

On the Handling of Uncertainty

Nicolae MĂRGINEAN

Facultatea de Științe Economice, Universitatea "Babeș-Bolyai" Cluj-Napoca

The principal aim of this article is to present shortly the main existent approaches of uncertainty used generally in computer systems, especially in expert systems. The natures of uncertainty determine what theory is useful in every case. I remind here about the probability theory in case of objective uncertainty, possibility theory and evidence theory in case of subjective uncertainty and fuzzy theory in case of vagueness of linguistic terms. Also, in many points of article I emphasize the main difference between presented theories.

Keywords: fuzzy set, evidence, possibility, probability, necessity, plausibility, consistence, belief.

Introducere

De-a lungul timpului s-a observat că realitatea și în general cunoașterea umană este incertă, și aceasta din cauza unei game variate de surse de incertitudine: ambiguitate, incompletitudine, incorectitudine, imprecizie, comportamente aleatoare etc. Soluționarea unor probleme învăluite de incertitudine impune folosirea cunoștințelor incerte, emularea gândirii umane prin intermediul unui sistem informatic impune dezvoltarea unor metode inferențiale incerte și inexacte.

Incetitudinea poate prezenta mai multe fațete. Ne putem confrunta cu așa numita incertitudine aleatoare ce rezultă din faptul că un sistem poate avea un comportament aleator. O mai întâlnim și sub denumirea de incertitudine stohastică sau incertitudine obiectivă. De asemenea reîntâlnim în viața reală și așa numita incertitudine epistemică sau subiectivă, datorată lipsei de informații despre un sistem de evenimente. În plus, chiar dacă nu ne confruntăm cu o lipsă de informație, o situație de incertitudine poate apărea datorită semanticii vagi sau ambigui a unor concepte.

2. Metodologie

2.1 Incertitudinea stohastică

Incetitudinea stohastică poate fi modelată foarte ușor cu ajutorul teoriei probabilităților bayesiene, teorie aplicabilă în acele situații în care evenimentele sunt bine precizate dar apariția lor este incertă din cauza lipsei de informație. Interesul privind calculul probabilităților în sistemele expert a crescut mult după

succesul remarcabil obținut în sistemul MYCIN.

Probabilitatea unui eveniment este un număr bine determinat, ce caracterizează șansa de realizare a unui eveniment. Câteva proprietăți ar fi următoarele:

$$P(0)=0;$$

$$0 \leq P(A) \leq 1$$

$\sum P(A_i)=1$ unde $A_1 \dots A_n$ un sistem complet de evenimente

$$P(\neg A)=1-P(A)$$

$P(A \cup B)=P(A)+P(B)-P(A \cap B)$ (formula lui Poincare)

$P(B/A)=P(A \cap B)/P(A)$ unde $P(B/A)$ este probabilitatea condiționată a lui B față de A. Dacă evenimentele sunt independente atunci

$$P(A \cap B)=P(A) \cdot P(B)$$

Inegalitatea lui Boole

$$P(A_1 \cap A_2 \dots A_n) \geq P(A_1)+P(A_2) \dots +P(A_n) - (n-1)$$

Formula probabilității totale

Dacă $A_1, A_2 \dots A_n$ este un sistem complet de evenimente și X un eveniment oarecare atunci

$$P(X)=P(A_1) \cdot P(X/A_1) + \dots + P(A_n) \cdot P(X/A_n)$$

Formula lui Bayes

Dacă $A_1, A_2 \dots A_n$ este un sistem complet de evenimente și X unul dintre acestea atunci

$$P(A_j/X) = (P(A_j) \cdot P(X/A_j)) / P(X).$$

Într-o regulă de producție IF A THEN B, fiind cunoscută probabilitatea $P(A)$, cu ajutorul regulii bayesiene putem identifica probabilitatea concluziei, data de valoarea lui $P(B/A)$.

2.2 Incertitudinea epistemică

În cazul incertitudinii subiective, probabilitățile nu mai pot fi aplicate din cauza lipsei de informații. Prin urmare, s-a încercat dezvoltarea altor teorii care să modeleze incertitudinea epistemică. Printre acestea se numără și teoria posibilității și teoria evidenței.

