

EXTRAGEREA STRUCTURII DIN COLECȚII DE DATE FUZZY: CONCEPTE METRICE ȘI CONSECINȚE ALGORITMICE

dr. ing. Vasile Georgescu

Universitatea Craiova

e-mail: vgeo@central.ucv.ro

Rezumat: Abstragerea sensului din masa amorfă a datelor de observație presupune elaborarea unor tehnici avansate, prin care să fie scoase la lumină *structurile cognitive latente*. Asemenea metode, de natură esențial inductivă, ilustrează faptul că statistica și analiza datelor multidimensionale reprezintă principalul contributor la dezvoltarea unor domenii importante ale inteligenței artificiale, precum *achiziția automată a cunoștințelor*¹. Scopul lucrării este să arate că explorarea universului semantic al datelor de observație și evidențierea structurilor cognitive, induse de acestea, pot fi complet și unitar tranșate, în cadrul *teoriei măsurii*. Atenția este focalizată asupra *datelor codificate prin termeni fuzzy*. Se definesc formal descriptorii și se introduc conceptele metrice, care înzestreză în mod adecvat spațiul variabilelor fuzzy-evaluate, precum și spațiul indivizilor descriși de astfel de variabile. Sunt explorate, de asemenea, consecințele algoritmice ale generalizărilor teoretice propuse, ce fac pe deplin posibilă extinderea analizei datelor multidimensionale (analiza componentelor principale, clasificarea automată, elaborarea modelelor grafice de asociere etc.) în context fuzzy.

Cuvinte cheie: structuri de date fuzzy, concepte metrice, structuri cognitive latente, teoria măsurii.

1. Introducere

În esență, datele de observație reprezintă mărci semantice, aplicate unor entități din realitate. În cazul variabilelor codificate numeric, semnificațiile sunt induse de structura metrică a universului de discurs, respectiv de procedeul de scalare utilizat. Cât privește *variabilele codificate lingvistic*, acestea pot beneficia de un formalism de reprezentare, bazat pe *teoria mulțimilor fuzzy*, dar necesită introducerea unor *concepte metrice* specifice. Incertitudinii induse de natura de eveniment a observațiilor i se adaugă acum și imprecizia proprie reprezentării lingvistice a materialului factual. În ceea ce privește natura formală a acestei reprezentări, are loc o deplasare de accent, de la norme și metrici proprii spațiilor numerice, la cele care înzestreză spațiile de funcții (dat fiind că descriptorul primar al unei mulțimi fuzzy este funcția de apartenență). Argumente similare au determinat plasarea întregii construcții teoretice, în cadrul natural oferit de spațiul Hilbert al funcțiilor de pătrat

¹ Sintagma anglo-saxonă "Data mining and knowledge discovery" exprimă mult mai plastic această arie de cercetări.

integrabil, unde este validă teorema proiecției și, prin urmare, putem apela la teoria proiectoriilor ortogonale în rezolvarea problemelor de normă minimă. În plus, generalizarea analizei dispersionale la cazul entităților fuzzy beneficiază aici de premise formale adecvate.

Mai întâi, vom supune analizei structura metrică a celor două spații în raport cu care se definește o colecție de date fuzzy: *spațiul variabilelor fuzzy-evaluate*, respectiv *spațiul indivizilor descriși de variabile fuzzy*. Modul în care putem abstrage structuri cognitive, plecând de la aceste structuri metrice, este destul de transparent. Astfel, celor n indivizi incluși în eșantion le corespunde un spațiu de reprezentare în care disimilaritățile reciproce dintre ei sunt induse de mărcile semantice distinctive, asociate celor p realizări ale variabilelor fuzzy-evaluate. Întrucât este depozitarul întregii informații despre indivizi, acesta poate fi interpretat ca *spațiu de semnificații (spațiu semantic)*. Măsurile de disimilaritate introduse pe el (metrici, ultrametrike etc.) desemnează, în fapt, tipuri particulare de *distanțe semantice* între indivizi sau grupe de indivizi. Pe de altă parte, spațiului n -dimensional, corespunzând reprezentării vectoriale a realizărilor fiecărei variabile fuzzy-evaluate pentru toți indivizii din eșantion, i se pot asocia anumite măsuri unghiulare, având semnificația unor indici de corelație, fapt ce conduce la interpretarea sa ca *spațiu al corelațiilor*.

Generalizarea structurilor metrice la cazul entităților fuzzy trebuie să țină cont de faptul că metodele ce permit identificarea structurilor cognitive latente, în cadrul analizei datelor multidimensionale, sunt esențial de natură proiectivă. Informația semantică, deținută în cazul reprezentării norului de indivizi pe un spațiu de dimensiune mare, poate fi rezumată (și, eventual, "vizualizată") prin proiecția pe un spațiu de dimensiune redusă, determinat din condiția ca deformarea norului în proiecție (deci, implicit, pierderea de informație ce are loc cu acest prilej) să fie minimă. O măsură a acestei pierderi de informație este modificarea inerției entităților reprezentate în spațiul inițial și în spațiul de proiecție. Agregarea indivizilor, după criteriul inerției minime intra-clase și a inerției maxime interclase, prin metode de clasificare automată, conduce la realizarea de ierarhii semnificative, fiind pusă astfel în lumină o altă sursă se informație latentă. Prin urmare, deși în decursul timpului s-au propus numeroase măsuri de asemănare sau indici de disimilaritate între mulțimi fuzzy, ele rămân inoperante câtă vreme nu asigură compatibilitatea dintre generalizarea conceptelor metrice în spațiul entităților fuzzy și teoria proiectoriilor ortogonale. Astfel, suntem încă o dată constrânși să recurgem la norme generate de un produs

scalar, deci, la spații Hilbert. Desigur, există și alte rațiuni ce justifică soluția constructivă, adoptată în această lucrare. Toate acestea vor face obiectul prezentării care urmează.

