusa; explicatia sa se bazeze pe dezordini. Conditia de acoperire captureaza ceea ce intuitiv se asteapta de la o explicatie, deci ea trebuie sa fie capabila de o justificare cauzala pentru toate manifestarile prezente. O explicatie trebuie de asemenea sa fie o submultime a lui  $D$  întrucât altfel (i.e. daca contine si nondezordini) este considerata incompleta. Dintre toate asemenea acoperiri reduce unele sunt considerate mai plauzibile decât altele, de unde si definitia teoriei acoperirii reduce.

O rezolvare abductiva a unei probleme trebuie sa fie *constructiva*. Folosind cunostintele reprezentate semantic prin relatia  $C$ , trebuie de construit explicatiile plauzibile pentru o multime data  $M^+$  mai curând decât a testa fiecare membru al multimii putere  $\mathcal{P}$ . Cardinalul multimii  $\mathcal{P}$  este foarte mare, iar majoritatea membrilor sai sunt irelevanti într-o problema data. Numarul de explicatii plauzi-

bile pentru o problema data este însă relativ mic. Astfel, pentru a simula ciclul “ipoteza-si-testare” procesul de rezolvare al problemei trebuie sa fie *secvential*: attributele prezentei probleme ( $M^+$ ) sunt date si procesate câte unul odata. Natura constructiva si secventiala este o trasatura distinctiva a acestui model de rationament abductiv. Algoritmul de rezolvare a problemei de diagnoza prin abductie este bazat pe algebra generatorilor si a multimilor de generatori.

**Definitia 4.** Fie  $g_1, g_2, \dots, g_n$  submultimi nevide, disjuncte doua câte doua, a lui  $D$ . Atunci  $G = \{g_1, g_2, \dots, g_n\}$  este un *generator*. Clasa generata de  $G$ , desemnata prin  $[G]$  este definita ca fiind  $G = \{\{d_1, d_2, \dots, d_n\} / d_i \in g_i, 1 \leq i \leq n\}$ .

Un generator poate fi interpretat din doua perspective:

- un generator  $G$  este o simpla multime de  $n \geq 0$  multimi distincte de dezordini;
- $[G]$  contine toate multimile posibile de  $n$  elemente ce pot fi formate luând câte un element din fiecare  $g \in G$ .

*Operatiile* care se aplica generatorilor sunt: *împartire* (*div*); *reziduu* (*res*); *reziduu-crescut* (*augres*) cu care se manipuleaza multimile de generatori în timpul rezolvării problemei.

Presupunem ca la un moment dat al rezolvării, multimea de manifestari  $M_1$  este cunoscuta iar multimea generatoare  $G_1$  reprezinta solutia tentativa (deci toate explicatiile lui  $M_1$ ). Daca o manifestare aditionala  $m_j \in M_1$  este descoperita, atunci manifestarile  $M_2 = M_1 \cup \{m_j\}$  formeaza  $M^+$  si împartirea *div*( $G_1, \text{cauze}(m_j)$ ) este multimea de generatori ce reprezinta toate explicatiile din  $[G_1]$  ce acopera si pe  $m_j$ , deci si pe  $M_2$ .

De asemenea *res*( $G_1, \text{cauze}(m_j)$ ) este multimea de generatori care reprezinta toate explicatiile din  $[G_1]$  ce nu acopera pe  $m_j$ . Adaugând elemente proprii din *cauze*( $m_j$ ) la fiecare multime din *res*( $G_1, \text{cauze}(m_j)$ ) se formeaza reziduu marit *augres*( $G_1, \text{cauze}(m_j)$ ). Se poate transforma fiecare explicatie a lui  $M_1$  în  $[G_1]$  care nu acopera pe  $M_1$  într-o acoperire a lui  $M_2$ . Multimea de explicatii reprezentata prin *div*( $G_1, \text{cauze}(m_j)$ ) plus acoperirea

definita de  $augres(G_1,cauze(m_j))$  reprezinta solutia actualizata sau ipotezele pentru  $M_2$ .