O prima abordare a incertitudinii epistemice o reprezintă teoria posibilității, prezentată pentru prima dată de Lotfi Zadeh, părintele mulțimilor fuzzy. Unul dintre conceptele principale ale teoriei posibilității este distribuția acesteia. Punctul de plecare l-a reprezentat noțiunea de restricție fuzzy. Pentru a înțelege ce este aceasta, să ne imaginăm un geamantan cu pereți elastici și unul inelastic. Pentru cel cu pereți tari, volumul acestuia este o valoare unică, bine stabilită. Pentru cel cu pereți elastici, volumul depinde de gradul de înghesuire al obiectelor în acesta. Acest grad de înghesuire poate fi foarte bine reprezentat de o funcție similară funcției de apartenență a unei mulțimi fuzzy. Astfel distribuția posibilității (D_{pos}) va fi numeric egală cu funcția de apartenență a unei mulțimi fuzzy (restricție fuzzy), având însă o interpretare diferită.

$D_{pos}: L \rightarrow [0,1]$

Dacă $D_{pos}(x)=0$ x este imposibil

Dacă $D_{pos}(x)=1$ x este cu certitudine posibil

Să luăm următorul exemplu. "Ion este tânăr".

În teoria mulțimilor fuzzy, gradul de apartenență este interpretat ca un grad de compatibilitate a vârstei lui Ion cu conceptul tânăr. În teoria posibilității, gradul de apartenență devine gradul posibilității ca Ion să fie tânăr.

Pentru a ilustra diferența dintre distribuția posibilității și distribuția probabilității, Zadeh ne oferă un exemplu foarte concludent. "Hans mănâncă x ouă la micul dejun. Distribuția posibilității poate fi interpretată ca o măsură a ușurinței cu care Hans mănâncă x ouă, în timp ce distribuția probabilității se obține în urma observării lui Hans la micul dejun, într-o anumită perioadă de timp, în scopul surprinderii frecvenței cu care Hans mănâncă x ouă.

Datorită faptului că distribuția posibilității nu ne oferă o situație completă a incertitudinii, s-a încercat introducerea unor măsuri mai

sintetice. Astfel, măsura posibilității este cea care măsoară gradul de consistență sau de plauzibilitate a unui set de evenimente și este dat de $P: X \rightarrow [0,1]$ unde $P = \max(D_{pos}(x))$. Aceasta prezintă mai multe proprietăți:

$$P(0)=0; P(1)=1;$$

$$P(A \cup B) = \max(P(A), P(B)),$$

$$P(A \cap B) < \min(P(A), P(B)).$$

Măsura duală a măsurii posibilității este măsura necesității care măsoară gradul de certitudine sau de siguranță a unui anumit set de evenimente. Ea este dată de funcția $N: X \rightarrow [0,1]$ unde $N(A) = 1 - P(\neg A)$.

Alte proprietăți ale acesteia:

$$N(A \cap B) = \min(N(A), N(B))$$

$$N(A \cup B) > \max(N(A), N(B))$$

$$\min(N(A), N(\neg A)) = 0$$

$$P(A) > N(A)$$

$$\text{Dacă } N(A) > 0, \rightarrow P(A) = 1$$

$$P(A) < 1, \rightarrow N(A) = 0$$

Măsura de necesitate și măsura de posibilitate se comportă ca limite ale unui interval în care ar fi conținută probabilitatea lui A . De aceea se mai spune că noțiunea de posibilitate este o generalizare a noțiunii de probabilitate. Există chiar și metode prin care se poate face trecerea de la posibilități spre probabilități și invers. De exemplu, pentru trecerea de la posibilități la probabilități se poate aplica "Principiul raționării incomplete" a lui Laplace.

Incertitudinea, în teoria posibilității, poate fi reprezentată și cu ajutorul unui indicator ce ia valori în intervalul $[0, 1]$. Astfel, fiecare cunoștință incertă este reprezentată sub forma unui tuplu (p, a) , unde p este cea cunoștință iar a este un indicator ce poate avea mai multe interpretări. Fie reprezintă limita minimă a gradului de certitudine a acelei cunoștințe $N(p) > a$, fie este doar un indicator de prioritate al acelei cunoștințe, util în operații de ordonare.

