

METODE DE MODELARE A RATIONAMENTULUI NUANTAT

mat. Rolanda Predescu

Institutul de Cercetări în Informatică

Rezumat

Ambiguitatea, reflectată prin imprecizie semantică și incertitudine asupra valorii de adevăr, constituie o caracteristică inherentă și dominantă a cunoștințelor cu care oamenii operează în mod curent, în situațiile decizionale complexe.

Modelarea raționamentelor, efectuate în condiții de ambiguitate constituie subiectul lucrării de față.

Această problematică devine de interes major în realizarea sistemelor de inteligență artificială actuale.

În lucrare sunt prezentate modelele pentru următoarele tipuri de raționament:

- cu premize incerte, în cadrul logicii polivalente;
- cu premize imprecise, unice sau multiple, conform modelului "modus ponens generalizat", introdus de Zadeh /12/;
- cu premize imprecise și incerte, conform modelului introdus de Yager /9/.

O extenzie particulară a modelului Yager, propusă în /7/, constituie suportul teoretic pentru o componentă de bază a mecanismului informațional, implementat în sistemul DECAM, pe care autoarea îl realizează în prezent.

Sistemul DECAM, scris în GC-Lisp, pe calculatoare compatibile IBM-PC/AT, este dedicat prelucrării cunoștințelor de natură ambiguă.

1. Introducere

Un obiectiv major al cercetării desfășurate în domeniul inteligenței artificiale, îl constituie realizarea de sisteme expert capabile să trateze cunoștințe imprecise (neclare) și incerte, provenind din mai multe surse, în vederea determinării unei soluții apreciate ca optime, la problemele propuse spre rezolvare. Atributul de optim se referă la obținerea unei soluții cu grad maxim de credibilitate și plauzibilitate, în condițiile de ambiguitate date.

Ambiguitatea, reflectată prin imprecizie și incertitudine, constituie o caracteristică inherentă și dominantă a cunoștințelor cu care oamenii operează în mod curent, în situațiile decizionale cele mai complexe, în care sunt implicate surse de informație și criterii multiple.

Imprecizia unui enunț este legată de natura sa semantică și provine, în general, din imposibilitatea de a defini în mod clar corespondența între obiectul referit și valoarea unui atribut al său, ale cărui valori sunt cuprinse pe o scală. Acest impas este depășit în mod natural de către oameni, prin exprimarea în termeni vagi, utilizând atât în situațiile neclare, de cunoaștere incompletă, cât și în situațiile de complexitate excesivă, datorată unei multitudini de detalii redate aproximativ.

Incidentudinea constă în imposibilitatea de a stabili exact valoarea de adevăr a unui enunț. Ea este caracteristică situațiilor deductive, în care se departajează două spații distincte: cel al enunțurilor considerate ca premize cu grad de evidență (certitudine) cunoscut și cel al enunțurilor considerate ca ipoteze, care pot fi mai mult sau mai puțin confirmate. Nivelul de confirmare corespunde gradului de incertitudine.

Efectuarea de raționamente în condiții de ambiguitate, uzuale la nivel uman, ridică probleme dificile de modelare la nivel formal. Pentru multă vreme atenția a fost orientată exclusiv spre incertitudine, modelul de referință acceptat fiind cel Bayesian.

În lucrarea de față sunt prezentate orientările actuale, detășate de această abordare.

Tratarea impreciziei poate fi considerată o abordare relativ recentă, datorată lui Zadeh, care a introdus ca model pentru conceptele imprecise mulțimile vagi, iar ulterior, ca model echivalent, dar cu perspective mai largi, distribuțiile de posibilități (par. 2.1).

În tratarea incertitudinii, ca alternativă la modelul Bayesian, au apărut:

- teoria posibilității, introdusă de Zadeh conform căreia incertitudinea este tratată sub aspect calitativ, stabilindu-se măsurile de posibilitate și necesitate asociate unui enunț, ca limite ale compatibilității acestuia cu premizele din care derivă (par. 2.3);
- teoria Dempster-Shafer a credibilității, în care incertitudinea este tratată cantitativ, probabilitatea unui enunț fiind definită de două limite: credibilitatea și plauzibilitatea ce-i pot fi asociate (par. 2.4).