2. Structuri metrice în spațiul variabilelor fuzzy-evaluate

Să considerăm o colecție de date multidimensionale, constând din n observații (indivizi), caracterizați de p variabile fuzzy-evaluate. Fiecare variabilă $(X^j)_{j=1,p}$ va fi definită prin cele n realizări fuzzy ale sale, date sub forma tăieturilor de nivel α :

$$(M_i^j)_\alpha = [\underline{m}_i^j(\alpha), \overline{m}_i^j(\alpha)]_{\alpha \in [0,1]} \quad (1)$$

unde $\underline{m}_i^j(\alpha)$ sunt funcții nedescrescătoare, iar $\overline{m}_i^j(\alpha)$ sunt funcții necrescătoare.

2.1. Media (punctuală) a unui eveniment fuzzy, versus media (fuzzy) a unei variabile fuzzy

Orice realizare M a unei variabile fuzzy-evaluate X poate fi percepută ca un eveniment. În esență, ea reprezintă o observație, dar, în fapt, încorporează un conglomerat de posibilități, datorită impreciziei inerente specificării lingvistice. De aceea, pentru a transforma această observație într-o valoare precisă, se face apel în mod curent la o procedură de "defuzzificare". Media unui eveniment fuzzy este măsura cea mai frecvent utilizată în acest scop. Fie (Ω, A, P) un câmp de probabilitate. Dacă se consideră pe acest câmp o distribuție de probabilități uniformă, atunci evenimentul fuzzy M poate fi localizat punctual, prin media sa (centrul de greutate al mulțimii fuzzy corespunzătoare) pe referențialul asociat variabilei X :

$$\text{media}(M) = \frac{\int_{S(M) \subset \mathcal{R}} x \cdot \mu_M(x) dx}{\int_{S(M) \subset \mathcal{R}} \mu_M(x) dx} \quad (2)$$

unde $S(M) = \text{suport}(M)$.

O astfel de măsură nu interesează în mod direct cercetarea pe care am inițiat-o, deoarece aceasta se focalizează explicit pe definirea momentelor fuzzy ale variabilelor fuzzy-evaluate; totuși, din calculul său pot fi desprinse anumite sugestii. Fie M o mulțime fuzzy de tip trapezoidal:

$M_\alpha = [\underline{m}(\alpha), \overline{m}(\alpha)]_{\alpha \in [0,1]}$
 $= [\underline{m} - f + f \cdot \alpha, \overline{m} + d - d \cdot \alpha]_{\alpha \in [0,1]}$ (figura 1). În acest caz, operatorul de localizare (defuzzificare) de mai sus se poate rescrie sub forma mediei ponderate a trei valori medii parțiale:

$$\text{media}(M) = \frac{\bar{x}^L \cdot w^L + \bar{x}^C \cdot w^C + \bar{x}^R \cdot w^R}{w^L + w^C + w^R} \quad (3)$$

unde:

$$w^L = \int_{\underline{m}-f}^{\underline{m}} \mu^L(x) dx;$$

$$w^C = \int_{\underline{m}}^{\overline{m}} \mu^C(x) dx; \quad w^R = \int_{\overline{m}}^{\overline{m}+d} \mu^R(x) dx$$

Cu transformările:

$$\mu^L(x) = \alpha \in [0,1] \quad x = \underline{m}(\alpha) \in [\underline{m}-f, \underline{m}] \Rightarrow$$

$$\Rightarrow \frac{\mu^L(x)}{\int_{\underline{m}-f}^{\underline{m}} \mu^L(x) dx} = \frac{\alpha}{\int_0^1 \alpha d\alpha} = \frac{\alpha}{1/2} = 2 \cdot \alpha$$

abscisa \bar{x}^L a centrului de greutate al triunghiului din stânga figurii (având baza $[\underline{m}-f, \underline{m}]$) se obține sub forma unei integrale Lebesgue, definită în raport cu măsura λ :

$$\begin{aligned} \bar{x}^L &= \frac{\int_{\underline{m}-f}^{\underline{m}} x \cdot \mu^L(x) dx}{\int_{\underline{m}-f}^{\underline{m}} \mu^L(x) dx} = \int_0^1 \underline{m}(\alpha) \cdot 2\alpha d\alpha = \\ &= \int_0^1 \underline{m}(\alpha) \cdot w(\alpha) d\alpha = \int_{[0,1]} \underline{m}(\alpha) \cdot \lambda(d\alpha) \end{aligned}$$

$$\text{unde } \lambda([0,1]) = \int_0^1 w(\alpha) d\alpha = \int_0^1 2\alpha d\alpha = 1,$$

iar $w(\alpha) = 2\alpha$ poate fi interpretată ca o funcție pondere.

Pentru $\underline{m}(\alpha) = \underline{m} - f + \alpha f$, obținem:

$$\bar{x}^L = \int_0^1 (\underline{m} - f + \alpha f) \cdot 2\alpha d\alpha = \underline{m} - f + \frac{2}{3}f = \underline{m} \left(\frac{2}{3} \right)$$




Figura 1. $\bar{x}^L = \int_0^1 \underline{m}(\alpha) \cdot 2\alpha d\alpha = \underline{m} \left(\frac{2}{3} \right)$; $\bar{x}^C = \frac{\underline{m} + \overline{m}}{2}$;

$$\bar{x}^R = \int_0^1 \bar{m}(\alpha) \cdot 2\alpha \, d\alpha = \bar{m}(2/3)$$

Vom reține modul de calcul al lui \bar{x}^L sub forma unei integrale Lebesgue, ca o sugestie pentru dezvoltări ulterioare.

Cât privește *media fuzzy a variabilei fuzzy-evaluate* X^j , aceasta poate fi calculată cu ajutorul relației:

$$\begin{aligned} G^j(\alpha) &= \sum_{i=1}^n p_i [\underline{m}_i^j(\alpha), \bar{m}_i^j(\alpha)] \\ &= \left[\sum_{i=1}^n p_i \underline{m}_i^j(\alpha), \sum_{i=1}^n p_i \bar{m}_i^j(\alpha) \right] = [G^j(\alpha), \bar{G}^j(\alpha)] \end{aligned} \quad (4)$$

unde p_i este ponderea relativă a fiecărui individ în eșantion ($p_i > 0$; $\sum p_i = 1$).