Aceste operatii ofera deci o modalitate mecanica de a reactualiza incremental multimea de generatori când o noua manifestare este descoperita în timpul procesului secvential de rezolvare a problemei.

Bazat pe operatiile descrise mai sus, algoritmul BIPARTIT dezvoltat de Reggia ofera o metoda mecanica de gasire a unei solutii pe ntru o problema de diagnoza. Acest algoritmul lucreaza într-o maniera secventiala si constructiva. El ia în considerare la momentul dat o unica manifestare  $m_j$  obtinuta fie din multimea  $M^+$  fie prin procesul iterativ de generare a întrebărilor si obtinere a raspunsur i-

**function** BIPARTIT(D,M,C)

**variabile**  $m_{new}$  manifestare,  $H_1=cauze(m_j)$ , ipoteze – multimea de generatori

**begin**

ipoteze = { $\emptyset$ }

// initial nici o manifestare nu este prezenta

**while** moremanif **do**

// cât timp mai exista manifestari

$m_{new} := nextman;$

// noua manifestare obtinuta

ipoteze := revise(ipoteze, cauze( $m_{new}$ ))

// actualizarea ipotezelor

**endwhile;**

**return** ipoteze;

// multimea generatoare pentru  $sol(P)$  \*/

**end**

*Observatii:*

▪ Fiecare ipoteza nou construita (ipoteze) este o acoperire iredundanta pentru toate manifestarile descoperite pâna atunci. Ordinea de aparitie a manifestarilor nu este importanta.

▪ Reprezentarea cunostintelor si metoda de rezolvare abductiva folosind teoria acoperirii reduce sunt naturale, rezultând astfel o metoda intuitiva si rationala de stabilire a diagnosticului diferential din punctul de vedere al diagnosticianului uman.

A explica de ce o dezordine apartine sau nu justificarii solutiei unei probleme de diagnoza folosind teoria acoperirii reduce presupune a face mai mult decât a cita toate manifestarile prezente ce pot fi cauzate de respectiva dezordine. Conceptul cheie folosit în justifi-

lor si încorporeaza  $cauze(m_j)$  printre ipotezele existente. Procesul continua pâna când toate manifestarile posibile au fost incluse si procesate. Ipotezele tentative si solutia finala sunt reprezentate în forma multimii de generatori si se bazeaza pe operatiile generatorilor:  $div, res, augres$ , discutate anterior. Se defineste functia "revise" pentru construirea de noi ipoteze din cele existente si noile manifestari aparute:  $revise(G,H_1) = F \cup res(Q,F)$ , unde  $G$  este multimea generator rezultata anterior;  $H_1 = cauze(m_j)$ ;  $F = div(G,H_1)$ ;  $Q = augres(G,H_1)$ ;  $res(Q,F)$  este folosita pentru a elimina acoperirile duplicate sau redundante din  $[Q]$ .

carei raspunsului prin aceasta teorie este ca pentru fiecare dezordine dintr-o explicatie ce reprezinta o acoperire iredundanta a lui  $M^+$  exista o manifestare  $m_j$  din  $M^+$  ce este unic acoperita de  $\mathcal{d}$ , astfel dezordinile dintr-o explicatie împart  $M^+$  în submultimi nevide. Manifestarile ce se afla într-o regiune a lui  $M^+$  ce este acoperita numai de o dezordine din explicatie reprezinta motivul pentru care respectiva dezordine este prezenta. Formal exista o metoda de justificare bazata pe teoria generatorilor.