O modalitate de raționament în teoria posibilității ar fi adaptarea lui "modus ponens". Astfel, o generalizare posibilă a lui modus ponens, care ne oferă posibilitatea și necesitatea lui B , cunoscându-le pe cele a lui A și $A \rightarrow B$, poate fi următoarea:

$$\text{Dacă } P(A \rightarrow B) \geq a$$

$$N(A \rightarrow B) \geq b$$

$$P(A) \geq c$$

$$N(A) \geq d$$

Atunci $P(B) \geq \max(a \cdot v(a+d), c \cdot v(b+c))$
 $N(B) \geq \min(d, b)$

Unde $v(x) = 1$ dacă $x > 1$
 0 dacă $x \leq 1$

O altă abordare a incertitudinii epistemice este cea reîntâlnită în teoria evidenței lui Dempster și Shafer. Această teorie este o extindere a teoriei probabilității, în care probabilitatea nu mai este asociată doar unui singur eveniment, ci unui set de evenimente. Cu alte cuvinte, analizăm un eveniment prin intermediul subevenimentelor componente. De asemenea, după cum am mai amintit, incertitudinea este caracterizată de un interval de valori și nu doar de o anumită valoare.

Există trei funcții importante în teoria evidenței: funcția probabilității de bază (bpa), funcția de încredere (bel) și funcția de plauzibilitate (pl).

Funcția probabilității de bază nu se referă la o probabilitate în sensul clasic. Ea este o funcție definită pe mulțimea părților unei mulțimi cu valori în intervalul [0,1]

$$m: P(X) \rightarrow [0,1]$$

$$m(\emptyset) = 0$$

$$\sum m(A) = 1 \text{ unde } A \in P(X)$$

ce caracterizează evidența cu care putem afirma că un element din X face parte dintr-o anumită submulțime A.

Pornind de la bpa, putem determina cele două limite care caracterizează incertitudinea unei cunoștințe.

Limita inferioară este dată de funcția de încredere. Aceasta reprezintă suma evidențelor tuturor submulțimilor unei mulțimi.

$$Bel(A) = \sum_{B|B \subseteq A} m(B)$$

Limita superioară a acestui interval este dată de funcția de plauzibilitate, având ca formulă de calcul

$$Pl(A) = \sum_{B|B \cap A \neq \emptyset} m(B)$$

În plus, cele două măsuri pot deriva una din cealaltă.

$$Pl(A) = 1 - Bel(\neg A)$$

unde $\neg A$ este complementul clasic al unei mulțimi A.

$$Bel(\neg A) = \sum_{B|B \cap A = \emptyset} m(B)$$

Și-n acest caz, cele două limite, Bel și Pl pot reprezenta limitele inferioară, respectiv superioară a probabilităților clasice.

În ceea ce privește inferența, în teoria evidenței se aplică regula combinațională a lui Dempster. Originea acestei reguli o reprezintă formula lui Bayes. Măsurile rezultatelor inferențiale, încrederea și plauzibilitatea vor fi calculate pe baza probabilităților primare.

Probabilitatea primară asignată unei combinații a două seturi de evenimente independente B și C este dată de formula

$$m_{1,2}(A) = \frac{\sum_{B \cap C = A} m_1(B) m_2(C)}{1 - K}$$

unde $K = \sum_{B \cap C = \emptyset} m_1(B) m_2(C)$, K este un factor

de normalizare care are rolul evitării conflictelor dintre evidențe.

Exemplu:

$$m_1(\{D\}) = 0.8, m_1(\{D'\}) = 0, m_1(\{D, D'\}) = 0.2$$

$$m_2(\{D\}) = 0.9, m_2(\{D'\}) = 0, m_2(\{D, D'\}) = 0.1$$

| | M2 | {D} | {D'} | {D,D'} |
|--------|-----|------|------|--------|
| m1 | | 0.9 | 0 | 0.1 |
| {D} | 0.8 | 0.72 | 0 | 0.08 |
| {D'} | 0 | 0 | 0 | 0 |
| {D,D'} | 0.2 | 0.18 | 0 | 0.2 |