În acest context a fost posibilă adaptarea modelului clasic de raționament, de tip modus ponens, la cerințele impuse de existența premizelor imprecise și incerte, care conduce la obținerea unor concluzii de aceeași natură.

Dintre sistemele realizate pe plan mondial, bazate pe această categorie de modele de raționament, menționăm ca reprezentative: CADIG și DIABETO-III, pentru diagnoză medicală și SPERIL-II, pentru diagnoză tehnică /14/.

În articol sunt prezentate modelele pentru următoarele tipuri de raționament:

- cu premize incerte, în cadrul logicii polivalente (par. 2.1);
- cu premize imprecise, unice sau multiple, conform modelului de referință "modus ponens generalizat", introdus de Zadeh (par. 3.2);
- cu premize imprecise și incerte, conform modelului Yager și unei extensiuni a acestuia, propusă în /7/ (par. 3.3).

2. Noțiuni preliminare

2.1. Multimi vagi și distribuții de posibilități

O submulțime vagă a unui univers S este generată de un concept (sau un eveniment), care se reflectă asupra universului S.

Acesta poate fi enunțat printr-o propoziție p de forma "X este A", în care A este un predicat vag. Submulțimea vagă indușă de A, pe care o vom nota cu A, este definită de o funcție de apartenență VA: S → [0,1], unde VA(s) exprimă gradul de compatibilitate dintre conceptul A și elementul s /10/.

Pe de altă parte, p limitează valorile pe care le poate lua variabila X în universul S. În acest sens, VA(s) se interpretează ca fiind posibilitatea ca propoziția ps = "X este s" să fie adevărată (X să coincidă cu s), în contextul "X este A". În consecință, "X este A" induce o distribuție de posibilități PX: S → [0,1], definită prin $PX(s) = VA(s)$ /13/.

Distribuția de posibilități, respectiv mulțimea vagă se numește normalizată, dacă există s în S a.î. $PX(s) = VA(s) = 1$.

2.2. Operatori conjunctivi și disjunctivi

Metoda folosită pentru evaluarea implicației este determinantă în stabilirea rezultatului inferenței deductive. Implicația este înțeleasă ca operație de tip conjunctiv sau disjunctiv între premiză și concluzie sau transformate ale acestora.

Operatorii conjunctivi și disjunctivi folosiți în modelarea implicației fac parte din categoria normelor, respectiv co-normelor triunghiulare.

Ca operator de transformare este folosit operatorul negație.

Principalele norme, în ordine crescătoare sunt:
 $\max(0, a+b-1) \leq a \cdot b \leq \min(a, b)$

Principalele co-norme, în ordine crescătoare sunt:
 $\max(a, b) \leq a + b - a \cdot b \leq \min(1, a+b)$

2.3. Măsuri de posibilitate și necesitate

Considerate în sens larg, operațiile de inferență crează o departajare a elementelor asupra cărora se aplică, în două spații distincte: un spațiu E, de fapte relativ evidente, cu grad de evidență cunoscut și un spațiu H, de ipoteze, care pot fi mai mult sau mai puțin confirmate, pe baza elementelor din E. Această departajare este valabilă în egală măsură, în cazul cunoștințelor cu care operează sistemele expert /1,4,7/. Măsurile de posibilitate și necesitate, asociate ipotezelor din H reflectă starea lor de (in)certitudine sub aspect "semantic", în sensul în(compatibilității) lor, în raport cu evidențele din E.

Considerind o ipoteză H1 exprimată printr-un predicat

vag B peste un univers S, deci în forma "X este B", starea de incertitudine prin care se caracterizează H1 nu se mai definește printr-o singură valoare, de natură probabilistă, ci se plasează între două limite: una superioară, care redă posibilitatea Pos și una inferioară, care redă necesitatea N, ca H1 să fie adevărată /13/. Pentru distribuția de posibilități generată de B, ca predicat vag se poate aprecia o măsură globală, în sens "absolut" a posibilității lui B:

$$Pos(B) = \max_s PX(s) = \max_s VA(s)$$

știind că pentru orice s din S, $Pos(\{s\}) = PX(s) = VB(s)$.