Din $\underline{m}_i^j(\alpha) \leq \bar{m}_i^j(\alpha)$, cu $\underline{m}_i^j(\alpha)$ funcții nedescrescătoare și $\bar{m}_i^j(\alpha)$ funcții necrescătoare, deducem $G^j(\alpha) \leq \bar{G}^j(\alpha)$, cu $G^j(\alpha)$ funcții nedescrescătoare și $\bar{G}^j(\alpha)$ funcții necrescătoare.

2.2. Matricea de covarianță fuzzy

În continuare, vom face, în plus, ipoteza că $\underline{m}_i^j(\alpha)$ și $\bar{m}_i^j(\alpha)$ sunt funcții măsurabile de pătrat integrabil Lebesgue (în raport cu măsura λ , definită mai sus), putându-le astfel interpreta ca elemente ale spațiului Hilbert $L_2 [0,1]$. În consecință, putem beneficia de existența produsului scalar:

$$\begin{aligned} \langle f(\alpha), g(\alpha) \rangle &= \int_{[0,1]} f(\alpha) \cdot g(\alpha) \, \lambda(d(\alpha)) = \\ &= \int_0^1 f(\alpha) \cdot g(\alpha) \, 2\alpha \, d\alpha \end{aligned}$$

care induce norma $\|f(\alpha)\| = (\langle f(\alpha), f(\alpha) \rangle)^{1/2}$ pe acest spațiu.

Principala presupunere pe care ne bazăm construcția matricei de covarianță V a celor p variabile fuzzy-evaluate este că aceasta trebuie să fie egală cu matricea $0_{p \times p}$, în cazul în care toate variabilele au realizări fuzzy constante. Să notăm prin \underline{Y}^j , respectiv \bar{Y}^j , componentele stângă și dreaptă ale variabilei fuzzy-evaluate centrate de rang j : $\bar{Y}_i^j(\alpha) = \bar{M}_i^j(\alpha) - \bar{G}^j(\alpha)$; $\underline{Y}_i^j(\alpha) = \underline{M}_i^j(\alpha) - \underline{G}^j(\alpha)$; $\forall i = \overline{1, n}$.

Cele $n \times p$ funcții $\underline{Y}_i^j(\alpha)$ pot fi colectate într-o matrice $\underline{Y}(\alpha)$, iar cele $n \times p$ funcții $\bar{Y}_i^j(\alpha)$ într-o matrice $\bar{Y}(\alpha)$. În final, putem reuni aceste două matrice într-una $(2n \times p)$ -dimensională, adică:

$$Y(\alpha) = \begin{pmatrix} \underline{Y}(\alpha) \\ \bar{Y}(\alpha) \end{pmatrix} \quad (5)$$

Fie acum $D = \text{diag}(p_i)$ matricea de ponderi, cu $\text{tr}(D) = 1$ și să introducem matricea bloc-diagonală de dimensiune $2n \times 2n$:

$$\tilde{D} = \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix}, \quad \text{cu } \text{tr}(\tilde{D}) = 1 \quad (6)$$

Matricea de covarianță fuzzy de dimensiune $p \times p$, asociată celor p variabile fuzzy-evaluate, se definește atunci prin:

$$\begin{aligned} V(\alpha) &= \begin{pmatrix} \underline{Y}(\alpha) \\ \bar{Y}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Y}(\alpha) \\ \bar{Y}(\alpha) \end{pmatrix} \\ &= \frac{\underline{Y}'(\alpha) \cdot D \cdot \underline{Y}(\alpha) + \bar{Y}'(\alpha) \cdot D \cdot \bar{Y}(\alpha)}{2} \\ &= \frac{V(\alpha) + \bar{V}(\alpha)}{2} \end{aligned} \quad (7)$$

Evident, această matrice este **invariantă la o translație** a unora sau tuturor variabilelor fuzzy-evaluate.

O evaluare numerică a matricei de covarianță fuzzy poate fi efectuată pentru orice nivel fixat al lui α din intervalul $[0, 1]$.

Pe de altă parte, ne putem pune problema găsirii celei mai reprezentative expresii numerice pentru $V(\alpha)$, caz în care este natural să apelăm la o *procedură de defuzzificare* bazată pe metoda centrului de greutate:

$$\begin{aligned} V &= \int_0^1 \begin{pmatrix} \underline{Y}(\alpha) \\ \bar{Y}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Y}(\alpha) \\ \bar{Y}(\alpha) \end{pmatrix} \cdot 2\alpha \, d\alpha \\ &= \frac{\int_0^1 \underline{Y}'(\alpha) \cdot D \cdot \underline{Y}(\alpha) \cdot 2\alpha \, d\alpha + \int_0^1 \bar{Y}'(\alpha) \cdot D \cdot \bar{Y}(\alpha) \cdot 2\alpha \, d\alpha}{2} \\ &= \frac{V + \bar{V}}{2} \end{aligned} \quad (8)$$

2.3. Matricea de corelație fuzzy

Vom defini acum matricea datelor fuzzy standardizate:

$$Z(\alpha) = \begin{pmatrix} \underline{Z}(\alpha) \\ \bar{Z}(\alpha) \end{pmatrix} = \begin{pmatrix} \underline{Y}(\alpha) \cdot D_{1/s}(\alpha) \\ \bar{Y}(\alpha) \cdot D_{1/s}(\alpha) \end{pmatrix} \quad (9)$$

unde:

$$\underline{D}_{1/s}(\alpha) = \text{diag}(1/\underline{s}_j(\alpha)); \quad \underline{s}_j(\alpha) = \sqrt{\underline{v}_{jj}(\alpha)}$$

$$\overline{D}_{1/s}(\alpha) = \text{diag}(1/\overline{s}_j(\alpha)); \quad \overline{s}_j(\alpha) = \sqrt{\overline{v}_{jj}(\alpha)}$$