**Definitia 5** (Modelul cauzal probabilist). Fie  $P = \langle D, M, C, M^+ \rangle$  o problema de diagnoza, si fie  $D_1 \subseteq D$ . Atunci probabilitatea relativa a lui  $D_1$  fiind dat  $M^+$ , este definita ca:

$$L(D_1, M^+) = \prod_{m_j \in M^+} [1 - \prod_{d_i \in D_1} (1 - c_{ij})] \cdot \prod_{d_i \in D_1} \prod_{m_i \in efect(d_i) - M^+} (1 - c_{il}) \cdot \prod_{d_i \in D_1} \frac{p_i}{(1 - p_i)}$$

Dintre toate  $D_1 \subseteq D$ , acelea cu cea mai mare probabilitate relativa poate fi aleasa drept solutie a problemei. De observat ca  $L(D_1, M^+) \geq 0$ , si  $L(\emptyset, \emptyset) = 1$ .

Pentru o mai mare claritate se considera

$L(D_1, M^+)$  ca fiind alcatuita din trei componente:

$$L(D_1, M^+) = L_1(D_1, M^+) \cdot L_2(D_1, M^+) \cdot L_3(D_1, M^+).$$

Primul produs,

$$L_1(D_I, M^+) = \prod_{m_j \in M^+} P(m_j | D_I) = \prod_{m_j \in M^+} [1 - \prod_{d_i \in D_I} (1 - c_{ij})]$$

poate fi privit ca măsurând cât de probabil este ca  $D_I$  sa cauzeze prezenta manifestarilor date de  $M^+$ . Al doilea produs,

$$L_2(D_I, M^+) = \prod_{m_j \in M^+} P(\bar{m}_j | D_I) = \prod_{d_i \in D_I} \prod_{m_j \in efecte(d_i) \rightarrow M^+} (1 - c_{ij})$$

poate fi vazut ca o masura a probabilitatii bazata pe manifestarile asteptate cu  $D_I$  dar care lipsesc. Al treilea produs

$$L_3(D_I, M^+) = \prod_{d_i \in D_I} \frac{p_i}{(1 - p_i)}$$

reprezinta probabilitatea bazata pe probabilitatile a priori ale lui  $D_I$ .

De subliniat ca toate aceste produse implica doar informatii probabilistice locale lui  $d_i \in D_I$  si  $m_j \in M^+ \in efecte(d_i)$  si nu întreaga baza de cunostinte.

### Studiu de caz

Sistemul expert dezvoltat utilizeaza un model de cunostinte al procesului  $M_i |_{i=0,k}$  pentru rezolvarea problemei P la nivelul modelului hibrid de cunostinte folosit. Iesirea procesului este comparata cu referinta (scopul) iar în masura în care aceasta iesire nu satisface criteriile cerute ea va reprezenta o eroare calitativa fuzzy. Aceste erori calitative reprezinta intrari activate unic de la  $[0, \dots, k]$  în sistemul de diagnoza SD (o eroare calitativa este de fapt un quantum de manifestari).

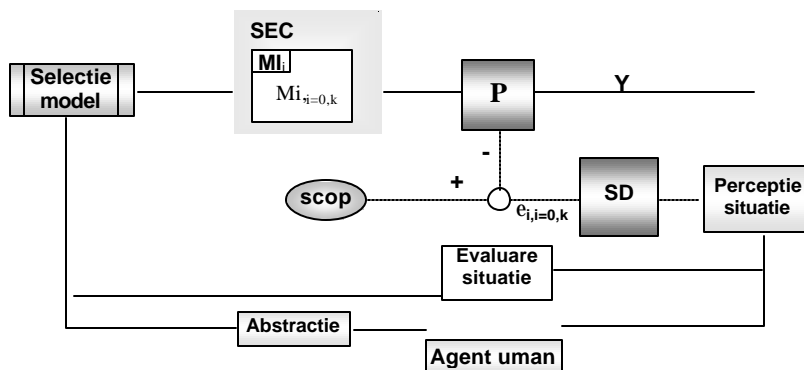


Fig. 1. Structura sistemului de învățare SIMHC

În figura 1, elementele componente au următoarele semnificatii:

- $e_i |_{i=0,k}$  - sirul erorilor calculate în raport cu functia obiectiv (de conducere). Calculul se realizeaza prin identificarea pentru fiecare sistem de conducere  $(0, \dots, k)$  a manifestarilor aparute în comportarea raspunsului sistemului de conducere, folosind modelul curent  $M_i |_{i=0,k}$  pe care agentul uman îl cunoaste cert. Sintetic,  $\varepsilon_i$  reprezinta multimea nevida de simptome care permit sistemului de diagnoza SD sa functioneze în vederea determinarii unui nou model de conducere. Dacă  $(\exists) i_0, i_0 \in \{0, \dots, k\}$  astfel încât  $\varepsilon_{i_0} = 0$  atunci SD nu mai este util, procesul de învățare se termina si agentul uman se considera instruit la nivelul  $M_{i_0}$ , întrucât  $M_0 \subset M_1 \subset \dots \subset M_k$  si pentru  $(\forall) s \geq k, M_k = M_s$  (nivelul maxim de cu-

nostinte la un moment dat). Aceasta releva si finitudinea procesului de învățare în  $\mathbb{N}$  dat.

- Sistemul expert (SEC) în bucla închisa este conform cu lucrarea [7].
- Sistemul de diagnoza SD primește ca intrari un set de manifestari si furnizeaza iesiri (printr-un rationament de generare de ipoteze), care reprezinta explicatii referitoare la prezenta manifestarilor. Agentul uman preia rezultatele sistemului de diagnoza (nivelul de perceptie privind rezolvarea problemei de conducere), le “abstractizeaza” (clasifica - cunostinte anterioare dobândite prin achizitia de cunostinte) si selecteaza un anumit model de cunostinte. Dacă pentru  $i \in \{0, \dots, k\}$  agentul a folosit si testat modelul corespunzator  $M_i$ , atunci în mod “cert”, alegerea unui “nou” model de cunostinte  $M_{i+1}$  se poate face cu conditia necesara ca  $M_{i+1} \supset M_i$ , adica ori-

ce urmator model de cunostinte trebuie sa prezinte o varianta îmbogățita.

În continuare se prezinta modul în care sistemul de diagnoza SD genereaza un set de ipoteze (explicatiile) si le clasifica pentru a explica manifestarile (abaterile de la buna functionare) sistemului supus diagnozei, rețeaua cauzala utilizata pentru diagnoza SEC, precum si o serie de teste pentru a evidentia influenta probabilitatilor ce apar în model.

*Cauzele* (primul nivel al grafului bipartit) sunt:

- *Sumax<sub>i</sub>#M6* – suma încarcarilor initiale nu este multiplu de 6 (cazul crisp). Chiar dacă este respectata strategia de conducere sistemul nu va realiza încarcarea echilibrata a celor 6 subsisteme deoarece încarcarile acestora sunt valori naturale pozitive, ele neputând fi divizate oricât de mult:  $\sum_{i=1}^6 \frac{x_{i_0}}{6} \notin N_+$  (1)

- *p2#p1* – nerespectarea strategiei de conducere prin folosirea altui vector de prioritati p2 care apartine unei clase de vectori  $\overline{p2}$  ce nu duce la rezolvarea problemei de echilibrare.

- *RIC* – repartitia (distributia) încarcarilor initiale este o alta cauza care poate, în cazul crisp, la aparitia unor manifestari. Exista situatii în care chiar daca suma încarcarilor initiale este multiplu de 6 si este folosit un vector de prioritati  $p1 \in \overline{p1}$ , problema de echilibrare nu poate fi rezolvata. Aceasta repartitie a încarcarilor initiale depinde de structura sistemului.