Măsura duală a necesității, se calculează prin complementarea posibilității de a se produce contrariul lui B:

$$N(B) = 1 - Pos(_B)$$

Sunt satisfăcute următoarele proprietăți:

$$Pos(B) \geq N(B); Pos(B) < 1 \rightarrow N(B) = 0; N(B) > 0 \rightarrow Pos(B) = 1$$

Măsura în care o evidență E1 = "X este A", redată printr-un predicat vag peste universul S, influențează certitudinea unei ipoteze H1, relativă la același univers, este exprimată sub forma posibilității și necesității condiționale:

$$\begin{aligned} Pos(B/A) &= \max_s \min(VB(s), PX(s)) = \max_s \\ &\min(VB(s), VA(s)) \\ N(B/A) &= 1 - Pos(_B/A) = \min_s \max(VB(s), 1 - PX(s)) \\ &= \min_s \max(VB(s), 1 - VA(s)) \end{aligned}$$

2.4. Măsuri de credibilitate și plauzibilitate

Starea de (in)certitudine a ipotezelor din H se poate aprecia și prin gradul de (ne)încredere care li se poate asocia, ca urmare directă a gradului de evidență al elementelor din E.

În teoria dezvoltată de Dempster /2/ și Shafer /8/ se stabilește ca gradul de evidență în E să fie reflectat printr-o distribuție de probabilități. În același timp dependența ipotezelor din H de premizele din E este definită printr-o aplicație multivalentă EH: E → Par(H), unde Par(H) reprezintă mulțimea părților lui H. EH face posibilă atribuirea unei "probabilități de bază" (mase), m: Par(H) → [0,1], în interiorul lui H, astfel încât masa mulțimii vide este 0, iar

$$\text{Sum}_{A \text{ inclus în } H} m(A) = 1$$

unde Sum este simbol al sumei.

Subseturile A din H, cu proprietatea $m(A) > 0$ sunt numite elemente focale. În aceste condiții, nivelul de încredere asociat unei ipoteze B din H este determinat printr-o limită inferioară, numită credibilitate și o limită superioară, numită plauzibilitate. Ambele sunt definite ca funcții cu domeniul Par(H).

Credibilitatea unei ipoteze se obține prin însumarea maselor faptelor care o susțin (din care derivă):

$$Cr(F) = \text{Sum}_{A \text{ inclus în } F} m(A)$$

Plauzibilitatea se obține însumând masele elementelor focale care nu pot genera contrariul acelei ipoteze:

$$PI(F) = \sum_{A \text{ intersecează } F} m(A) = 1 - Cr(F)$$

Sunt satisfăcute următoarele proprietăți:

$$Cr(F) + Cr(\neg F) \leq 1, PI(F) + PI(\neg F) \geq 1,$$

$$Cr(F) \leq PI(F)$$

Pentru cazul ipotezelor imprecise(vagi), credibilitatea și plauzibilitatea au fost definite în [9], prin:

$$Cr(F) = \sum_i m(A_i) \times N(F/A_i)$$

$$PI(F) = \sum_i m(A_i) \times Pos(F/A_i)$$

unde A_i sunt acele elemente focale care fac pe F necesar și posibil.

3. Modelarea raționamentului nuanțat

3.1. Inferențe deductive cu premize incerte

Regula principală de inferență în logica clasică este modus ponens: $(p \text{ și } p \rightarrow q) \rightarrow q$, unde p și q sunt propoziții.

Considerăm cazul în care p și q nu sunt imprecise(vagi), dar au un statut de incertitudine, exprimat prin asocierea unor valori (grade) de adevăr, respectiv $v(p)$, $v(q)$ situate în $[0,1]$.

Un cadru adecvat de extindere a modelului modus ponens pentru tratarea acestui caz îl constituie logica polivalentă.