Matricea de corelație fuzzy poate fi ușor dedusă din $Z(\alpha)$ și \tilde{D} :

$$R(\alpha) = \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix}$$

$$= \frac{\underline{Z}'(\alpha) \cdot D \cdot \underline{Z}(\alpha) + \overline{Z}'(\alpha) \cdot D \cdot \overline{Z}(\alpha)}{2}$$

$$= \frac{\underline{D}_{1/s}(\alpha) \cdot \underline{V}(\alpha) \cdot \underline{D}_{1/s}(\alpha) + \overline{D}_{1/s}(\alpha) \cdot \overline{V}(\alpha) \cdot \overline{D}_{1/s}(\alpha)}{2}$$

$$= \frac{R(\alpha) + \overline{R}(\alpha)}{2} \quad (10)$$

O evaluare numerică a lui $R(\alpha)$ se poate obține aplicând procedura de "defuzzificare", bazată pe metoda centrului de greutate:

$$R = \int_0^1 \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix} 2\alpha \, d\alpha$$

$$= \frac{\int_0^1 \underline{Z}'(\alpha) \cdot D \cdot \underline{Z}(\alpha) \cdot 2\alpha \, d\alpha + \int_0^1 \overline{Z}'(\alpha) \cdot D \cdot \overline{Z}(\alpha) \cdot 2\alpha \, d\alpha}{2}$$

$$= \frac{R + \overline{R}}{2} \quad (11)$$

3. Structuri metrice în spațiul indivizilor descriși de variabile fuzzy-evaluate

Construcția introdusă în paragrafele precedente sugerează, deja, că statistica entităților fuzzy se întemeiază pe furnizarea unei definiții formale, adecvată noțiunii de distanță între două mulțimi fuzzy. Este ușor de sesizat că măsurile prin care am modelat variabilitatea în spațiul variabilelor fuzzy-evaluate (precum dispersia, respectiv covarianța) au fost, în mod natural, derivate dintr-un asemenea concept metric.

3.1. Distanța pătratică dintre două mulțimi fuzzy

Fie X^j o variabilă fuzzy-evaluată, definită pe componenta j a unui referențial p -dimensional X și fie M_i^j , respectiv M_ℓ^j , două realizări desemnând mulțimi fuzzy.

Ipoteza fundamentală pe care ne-am bazat construcția este că disimilaritatea

dintre două mulțimi fuzzy $(M_i^j)_\alpha = [\underline{m}_i^j(\alpha), \overline{m}_i^j(\alpha)]_{\alpha \in [0,1]}$ respectiv $(M_\ell^j)_\alpha = [\underline{m}_\ell^j(\alpha), \overline{m}_\ell^j(\alpha)]_{\alpha \in [0,1]}$ se datorează absenței congruenței între funcțiile limită-stângă $\underline{m}_i^j(\alpha)$ și $\underline{m}_\ell^j(\alpha)$, respectiv funcțiile limită-dreaptă $\overline{m}_i^j(\alpha)$ și $\overline{m}_\ell^j(\alpha)$. Reductibilitatea cazului fuzzy la cel strict (al variabilelor reale) este asumată implicit.

Pentru orice α din intervalul $[0, 1]$ se poate calcula o distanță pătratică între tăieturile de nivel α , corespunzătoare celor două mulțimi fuzzy:

$$d^2(M_i^j(\alpha), M_\ell^j(\alpha)) = \frac{(\underline{m}_i^j(\alpha) - \underline{m}_\ell^j(\alpha))^2 + (\overline{m}_i^j(\alpha) - \overline{m}_\ell^j(\alpha))^2}{2}$$

Prezintă îndeosebi interes cazurile:

$\alpha = 0$ - când mulțimile fuzzy se extind la întregul suport (ce coincide cu tăietura de nivel 0);

$\alpha = 1$ - când mulțimile fuzzy se restrâng la nucleu (tăietura de nivel 1).

Putem introduce acum **distanța pătratică dintre două mulțimi fuzzy** M_i^j și M_ℓ^j , ca *medie ponderată a distanțelor corespunzătoare tăieturilor de nivel α* . Ea va fi în mod natural definită, utilizând norma indusă de produsul scalar, ce înzestrează spațiul Hilbert $L_2[0, 1]$:

$$d^2(M_i^j, M_\ell^j) = \frac{1}{2} \left[\int_{[0,1]} (\underline{m}_i^j(\alpha) - \underline{m}_\ell^j(\alpha))^2 \lambda(d\alpha) + \int_{[0,1]} (\overline{m}_i^j(\alpha) - \overline{m}_\ell^j(\alpha))^2 \lambda(d\alpha) \right]$$

$$= \frac{1}{2} \left[\int_0^1 (\underline{m}_i^j(\alpha) - \underline{m}_\ell^j(\alpha))^2 2\alpha \, d\alpha + \int_0^1 (\overline{m}_i^j(\alpha) - \overline{m}_\ell^j(\alpha))^2 2\alpha \, d\alpha \right] \quad (12)$$

unde integrala Lebesgue a fost considerată în raport cu măsura λ deja menționată.