$(\forall) X_0 \subset \mathbf{X}, (\exists)$

$\overline{X_0} \subset X_0, \overline{X_0} = \{x_0 | PE(x_0) \text{ este corecta}\}$

$(\forall)x_0 \in X_0, \sum_{i=1}^6 x_{i_0} = M_6$  (2)  $X_0 - \overline{X_0} \neq \emptyset$

$(\forall)x'_0 \in X_0 - \overline{X_0}, PE_{p_1}(x'_0)$  nu este corecta

- *fuzzificare necorespunzatoare* - reprezinta o fuzzificare a universului de discurs care modifica semantica intrinseca a cunostintelor imprecise. Este atât o cauza calitativa cât si una cantitativa.

- *strategia de rezolvare a conflictelor (strat. rez. conflicte)* – strategia de rezolvare fuzzy a conflictelor este necorespunzatoare. Depinde de  $\eta, \varepsilon$  din schema de inferenta GMP (General Modus Ponens) conform lucrării [7].

- *filtrare* – se refera la filtrajul fuzzy (criteriul de similaritate notat CS). Dacă  $\Pi=1$  si  $N>0$  se considera ca regula satisface conditia de filtrare. Deci una din cauzele aparitiei unor manifestari poate fi o conditie de filtrare mai “severa”, conform relatiei (4):

$$\begin{cases} \Pi=1 \\ N > \varepsilon, \text{ pentru } \varepsilon > 0 \end{cases} \quad (3)$$

$CS(\Pi, N; \varepsilon_1)(\mathbf{m}_p, \mathbf{m}_D) > CS(\Pi, N; \varepsilon_2)(\mathbf{m}_p, \mathbf{m}_D)$ , unde  $> =$  “mai bun” daca  $\varepsilon_1 > \varepsilon_2$  (4)

*Manifestarile* (nivelul 2 al rețelei cauzale) sunt reprezentate de:

- *echilibrare necorespunzatoare* – echilibrare globala (la nivelul întregului sistem) necorespunzatoare.

- *ciclicitate*.

- *timp raspuns* – este manifestarea ce semnifica faptul ca timpul de raspuns este mai mare decât un timp impus (în cazul sistemului nostru se cuantifica prin numarul de inferente ale motorului de inferente al SEC), care difera de  $t$ :  $t_{\text{raspuns}} > t_{\text{impus}}$

- *gep<sub>i</sub>* – ( $i=1,5$ ) reprezinta grade de echilibrare partiala între grupurile de subsisteme (1,2,3,4), (1,2,4), (3,4,5,6), (1,3,4,5,6) si (2,4,5,6).

Sunt prezentate doua serii de teste pentru a explica cum sunt construite ipotezele si pentru a scoate în evidenta influenta probabilitatilor atasate cauzelor asupra probabilitatilor ipotezelor generate de algoritmul BIPARTIT.

- *SERIA -1*: se efectueaza teste pentru o serie de probabilitati.

- *SERIA -2*: se efectueaza teste pentru aceleasi manifestari observate dar probabilitatile atasate cauzelor se vor modifica:

- probabilitatea nerespectarii strategiei creste de la 0.4 la 0.5

- toate celelalte probabilitati atasate cauzelor devin 0.1

*Observatie*: Ipotezele generate vor fi aceleasi numai ca probabilitatile atasate lor vor avea valori diferite.

În tabelul urmator, avem observatiile:

‘ $\uparrow$ ’, ‘ $\downarrow$ ’ - ipoteza respectiva a crescut sau a scazut ca importanta în raport cu celelalte ipoteze. Dacă nu apare sageata înseamna ca ipoteza si-a pastrat importanta.

‘+’, ‘-’ - probabilitatea atasata ipotezei a

crescut sau a sczut fata de cea obtinuta la Seria 1 de teste. Neaparitia semnelor '+' sau '-' semnifica faptul ca probabilitatea ipotezei a ramas constanta.