În acest context evaluarea implicației, deci stabilirea gradului de adevăr al relației dintre premiză și concluzie, se face printr-o funcție f a gradelor de adevăr ale acestora:

$$v(p \rightarrow q) = f(v(p), v(q))$$

Pentru compunerea lui $v(p)$ cu $v(q)$ prin normele prezentate în paragraful 1.2. se obțin următoarele tipuri de implicații:

$$\min(v(p), v(q))$$

- implicația Gödel:

$$v(p \rightarrow q) = \begin{cases} 1, & v(p) \leq v(q) \\ v(q), & \text{în rest} \end{cases}$$

- implicația Dienes:

$$v(p \rightarrow q) = \max(1 - v(p), v(q))$$

$$v(p) \cdot v(q);$$

- implicația Goguen:

$$v(p \rightarrow q) = \begin{cases} 1, & v(p) = 0 \\ \min(1, v(p)/v(q)), & \text{în rest} \end{cases}$$

- implicația probabilistă:

$$v(p \rightarrow q) = 1 - v(p) + v(p) \cdot v(q)$$

$$\max(0, v(p) + v(q) - 1);$$

- implicația Lukasiewicz:

$$v(p \rightarrow q) = \min(1, 1 - v(p) + v(q))$$

Modelul Lukasiewicz reprezintă, în general, alegera cea mai sigură [6] pentru evaluarea rezultatului inferențelor deductive cu premize incerte.

3.2. Inferențe deductive cu premize imprecise

Situată în care premizele sunt imprecise corespunde unor implicații de formă $R = "dacă X este F atunci Y este G"$, unde F și G sunt predicate vagi, care determină

distribuții de valori posibile ale variabilelor X și Y peste două universuri S și T , respectiv $PX(s) = VF(s)$ și $PY(t) = VG(t)$.

În această situație, valoarea de adevăr a implicației R este redată printr-o distribuție de posibilități condițională $P-Y/X(t,s) = VR(t,s)$, prin care se restricționează valorile pe care le poate lua Y în funcție de X .

În funcție de tipul de operator conjunctiv folosit în relația dintre premiză și concluzie, rezultă următoarele valori ale implicației:

- $\min(VF(s), VG(t))$:

$$VR1(t,s) = \begin{cases} 1, & VF(s) \leq VG(t) \\ VG(t), & \text{în rest} \end{cases}$$

- $VF(s) \cdot VG(t)$:

$$VR2(t,s) = \begin{cases} 1, & VF(s) = 0 \\ \min(1, VG(t)/VF(s)), & \text{în rest} \end{cases}$$

- $\max(0, VF(s) + VG(t) - 1)$

$$VR3(t,s) = \min(1, 1 - VF(s) + VG(t))$$

Cele trei valori ale implicației sunt ordonate astfel:

$$VR3(t,s) \geq VR2(t,s) \geq VR1(t,s)$$

Modelul de raționament de tip modus ponens adecvat existenței premizelor imprecise a fost introdus de Zadeh [12] sub numele de modus ponens generalizat sau raționament aproximativ și are următoarea reprezentare:

$$X \text{ este } F \rightarrow Y \text{ este } G$$

$$X \text{ este } F'$$

$$\underline{Y \text{ este } G'}$$

Se presupune că F' este normalizată. Distribuția de posibilități $VG' = PY$, corespunzătoare concluziei finale se calculează prin formula:

$$VG'(t) = \sup_s \min(VF'(s), VR(t,s))$$

Pentru VR este de preferat alegerea lui $VR3$, întrucât reprezintă conexiunea cea mai puternică între F și G , cu nivelul de precizie cel mai ridicat.

În cazul regulilor cu premize multiple conjunctive, de forma "dacă $\wedge^i (X \text{ este } F_i)$ atunci $Y \text{ este } G'$ " agregarea se face prin operatorul max:

$$VG'(t) = \max_i VG'(i,t)$$

unde $VG'(i,t) = \sup_s \min(VF'(i,s), VR_i(t,s))$.