Conceptul metric, definit mai sus, satisface toate axiomele unei distanțe:

1. $d(M_i^j, M_\ell^j) \geq 0$
2. $d(M_i^j, M_\ell^j) = d(M_\ell^j, M_i^j)$
3. $d(M_i^j, M_\ell^j) = 0 \Rightarrow M_i^j = M_\ell^j$
4. $d(M_i^j, M_\ell^j) \leq d(M_i^j, M_k^j) + d(M_k^j, M_\ell^j)$

3.2. Distanța pătratică dintre doi indivizilor descriși de variabile fuzzy-evaluate. Inerția norului de indivizi

Să considerăm acum o colecție de date ce descriu n indivizi prin p variabile fuzzy-evaluate. Notăm cu:

$$X(\alpha) = \begin{pmatrix} \underline{X}(\alpha) \\ \overline{X}(\alpha) \end{pmatrix}, \text{ respectiv } Z(\alpha) = \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix}$$

matricele $(2n \times p)$ -dimensionale, formate fiecare din două blocuri matriceale suprapuse, reprezentând tăieturile de nivel α , ale datelor nestandardizate, respectiv standardizate. Desemnăm, totodată, doi indivizi, reprezentați pe spațiul produs $X = X^1 \times \dots \times X^p$ al variabilelor fuzzy-evaluate de liniile corespunzătoare ale blocurilor matriceale definite mai sus:

- individul $i(\alpha)$ prin:

$$\begin{pmatrix} \underline{X}_i(\alpha) \\ \overline{X}_i(\alpha) \end{pmatrix}, \text{ respectiv } \begin{pmatrix} \underline{Z}_i(\alpha) \\ \overline{Z}_i(\alpha) \end{pmatrix}$$

- individul $\ell(\alpha)$ prin:

$$\begin{pmatrix} \underline{X}_\ell(\alpha) \\ \overline{X}_\ell(\alpha) \end{pmatrix}, \text{ respectiv } \begin{pmatrix} \underline{Z}_\ell(\alpha) \\ \overline{Z}_\ell(\alpha) \end{pmatrix}$$

Distanța pătratică dintre cei doi indivizi $i(\alpha)$ și $\ell(\alpha)$ descriși prin tăieturi de nivel α este:

- pentru date nestandardizate:

$$\delta^2(i(\alpha), \ell(\alpha)) = \frac{\|\underline{X}_i(\alpha) - \underline{X}_\ell(\alpha)\|^2 + \|\overline{X}_i(\alpha) - \overline{X}_\ell(\alpha)\|^2}{2} \quad (13a)$$

- pentru date standardizate:

$$\delta^2(i(\alpha), \ell(\alpha)) = \frac{\|\underline{Z}_i(\alpha) - \underline{Z}_\ell(\alpha)\|^2 + \|\overline{Z}_i(\alpha) - \overline{Z}_\ell(\alpha)\|^2}{2} \quad (13b)$$

Din motive de reprezentativitate, distanța pătratică dintre indivizii i și ℓ descriși de variabile fuzzy-evaluate, se va calcula, în final, sub forma unei medii ponderate a distanțelor definite mai sus, în raport cu nivelurile arbitrare ale lui α . Avem:

$$\delta^2(i, \ell) = \int_0^1 \delta^2(i(\alpha), \ell(\alpha)) 2\alpha d\alpha \quad (14)$$

Inerția în raport cu centrul de greutate $G(\alpha)$ a norului compus din cei n indivizi (descriși prin tăieturi de nivel α și desemnați generic prin $i(\alpha)$) se definește astfel:

- pentru date nestandardizate:

$$\begin{aligned} I_G(\alpha) &= \sum_{i=1}^n p_i \delta^2(i(\alpha), G(\alpha)) = \sum_{i=1}^n p_i \frac{\|\underline{Y}_i(\alpha)\|^2 + \|\overline{Y}_i(\alpha)\|^2}{2} \\ &= \sum_{j=1}^p \frac{\sum_{i=1}^n p_i [\underline{Y}_i^j(\alpha)]^2 + \sum_{i=1}^n p_i [\overline{Y}_i^j(\alpha)]^2}{2} \\ &= \sum_{j=1}^p \frac{\text{var}(\underline{X}^j(\alpha)) + \text{var}(\overline{X}^j(\alpha))}{2} = \text{tr} \left(\frac{V(\alpha) + \overline{V}(\alpha)}{2} \right) = \text{tr}(V(\alpha)) \end{aligned}$$

- pentru date standardizate:

$$\begin{aligned} I_G(\alpha) &= \sum_{i=1}^n p_i \frac{\|\underline{Z}_i(\alpha)\|^2 + \|\overline{Z}_i(\alpha)\|^2}{2} \\ &= \sum_{j=1}^p \frac{\sum_{i=1}^n p_i [\underline{Z}_i^j(\alpha)]^2 + \sum_{i=1}^n p_i [\overline{Z}_i^j(\alpha)]^2}{2} \\ &= \sum_{j=1}^p \frac{\text{cor}(\underline{X}^j(\alpha), \underline{X}^j(\alpha)) + \text{cor}(\overline{X}^j(\alpha), \overline{X}^j(\alpha))}{2} \\ &= \text{tr} \left(\frac{R(\alpha) + \overline{R}(\alpha)}{2} \right) = \text{tr}(R(\alpha)) = p \end{aligned}$$

Inerția norului de indivizi descriși de variabile fuzzy-evaluate se poate exprima acum sub forma unei medii ponderate a inerțiilor calculate cu ajutorul tăieturilor de nivel α :

$$I_G = \int_0^1 I_G(\alpha) 2\alpha d\alpha \quad (15)$$

Trebuie notat că mai multe consecințe algoritmice rezultă natural din abordarea teoretică de mai sus. Câteva dintre ele au fost sugerate, pentru prima dată, într-una din lucrările noastre anterioare (vezi [2]).

4. Extensia fuzzy a analizei componentelor principale

4.1. Principiul metodei

Principiul analizei componentelor principale este acela de a rezuma și de a vizualiza sub formă grafică informația adusă de un număr de p variabile ce descriu n indivizi, printr-un număr mai restrâns ($q < p$) de variabile noi, astfel încât pierderea de informație să fie minimă. Informația despre indivizi este complet definită prin localizarea acestora în spațiul inițial de dimensiune p . Acțiunea de a reduce reprezentarea revine atunci la cea de a proiecta "norul" de indivizi pe un subspațiu afin de dimensiune q , determinat din condiția ca deformarea distanțelor dintre indivizi, inerentă în cursul proiecției, să fie minimă. Criteriul formal echivalent este de a maximiza inerția norului proiectat, adică media ponderată a

pătratelor distanțelor dintre proiecțiile indivizilor și centrul lor de greutate.