$$(2 \text{ cazuri } X \cap Y = \emptyset, m_1(\{D\}) \cap m_2(\{D'\})$$

$$m_1(\{D'\}) \cap m_2(\{D\})$$

$$K = 1 - 0 - 0 = 1$$

$$m_1 \circ m_2(\{D\}) = 1 \cdot (0.72 + 0.08 + 0.18) = 0.98$$

$$m_1 \circ m_2(\{D'\}) = 1 \cdot 0 = 0$$

$$m_1 \circ m_2(\{D, D'\}) = 1 \cdot 0.02 = 0.02$$

Modelarea incertitudinii unei reguli de producție IF B THEN A va fi realizată printr-o probabilitate primară condiționată. Aceasta nu este altceva decât un caz special al aplicării regulii lui Dempster. Astfel probabilitatea primară a lui A va fi calculată cu următoarea

formulă: $m_B(A) = \frac{\sum_{C \cap B = A} m(C)}{\sum_{C \cap B \neq \emptyset} m(C)}$

sau, cu ajutorul indicatorilor de încredere,

$$Bel_B(A) = \frac{Bel(A \cap \bar{B}) - Bel(\bar{B})}{1 - Bel(\bar{B})}$$

În cazul în care apar situații caracterizate de un număr mare de informații conflictuale, regula lui Dempster trebuie ajustată, rezultatele nemaifiind elocvente. O serie de cercetători au încercat modificarea regulii combinaționale a lui Dempster, printre care îi amintim pe Yager, Inagaki, Zhang, Dubois, Prade. Pentru exemplificare, vom aminti regula modificată a lui Yager. Acesta face o distincție clară între probabilitatea primară m și ceea ce el numește probabilitatea de fond, notată cu q . Probabilitatea de fond combinată ar fi următoarea

$$q(A) = \sum_{B \cap C = A} m_1(B)m_2(C)$$

De remarcat ca dispare factorul de normalizare K . Dacă la Dempster, $m(0)=0$, la Yager $q(0) \geq 0$, unde $q(0)$ are ca formulă de calcul, cea a lui K din regula lui Dempster, fiind denumit gradul de ignoranță. Astfel probabilitatea primară a lui Yager la nivel de subset este numeric egală cu probabilitatea de fond, dar în schimb la nivel de set universal probabilitatea primară se calculează în felul următor: $m'(X)=q(X)+q(0)$. Se observă faptul că normalizarea nu se mai face la nivel de subset, ci doar la nivel de set universal.

Trebuie să reținem că probabilitatea primară a lui Dempster nu este același lucru cu probabilitatea primară a lui Yager. Dacă la Yager, $m(A)=q(A)$, la Dempster $m(A)=q(A)/1-q(0)$.

$$R1 \circ R2 = \{(x, z), \max(\min(\mu_{R1}(x, y), \mu_{R2}(y, z))) | x \in X, y \in Y, z \in Z\}$$

Dacă $R1(x, y), (x, y)$ în $X \times Y$ și $R2(y, z), (y, z)$ în $Y \times Z$ sunt două relații fuzzy atunci Unul din instrumentele de bază ale logicii fuzzy și raționamentului aproximativ îl reprezintă variabila lingvistică.

O variabila lingvistica este un quintuplu (x, T, G, U, M) unde

1. x este numele variabilei lingvistice
2. T este mulțimea valorilor lingvistice ale

2.3 Ambiguitatea termenilor lingvistici

Să prezentăm în cele ce urmează, modalitatea de modelare a incertitudinii determinată de ambiguitatea unor termeni lingvistici.

Logica fuzzy se dorește a fi o extindere naturală a logicii booleene, în sensul introducerii unei infinități de valori de adevăr între fals și adevărat, valori de adevăr exprimate cu ajutorul unui număr real din intervalul $[0,1]$. A fost fundamentată teoretic de către Lotfi Zadeh.

Dacă X este o colecție de obiecte, atunci o mulțime fuzzy este o mulțime de perechi ordonate:

$$A = \{(x, \mu(x)) | x \in X\}$$

unde $\mu: X \rightarrow [0,1]$ poartă denumirea de funcție de apartenență a lui x în A . Valoarea 1 semnifică apartenență totală în timp ce valoarea 0 semnifică neapartenența.