În mod dual, pentru premize disjunctive, concluzia finală G' se definește prin:

$$VG'(t) = \min_i VG'(i,t)$$

3.3. Inferențe deductive cu premize imprecise și incerte

Să considerăm cazul regulilor cu premize multiple conjunctive, în care premizele " X este F_i " sunt reprezentate prin distribuții de posibilități $PX_i = VF_i$, iar F_i au mase cunoscute $m(F_i)$. În aceste condiții, concluzia finală G' , obținută în urma aplicării inferenței deductive, se va caracteriza prin distribuția $PY = VG'$, calculată conform modelului modus ponens generalizat. În privința stării de incertitudine, aceasta se va caracteriza prin credibilitatea și plauzibilitatea

induse asupra lui G' de premizele F_i . Conform modelului Yager, vom avea:

$$Cr(G') = \sum_i m(F_i) \times N(G'/F_i)$$

$$Pl(G') = \sum_i m(F_i) \times Pos(G'/F_i)$$

Modelul construit de autori în [7] folosește în locul lui $m(F)$, donă valori generice $cr(F_i)$ și respectiv $pl(F_i)$, rezultând:

$$Cr(G') = \sum_i cr(F_i) \times N(G'/F_i)$$

$$Pl(G') = \sum_i pl(F_i) \times Pos(G'/F_i)$$

În [7] se consideră că inferențele deductive se desfășoară într-un spațiu de opinii eterogen, în care se definesc trei categorii de fapte: complet suportate, parțial ipotetice și complet ipotetice. Pentru fiecare categorie se determină moduri specifice de a evalua cr și pl , descrise pe larg în [7].

4. Concluzii

Modelele de raționament prezentate au fost implementate prin programe care constituie componente ale sistemului DECAM.

Principalele obiective urmărite în perspectivă, în vederea realizării și experimentării sistemului DECAM sunt următoarele:

- definirea și implementarea operatorilor de agregare și stabilizare a cunoștințelor imprecise relative la același domeniu;
- definirea și implementarea metodelor de determinare a unei soluții apreciate ca optimă, deci cu nivel maxim de credibilitate și plauzibilitate, în condițiile de ambiguitate date;
- realizarea unei aplicații reprezentative.

Rezultatele obținute, pe măsura atingerii obiectivelor menționate, urmează să fie prezentate prin contribuții ulterioare în cadrul revistei.

Bibliografie

1. BONNISSONNE, P.B., TONG, R.M.: *Reasoning with Uncertainty in Expert Systems*. In: J. Man-Mach. Studies, vol. 22, 1985, pp. 241-250.
2. DEMPSTER A.P.: *Upper and Lower Probabilities Induced by a Multi-valued Mapping*. In: Ann. Math. Stat., vol. 38, 1967, pp. 325-339.
3. DUBOIS D., PRADE H.: *Fuzzy Logics and the Generalized Modus Ponens Revisited*. In: Cybern Syst., vol. 15, 1984, pp. 87-125.
4. DUBOIS D., PRADE H.: *Handling Uncertainty in Expert Systems*, Seminar on Safety and Risk in the Use of Exp. Systems, Copenhagen, 1988.
5. PRADE, H.: *Modèles mathématiques de l'imprécis et de l'incertain en vue d'applications au raisonnement naturel*. Thèse d'Etat. Univ. P. Sabatier, Toulouse, 1982.
6. PRADE H.: *Computational Approach to Approximate and Plausible Reasoning*. In: PAMI, vol. 7, nr. 3, 1985.
7. PREDESCU, R., HOTĂRAN, A.: *Gradual Aggregation of Hypotheses within Imprecise and Uncertain Environments*. 4-th World Congress Int. Fuzzy Syst. Assoc. IFSA'91, Bruxelles, 1991.
8. SHAFER, G.: *A Mathematical Theory of Evidence*. Princeton Univ. Press, 1976.
9. YAGER, R.R.: *An approach to Inference in Approximate Reasoning*. In: Int. J. Man-Machine Studies, vol. 13, 1980, pp. 323-338.
10. ZADEH, L.A.: *Fuzzy Sets*. In: Inform. Control, vol. 8, 1965, pp. 338-353.
11. ZADEH, L.A.: *Similarity Relations and Fuzzy Orderings*. In: Inform. Sci., vol. 3, pp. 177-200, 1971.
12. ZADEH, L.A.: *A Theory of Approximate Reasoning*, Machine Intelligence, vol. 9, 1977, pp. 149-194.
13. ZADEH L.A.: *Fuzzy Sets as a Basis for a Theory of Possibility*. In: Fuzzy Sets Syst., vol. 1, nr. 1, 1978.
14. ZIMMERMANN, H.J.: *Fuzzy Sets Decision Making and Expert Systems*, Kluwer, 1987.