În continuare, ne vom concentra atenția asupra extinderii acestei metode de analiză asupra cazului în care indivizii sunt caracterizați de variabile fuzzy-evaluate.

4.2. Determinarea subspațiului optimal de proiecție, utilizând teoria proiectorilor ortogonali

Fie P matricea de proiecție M -ortogonală (idempotentă $P^2 = P$ și M -simetrică $P'M = MP$) a vectorilor p -dimensionali din spațiul inițial pe un subspațiu de dimensiune q . Matricea M înzestrează spațiul indivizilor cu o metrică ce permite o scalare convenabilă a datelor. Vom considera cele două cazuri relevante (induse de alegerea lui M):

(1°) - indivizii sunt descriși de matricea $(2n \times p)$ -dimensională a datelor centrate, exprimate sub forma tăieturilor de nivel α :

$$Y(\alpha) = \begin{pmatrix} \underline{Y}(\alpha) \\ \overline{Y}(\alpha) \end{pmatrix}$$

Pentru o valoare fixată a lui α din intervalul $[0, 1]$, $Y(\alpha)$ este o matrice numerică. Imaginea sa, obținută prin proiecția celor $2n$ vectori linie, de dimensiune p , cu ajutorul operatorului de proiecție ortogonală, este matricea:

$$\hat{Y}(\alpha) = \begin{pmatrix} \underline{Y}(\alpha) \\ \overline{Y}(\alpha) \end{pmatrix} \cdot P'$$

Matricea de covarianță a lui $\hat{Y}(\alpha)$ este dată atunci de:

$$\hat{V}(\alpha) = P \cdot \begin{pmatrix} \underline{Y}(\alpha) \\ \overline{Y}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Y}(\alpha) \\ \overline{Y}(\alpha) \end{pmatrix} \cdot P' = P \cdot V(\alpha) \cdot P'$$

În cazul datelor centrate, matricea care furnizează metrica pe spațiul indivizilor este $M = I$, deci, vom avea $P = P' = P^2$. Prin urmare, inerția totală a norului proiectat al indivizilor, pe subspațiul q -dimensional corespunzător, rezultă sub forma:

$$I(\alpha) = \text{tr}(\hat{V}(\alpha)) = \text{tr}(PV(\alpha)P') = \text{tr}(PV(\alpha)P) = \text{tr}(V(\alpha)P^2) = \text{tr}(V(\alpha)P)$$

Pentru a evita alegerea arbitrară a lui α , putem, din nou, să utilizăm media ponderată, introdusă pe spațiul funcțiilor măsurabile, de pătrat integrabil. Matricea de covarianță a proiecțiilor "defuzzificate" este atunci:

$$\begin{aligned} \hat{V} &= P \left\{ \int_0^1 \begin{pmatrix} \underline{Y}(\alpha) \\ \overline{Y}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Y}(\alpha) \\ \overline{Y}(\alpha) \end{pmatrix} 2\alpha \, d\alpha \right\} P' \\ &= P \frac{V + \bar{V}}{2} P' = PVP' \end{aligned}$$

și deci:

$$I = \text{tr}(\hat{V}) = \text{tr}(PVP') = \text{tr}(VP)$$

(2°) - indivizii sunt descriși de matricea $(2n \times p)$ -dimensională a datelor standardizate, exprimate sub forma tăieturilor de nivel α :

$$Z(\alpha) = \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix} = \begin{pmatrix} \underline{Y}(\alpha) \cdot \underline{D}_{1/s}(\alpha) \\ \overline{Y}(\alpha) \cdot \overline{D}_{1/s}(\alpha) \end{pmatrix}$$

unde:

$$\begin{aligned} \underline{D}_{1/s}(\alpha) &= \text{diag}(1/\underline{s}_j(\alpha)); \quad \underline{s}_j(\alpha) = \sqrt{\underline{v}_{jj}(\alpha)} \\ \overline{D}_{1/s}(\alpha) &= \text{diag}(1/\overline{s}_j(\alpha)); \quad \overline{s}_j(\alpha) = \sqrt{\overline{v}_{jj}(\alpha)} \end{aligned}$$

Matricea proiecțiilor standardizate este:

$$\hat{Z}(\alpha) = \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix} \cdot P'$$

În acest caz matricele de covarianță (asociate atât datelor inițiale cât și celor proiectate) coincid cu matricele de corelație. Prin urmare, avem:

$$\hat{R}(\alpha) = P \cdot \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix} \cdot P' = P \cdot R(\alpha) \cdot P'$$

$$I(\alpha) = \text{tr}(\hat{R}(\alpha)) = \text{tr}(R(\alpha)P)$$

$$\begin{aligned} \hat{R} &= P \left\{ \int_0^1 \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix}' \cdot \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \cdot \begin{pmatrix} \underline{Z}(\alpha) \\ \overline{Z}(\alpha) \end{pmatrix} 2\alpha \, d\alpha \right\} P' \\ &= P \frac{R + \bar{R}}{2} P' = PRP' \end{aligned}$$

$$I = \text{tr}(\hat{R}) = \text{tr}(PRP') = \text{tr}(RP)$$

În ambele cazuri prezentate mai sus, problema determinării subspațiului optimal de proiecție constă în a găsi matricea de proiecție ortogonală P , de rang q , ce satisface condiția de a maximiza inerția totală a norului proiectat ($I = \text{tr}(VP)$, respectiv $I = \text{tr}(RP)$).