Manifestari	Ipoteze (explicatii)	Probabilitati	
		Seria1	Seria2
<b>TEST1</b> {echil. necorep.}	{p2#p1} +	1-> 0.1493333333	1-> 0.2240000000
	{fuzzificare "proasta"} ∩ -	2-> 0.1225000000	3-> 0.0544444444
	{Sumaxi#M6} ∩ -	3-> 0.0988235294	2-> 0.0622222222
	{RIC}	4-> 0.0355555556	4-> 0.0355555556
	{strat. rez. conflicte} ∩	5-> 0.0120000000	6-> 0.0120000000
	{filtrare} ∩ +	6-> 0.0094736842	5-> 0.0200000000
<b>TEST2</b> {timp raspuns}	{p2#p1} +	1-> 0.0373333333	1-> 0.0560000000
	{RIC}	2-> 0.0133333333	2-> 0.0133333333
	{strat. rez. conflicte}	3-> 0.0053333333	3-> 0.0053333333
<b>TEST3</b> {echil. necorep., cicl i citate}	{Sumaxi#M6} ∩ -	1-> 0.0423529412	2-> 0.0266666667
	{p2#p1} ∩ +	2-> 0.0373333333	1-> 0.0560000000
<b>TEST4</b> {echil. necorep., gep_i}	{p2#p1} +	1-> 0.0640000000	1-> 0.0960000000
	{fuzzificare "proasta"} -	2-> 0.0525000000	2-> 0.0233333333
	{strat. rez. conflicte}	3-> 0.0080000000	3-> 0.0080000000
	{filtrare} +	4-> 0.0010526316	4-> 0.0022222222
<b>TEST5</b> {ciclicitate, timp raspuns}	{p2#p1} +	1-> 0.0093333333	1-> 0.0140000000
	{Sumaxi#M6, RIC} -	2-> 0.0001411765	2-> 0.0000888889
	{Sumaxi#M6, strat. rez. conflicte} -	3-> 0.0000564706	3-> 0.0000355556
<b>TEST6</b> {ciclicitate, gep_i}	{p2#p1} +	1-> 0.0040000000	1-> 0.0060000000
	{Sumaxi#M6, strat. rez. conflicte} -	2-> 0.0003388235	2-> 0.0002133333
	{Sumaxi#M6, fuzzificare "proasta"} -	3-> 0.0002382353	3-> 0.0000666667
	{Sumaxi#M6, filtrare} +	4-> 0.0000445820	4-> 0.0000592593
<b>TEST7</b> {timp raspuns, gep_i}	{p2#p1} +	1-> 0.0160000000	1-> 0.0240000000
	{strat. rez. conflicte}	2-> 0.0035555556	2-> 0.0035555556
	{RIC, fuzzificare "proasta"} -	3-> 0.0003000000	3-> 0.0001333333
	{RIC, filtrare} +	4-> 0.0000561404	4-> 0.0001185185
<b>TEST8</b> {ciclicitate, timp raspuns, gep_i}	{p2#p1} +	1-> 0.0040000000	1-> 0.0060000000
	{Sumaxi#M6, strat. rez. conflicte} -	2-> 0.0000376471	2-> 0.0000237037
	{Sumaxi#M6, RIC, fuzzificare "proasta"} -	3-> 0.0000031765	3-> 0.0000088889
	{Sumaxi#M6, RIC, filtrare} +	4-> 0.0000005944	4-> 0.0000007901

## Concluzii

Sistemul elaborat SIMHC simuleaza numai componenta de diagnoza dar include modelul hibrid de cunostinte aferent problemei de planificare considerate. Modelul de diagnoza implica entitati de diagnoza (dezordini, manifestari), asociatii cauzale ce leaga aceste entitati (retea cauzala), notiunea de explicatie a diagnosticului si rationamentul prin generare de ipoteze. Algoritmul lucreaza într-o maniera secventiala si constructiva, luând în considerare la un moment dat o unica manifestare si încorporând cauzele acesteia în ipotezele existente. Procesul continua pâna când toate manifestarile au fost incluse si procesate, iar timpul de învățare este mai mic sau egal cu

În. Astfel, sistemul de diagnoza primeste ca intrari un set de manifestari si furnizeaza iesiri care reprezinta explicatii referitoare la prezenta manifestarilor.