Logica fuzzy este o extindere a logicii clasice booleene, așa încât vom regăsi toate operațiile principale AND, OR, NOT.

$$\mu_{A \text{ AND } B} = \max(\mu_A, \mu_B)$$

$$\mu_{A \text{ OR } B} = \min(\mu_A, \mu_B)$$

$$\mu_{\text{NOT } A} = 1 - \mu_A$$

Relațiile fuzzy sunt submulțimi fuzzy de $X \times Y$. Dacă X, Y în R , atunci

$Rel = \{(x, y), \mu_{rel}(x, y) | (x, y) \in X \times Y\}$ se numește relație fuzzy pe $X \times Y$.

Dacă R și Z sunt două relații având același univers al discursului, atunci

$$\mu_{R \cup Z}(x, y) = \max(\mu_R(x, y), \mu_Z(x, y))$$

$$\mu_{R \cap Z}(x, y) = \min(\mu_R(x, y), \mu_Z(x, y))$$

Relațiile fuzzy pot fi combinate între ele prin aplicarea regulii compoziționale a mulțimilor fuzzy.

variabilei lingvistice, T fiind numărabilă

3. G este o gramatică ce generează elementele din T

4. U este universul discursului, adică mulțimea suport a tuturor mulțimilor fuzzy atașate valorilor lingvistice

5. M este o regulă semantică ce atașează unei valori lingvistice semnificația sa

Exemplu: variabila lingvistică "vârsta" poate

avea mai multe valori lingvistice ca “bătrân”, “tânăr” etc., fiecareia dintre acestea corespunzându-i o mulțime fuzzy. Ca univers al discursului, în cazul de fata putem lua intervalul $[0,100]$, vârsta unui om încadrându-se de cele mai multe ori în acest interval.

$$M(\text{batran}) = \{(x, \mu_{\text{batran}}(x)) \mid x \in [0,100]\}$$

Asupra valorilor lingvistice putem aplica așa numiții modificatori, care au ca principal rol modificarea gradului de apartenență a mulțimilor fuzzy aflate în spatele lor, sau, altfel spus, redesenarea aspectului grafic al funcției de apartenență aferentă acestora. Cu ajutorul acestora, putem reprezenta expresii de forma “foarte tânăr”, mai mult sau mai puțin bătrân”, “destul de tânăr etc. De exemplu, foarte $A = \text{con}(A)$, mai mult sau mai puțin $A = \text{dil}(A)$.

Modelele matematice cele mai frecvente folosite pentru modificatori sunt

- concentrația $\mu_{\text{con}(A)}(x) = (\mu_A(x))^2$

- diluarea $\mu_{\text{dil}(A)}(x) = (\mu_A(x))^{1/2}$

- intensificarea contrastelor

$$\mu_{\text{int}(A)}(x) = \begin{cases} 2(\mu_A(x))^2 & \text{for } \mu_A(x) \in [0,0.5] \\ 1 - 2(1 - \mu_A(x))^2 & \text{altfel} \end{cases}$$

- accentuatorii și dezaccentuatorii

$$\mu_{\text{plus}A}(x) = (\mu_A(x))^{1.25}$$

$$\mu_{\text{minus}A}(x) = (\mu_A(x))^{0.75}$$

Regulile de producție fuzzy nu diferă ca formă de cele clasice “Dacă x este A atunci y este B”. Dar în acest caz, x și y sunt variabile lingvistice iar A și B valori lingvistice.

Pentru a putea executa inferențe putem apela ca și în cazul logicii clasice la modus ponens, într-o formă adaptată. Pentru aceasta avem nevoie de definiția operatorului “implică” în termeni fuzzy. În literatura de specialitate regăsim mai multe definiții, ca de exemplu:

Early Zadeh ----- $I(x,y) = \max(1-x, \min(x,y))$

Lukasiewicz ----- $I(x,y) = \min(1, 1-x-y)$

Mamdani ----- $I(x,y) = \min(x,y)$

unde x este gradul de apartenență al premisei, y gradul de apartenență al concluziei iar I gradul de apartenență al implicației.