Evident, soluția este cea cunoscută din cazul clasic: subspațiul optimal de proiecție de dimensiune q este generat de cei q vectori proprii asociați celor mai mari q valori proprii ale matricei V (în cazul datelor centrate), adică:

$$VU = UD_\lambda; \quad U'U = I_p; \quad D_\lambda = \text{diag}(\lambda_k); \quad \lambda_1 \geq \lambda_2 \geq \dots$$

respectiv matricei R (în cazul datelor standardizate), adică:

$$RU = UD_\lambda; \quad U'U = I_p; \quad D_\lambda = \text{diag}(\lambda_k); \quad \lambda_1 \geq \lambda_2 \geq \dots$$

4.3. Proiecția entităților fuzzy: Interpretare

O particularitate importantă, atunci când metoda se aplică unei colecții de date fuzzy, constă în semnificația componentelor principale. Acestea se pot defini atât pentru valori arbitrare ale lui α din intervalul $[0, 1]$:

$$C(\alpha) = \left(\frac{C(\alpha)}{C(\alpha)} \right) = \left(\frac{Y(\alpha)}{Y(\alpha)} \right) U$$

cât și ca rezultat al defuzzificării, prin utilizarea mediei ponderate pe spațiul funcțiilor măsurabile:

$$C = \left(\frac{C}{C} \right) = \left(\int_0^1 \left(\frac{Y(\alpha)}{Y(\alpha)} \right) 2\alpha d\alpha \right) U$$

Deoarece mai sus s-a avut în vedere cazul datelor centrate, U desemnează matricea vectorilor proprii coloană ai lui V . În plus, avem:

$$\text{Media} \left(\frac{C(\alpha)}{C(\alpha)} \right) = \text{Media} \left(\frac{Y(\alpha)}{Y(\alpha)} \right) U = 0_{2n \times p}$$

Matricea de covarianță a componentelor principale:

$$\begin{aligned} \text{Var} \left(\frac{C}{C} \right) &= \int_0^1 \left(\frac{C(\alpha)}{C(\alpha)} \right)' \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \left(\frac{C(\alpha)}{C(\alpha)} \right) 2\alpha d\alpha \\ &= U \left\{ \int_0^1 \left(\frac{Y(\alpha)}{Y(\alpha)} \right)' \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \left(\frac{Y(\alpha)}{Y(\alpha)} \right) 2\alpha d\alpha \right\} \cdot U \\ &= U' V U = U' U D_\lambda = D_\lambda \end{aligned}$$

Prin urmare:

$$\text{std}(C^k) = \sqrt{\lambda_k}; \quad \text{cov}(C^j, C^k) = 0, \forall j \neq k$$

Observații:

a. În cazul datelor standardizate, matricea Y trebuie înlocuită cu Z .

b. Întrucât componentele principale sunt de medie nulă, ele pot fi standardizate prin multiplicare cu inversele abaterilor standard ($1/\sqrt{\lambda_k}$):

$$\left(\frac{C(\alpha)}{C(\alpha)} \right) \cdot D_{1/\sqrt{\lambda}}$$

unde $D_{1/\sqrt{\lambda}} = \text{diag}(1/\sqrt{\lambda_k})$

c. Matricea corelațiilor dintre variabilele inițiale X și componentele principale C se definește astfel:

$$\begin{aligned} R(X, C) &= \left\{ \int_0^1 \left(\frac{Z(\alpha)}{Z(\alpha)} \right)' \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \left(\frac{C(\alpha)}{C(\alpha)} \right) 2\alpha d\alpha \right\} \cdot D_{1/\sqrt{\lambda}} \\ &= \left\{ \int_0^1 \left(\frac{Z(\alpha)}{Z(\alpha)} \right)' \begin{pmatrix} D/2 & 0 \\ 0 & D/2 \end{pmatrix} \left(\frac{Z(\alpha)}{Z(\alpha)} \right) 2\alpha d\alpha \right\} \cdot U \cdot D_{1/\sqrt{\lambda}} \\ &= R \cdot U \cdot D_{1/\sqrt{\lambda}} = U \cdot D_\lambda \cdot D_{1/\sqrt{\lambda}} = U \cdot D_{\sqrt{\lambda}} \end{aligned}$$

Așadar:

$$r(C^k, X^j) = \sqrt{\lambda_k} \cdot u_j^k, \quad k = \overline{1, p}, \quad j = \overline{1, p}$$

Dacă sortăm cele p valori proprii în ordine descendentă și alegem primele q dintre ele (cu

$q < p$), atunci $r(C^k, X^j)_{k=1, \dots, q}$ se pot interpreta ca fiind coordonatele variabilei X^j pe primele q axe de inerție maximă (proiecția variabilelor inițiale pe subspațiul q -dimensional de inerție maximă).

În final, trebuie să proiectăm cei n indivizi descriși de variabile fuzzy-evaluate pe subspațiul q -dimensional de inerție maximă.

Fiecărui individ îi vor corespunde două proiecții. Astfel, pentru o valoare a lui α , fixată arbitrar în intervalul $[0, 1]$, se vor obține proiecțiile limitelor intervalelor ce definesc tăieturile de nivel α :

$$s \cdot \left(\frac{Z(\alpha)}{Z(\alpha)} \right) \cdot U$$

unde s este o constantă de scalare (uzual, $s = 1/\sqrt{p}$).

Observație: În principiu, se pot proiecta orice valori situate pe suportul mulțimilor fuzzy, ce definesc indivizii, sau se pot realiza interpolări între perechi de valori extreme.

Proiecțiile "defuzzificate" utilizând media ponderată introdusă pe spațiul funcțiilor măsurabile sunt date de:

$$s \cdot \left(\frac{Z}{Z} \right) \cdot U = s \cdot \left\{ \int_0^1 \left(\frac{Z(\alpha)}{Z(\alpha)} \right) 2\alpha d\alpha \right\} \cdot U$$

5. Extensia fuzzy a algoritmilor de clasificare automată

În scopul ordonării indivizilor, al producerii de grupări și al descrierii acestora printr-un anumit număr de caractere specifice, se poate apela la o clasificare automată. Considerînd, spre exemplu, mulțimea celor n indivizi descriși de p variabile, clasificarea presupune definirea unui anumit număr de clase (agregări) de indivizi care, în raport cu distanțele dintre ei, fac să varieze cel mai puțin inerția la nivelul fiecărei clase, maximizând, totodată, inerția interclase. Dacă strategia de clasificare este una ierarhic ascendentă, indivizii sunt împărțiți în clase din ce în ce mai largi, obținute prin regrupări succesive ale părților. Sunt produse, astfel, ierarhii indexate, care asociază fiecărei părți un anumit nivel de agregare, utilizând o distanță ultrametrică.