*Rezultatele testelor* pentru problema de învățare propusa si reprezentata prin modelul hibrid de cunostinte, utilizând diagnoza, pot fi caracterizate prin:

1. cea mai importanta cauza a majoritatii situatiilor de nerezolvare a problemei o reprezinta nerespectarea strategiei de planificare;
2. scaderea sau cresterea probabilitatilor atasate cauzelor influenteaza în acelasi sens importanta unei ipoteze în raport cu celelalte;
3. chiar daca probabilitatile unor ipoteze variaza în acelasi sens, ele pot creste sau scade

ca importanta dupa cum trendul lor este mai accentuat sau nu.

În raport cu structura de sistem de învățare propusa, se pot evidenta următoarele *concluzii*:

- sistemul de diagnoza lucreaza într-o maniera asemanatoare diagnosticianului uman (secvential si constructiv);
- învățarea este supravegheata, scopul acesteia fiind ca agentul uman sa asimileze cunostinte privind rezolvarea problemei de planificare, astfel încât acesta sa devina autonom;
- o limita este faptul ca închiderea buclei, în conformitate cu structura conceptuala a sistemului de învățare în bucla închisa, se face prin intermediul agentului care învata.

*Directii posibile de dezvoltare:*

- rafinarea modelului de cunostinte utilizat de sistemul de diagnoza atât prin cresterea numarului de niveluri ale grafului si numarului de noduri, cât si prin îmbunatatirea cunostintelor probabiliste;
- evaluarea cunostintelor capatate de agentul uman care învata si care preia rezultatele sistemului de diagnoza (feedback-ul performantei);
- dezvoltarea blocului de selectie a modelului de cunostinte utilizat de sistemul expert de conducere SEC (fiecare nou model de cunostinte selectat reprezinta o varianta îmbunatatita), care îndeplineste o functie de metaclassificator.

### **Bibliografie**

1. Antsaklis P.J., Lemmon M., Stiver J.A. (1996) “*Learning to Be Autonomous – Intelligent Supervisory Control*” in “Intelligent Control Systems – Theory and Applications” by Gupta M.M., Sinha N.K., IEEE Press
2. Caprita D., Mazilescu V. (2001) “*A Learning Hybrid System*”, The Annals of Dunarea de Jos University of Galati, Fascicle I, Economics, Year VII

3. Caprita D., Mazilescu V. (2002) “*Sequence Learning Applied for a Specific Decision Maker*”, Conferinta Internationala REC7, Galati, p. 630-637

4. Farrell J., Baker W. (1996) “*Learning Control Systems – Motivation and Implementation*” in “Intelligent Control Systems – Theory and Applications” Gupta M.M., Sinha N.K., IEEE Press

5. Kalman R.E., Falb P.L., Arbib M.A. (1969) “*Teoria sistemelor dinamice*”, Editura Tehnica, Bucuresti

6. Mazilescu V., Negoescu Gh. (2000) “*Sisteme expert fuzzy de conducere cu aplicatii în economie*”, Editura Didactica si Pedagogica, Bucuresti

7. Mazilescu V. (2001) “The Management of Fuzzy Knowledge in Planning Systems”, The Fifth International Symposium of Economic Informatics, Bucharest 10-13 May 2001, P.P. 967-977

8. Peng Y., Reggia A. (1990) “*Abductive Inference Models for Diagnostic Problem Solving*”, Springer-Verlag.

9. Pimentel J. “*Design of Net-learning Systems Based on Experiential Learning*” [www.aln.org/alnweb](http://www.aln.org/alnweb)