Dacă A, A', B, B' mulțimi fuzzy atunci modus ponens generalizat arată astfel:

Premisa: x este A'

Implicatie: Dacă x este A atunci y este B

Concluzie: y este B'

Pasii principali ai unei proces inferential ar fi următorii:

- fuzificarea intrărilor, adică transformarea intrărilor în mulțimi fuzzy, dând o anumită formă funcției de apartenență;
- aplicarea operațiilor fuzzy cunoscute, de regulă AND, OR, NOT
- aplicarea operatorului de implicație, preluând una dintre definițiile dorite
- agregarea rezultatelor (transformarea funcțiilor de apartenență ale tuturor regulilor într-una singură prin operații de însumare, maximizare etc.)
- defuzzificarea – transformarea rezultatului obținut mai sus în numere discrete; consacrate fiind mai multe metode: metoda centroidului, minimul maximelor, maximul maximelor, media ponderata a maximelor, metoda bisectoarei etc.

3. Concluzii

Metodele prezentate mai sus trebuie aplicate cu mult discernământ. În funcție de incertitudinea cu care ne confruntăm la un moment dat, trebuie să știm să alegem teoria adecvată. În cazul incertitudinii aleatoare, teoria probabilităților este cea mai bună. Probabilitățile trebuie cunoscute “a priori”, putându-se deduce din serii statistice sau date de un expert. Dar, oricât de bun ar fi un expert, este dificil să se ofere probabilitățile apriorice, cu atât mai mult cu cât, în general, după cum o dovedesc experimentele, subiecții nu raționează în domeniul incertitudinii cu ajutorul probabilităților. În plus, sunt necesare multe serii de observații pentru a cunoaște valoarea probabilităților.

În cazul incertitudinii subiective, teoriile evidenței și posibilității sunt două din variantele adecvate pe care le avem la îndemână. Teoriile evidenței și posibilității nu mai folosesc doar un simplu indicator pentru cuantificarea incertitudinii, ci se apelează la doi indicatori sub forma unui interval. Ambele teorii recunosc tot două valori de adevăr, respectiv adevărat sau fals, încercând să surprindă tendința

unor cunoștințe incerte înspre una dintre valorile booleene. De asemenea, indicatorii nu vor mai fi definiți pe un singur eveniment ci se vor defini pe seturi de evenimente așa încât incertitudinea unei eveniment va fi modelată prin intermediul setului de evenimente ce provoacă evenimentul inițial. În plus, proprietatea de aditivitate nu se mai respectă. Prin aditivitate înțelegem faptul că, fiind cunoscută valoarea unui indicator pentru un anumit eveniment, automat cunoaștem și valoarea indicatorului pentru nerealizarea evenimentului, (adică "ind+NON(ind)=1"). În cazul de față, după cum observăm și-n graficul de mai jos, $\text{ind} + \text{NONind} < 1$, intervalul $[x, y]$ reprezentând incertitudinea ce nu poate fi cuantificată.

--0-----ind-----|x -----|y ---NON ind-----1

În situațiile de ambiguitate lingvistică, mulțimile fuzzy reprezintă varianta cea mai potrivită. În plus, chiar și incertitudinea epistemică amintită mai sus poate fi modelată cu ajutorul acestora, însă acceptând ipoteza multitudinii valorilor de adevăr.

Succesul sistemelor informatice ale viitorului va depinde într-o mare măsură de capacitatea acestora de a implementa incertitudinea. Într-o societate în care totul evoluează foarte rapid, schimbarea fiind omniprezentă, în care volumul informațional crește exponențial, în care problematicile de soluționat devin din ce în ce mai complexe datorită multitudinii de factori și relații, manevrarea incertitudinii cu ajutorul calculatorului devine o necesitate stringentă.

Bibliografie

1. Andone Ioan, Tugui Alexandru, "Dezvoltarea sistemelor inteligente in economie", Editura Economică, București, 2001
2. Benchimol Guy, Levine Pierre, "Sisteme expert in intreprindere", Editura Tehnică, București, 1993
3. Muresan Anton, "Matematici pentru economisti", Universitatea Babes-Bolyai, Cluj-Napoca, 1991
4. Zadeh L., "A fuzzy set theoretic interpretation of linguistic hedges", College of engineering, University of California, Berkeley, 1984
5. Zimmermann H, "Fuzzy set theory and its applications", Kluwer Academic Publishers, 1996
6. citeseer.ist.psu.edu
7. doctor-si.ugr.es
8. en.wikipedia.org
9. www.sandia.gov