Conceptul cheie ce permite generalizarea algoritmilor de clasificare automată în context fuzzy este distanța pătratică dintre indivizi, introdusă în paragraful 3.2. Într-adevăr, punctul de plecare în cadrul majorității algoritmilor de clasificare îl reprezintă matricea simetrică a distanțelor mutuale dintre indivizi. Odată această matrice calculată, rezolvarea problemei se reduce la aplicarea metodelor clasice.

6. Modele grafice ale dependențelor condiționate dintre variabilele fuzzy-evaluate

Modelele grafice sunt modelele statistice ale legăturilor dintre variabile, bazate, în esențial, pe conceptul de

independență condiționată. Graful complet, al conexiunilor potențiale dintre variabile, reprezintă modelul saturat. Modelul real se obține prin desfacerea legăturilor statistic nesemnificative (acelea care verifică ipoteza de independență condiționată).

Generalizarea metodologiei clasice la cazul variabilelor fuzzy-evaluate este, și în acest caz, pe deplin posibilă. Într-adevăr, elementul cheie în stabilirea independenței a două variabile continue, condiționată de restul variabilelor, îl reprezintă inversa matricei de corelație. Cum printre generalizările propuse de această lucrare (vezi secțiunea 2) se numără și calculul matricei de corelație asociată variabilelor fuzzy-evaluate, sunt create premisele conceptuale și metodologice pentru a accede la mecanismul clasic de specificare a modelelor grafice gaussiene, concomitent cu extinderea câmpului de aplicații al acestora. Odată depășită faza acestor generalizări, utilizarea unei tehnici de partiționare ne permite să găsim estimația de verosimilitate maximă a inversei matricei de corelație și să evaluăm devianța conexiunilor dintre variabile; cum statistica asociată acestei măsuri urmează asimptotic o distribuție χ^2 , ea oferă baza testării independenței condiționate și, implicit, a construcției grafului legăturilor statistic semnificative

O cale simplă de a defini un model grafic este de a sintetiza toate restricțiile de independență condiționată prin partiționarea vectorului aleator X în 3 subvectori (X^a, X^b, X^c) și de a scrie modelul sub forma: $X^b \perp X^c \mid X^a$. Următoarea propoziție (vezi [7]) are un interes practic deosebit:

Propoziție: Estimația de verosimilitate maximă \hat{V} a matricei de covarianță V , pentru modelul grafic specificat în întregime de $X^b \perp X^c \mid X^a$ este:

$$\hat{V} = \begin{pmatrix} S_{aa} & & & & & \\ S_{ba} & S_{bb} & & & & \\ S_{ca} & S_{ca} S_{aa}^{-1} S_{ab} & S_{cc} & & & \end{pmatrix}$$

unde S desemnează matricea de covarianță de selecție a vectorului $X = (X^a, X^b, X^c)$, matrice organizată pe blocuri potrivit partiționării lui X . Dacă X^a , X^b și X^c sunt p -, q -, respectiv r -dimensionali, atunci măsura:

$$\text{dev}(X^b \perp X^c \mid X^a) = -N \log \frac{\det(S) \cdot \det(S_{aa})}{\det(S_{a \cup b, a \cup b}) \cdot \det(S_{a \cup c, a \cup c})}$$

se numește *devianță* și urmează o distribuție asimptotică χ^2 cu $q \cdot r$ grade de libertate. Dacă $q = r = 1$, această expresie a devianței se simplifică, luând forma:

$$\text{dev}(X^b \perp X^c \mid X^a) = -N \log (1 - \text{cor}_N^2(X^b, X^c \mid X^a))$$

unde $\text{cor}_N(X^b, X^c \mid X^a)$ este coeficientul de corelație parțială de selecție dintre X^b și X^c , dat fiind X^a .

Detalii cu privire la conținutul, specificul și aplicabilitatea acestei clase de metode ale analizei statistice multidimensionale pot fi găsite în [7].

7. Concluzie

Am arătat că analiza datelor multidimensionale în context fuzzy poate fi întemeiată prin introducerea unor concepte metrice adecvate. S-a analizat structura spațiului variabilelor fuzzy-evaluate, cea a spațiului indivizilor descriși de astfel de variabile, precum și modul în care teoria proiectoarelor ortogonale operează pe aceste spații. S-au cercetat, de asemenea, consecințele metodologice pe care extensiile fuzzy ale conceptelor introduse le au pentru trei mari categorii de aplicații: analiza componentelor principale, clasificarea automată și generarea inductivă a modelelor grafice de asociere (dependență condiționată).

Bibliografie

1. GEORGESCU, V.: Proiectarea sistemelor expert în logică fuzzy și logică posibilistă, Ed. Intarf, Craiova, 1995.
2. GEORGESCU, V.: A Fuzzy Generalization of Principal Components Analysis and Automatic Classification. În: Proc. of the Third Congress of SIGEF, 10-13 November 1996, Buenos Aires.
3. MORDESON, J., NAIR, P.: Fuzzy mathematics, Physica-Verlag, Heidelberg, 1998.
4. PEARL, J.: Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference, Morgan Kaufmann Publishers, Inc., 1988.
5. SAPORTA, G.: Probabilités, analyse des données et statistique, Technip, Paris, 1990.
6. WEIR, J. A.: General Integration and Measure II, Cambridge University Press, 1974.
7. WITTAKER, J.: Graphical Models in Applied Multivariate Statistics, John Wiley, New York, 1990.