

Scalarea și analiza dimensională a datelor de tip ordine preferențială: modele *unfolding*

Andrei Gheorghiță*

Universitatea „Lucian Blaga” din Sibiu

Abstract:

This article explores the use of unidimensional unfolding for the scaling and dimensional analysis of preferential choice data. Although rather rarely used in the social sciences, preferential choice data allow the researchers to acquire a meaningful insight into the mechanisms of human choice, namely the identification of relevant criteria for individual choices. Unfolding models are discussed in the larger framework of Coombs' theory of data, with a focus on general purposes of scaling models (identification of underlying sources of variation, measurement, and data reduction). A simulation of unidimensional unfolding on empirical data is extensively considered.

Key words: unfolding, scaling models, dimensional analysis, preferential choice data

Scalare și dimensionalitate

Termenul generic de *scalare* acoperă o plajă largă de modele și metode de analiză statistică ce își propun identificarea surselor de variație în datele empirice cu care operează cercetătorul. Ele au în comun faptul că se bazează pe o metaforă geometrică (Weisberg, 1974: 743), altfel spus asumă posibilitatea unei modelări geometrice a informațiilor provenind din observații empirice. Tehnicile de scalare sunt folosite în cercetarea empirică pentru cel puțin trei categorii de rațiuni (Coombs, 1964; Weisberg, 1974; McIver și Carmines, 1981; Bădescu, 1999). În primul rând, ele pot fi folosite pentru a descrie structura unor date empirice, prin identificarea dimensiunilor latente care stau în spatele variației acestora. Scopul este practic unul explorator, iar rezultatul poate fi identificarea unei dimensiuni latente (unidimensionalitate) sau a mai multora (multidimensionalitate) care stau la baza variației. Spre exemplu, putem găsi o dimensiune ideologică (stânga-dreapta) care să explice variațiile în intențiile de vot ale indivizilor pentru o mulțime dată de partide politice sau putem identifica simultan și alte dimensiuni latente (cum ar fi libertarianism-autoritar). În al doilea rând, scalarea poate avea drept obiectiv măsurarea comportamentelor/atitudinilor individuale, prin dezvoltarea unei scale pe care indivizilor li se conferă scoruri. Aceasta este situația unui sociolog care construiește o scală a statusului socio-economic pe care să poziționeze indivizii pornind de la anumite variabile atitudinale și comportamentale (McIver și Carmines, 1981: 9). În al treilea rând, finalitatea scalării poate fi în mod explicit reducerea complexității datelor, prin diminuarea numărului de variabile în condițiile păstrării aceleiași structuri a datelor (Bădescu, 1999: 254).

Modelele de scalare pot fi folosite pentru a scala persoane (indivizii primesc scoruri pe o scală prin combinarea răspunsurilor/valorilor individuale), stimuli (caracteristici ale obiectelor primesc scoruri prin scalarea valorilor percepute de

* Adresa de corespondență: andrei.gheorghita@ulbsibiu.ro.

către mai mulți indivizi) sau răspunsuri ale indivizilor la stimuli (răspunsul va varia în funcție de stimul, dar și de poziția proprie a individului în legătură cu caracteristica în cauză). Pentru fiecare situație, doar anumite modele de scalare sunt potrivite.

Totodată, așa cum observam anterior, modelele de scalare pot genera soluții unidimensionale sau multidimensionale, în funcție nu doar de natura datelor, ci și de natura metodei/tehnicii în discuție. Vorbim despre scalare unidimensională atunci când este întemeiată presupunerea unei unice dimensiuni fundamentale latente în spatele unui set de date empirice (McIver și Carmines, 1981: 13). Atunci când soluția unidimensională pare a fi insuficientă pentru a explica structura datelor, apare necesitatea unei abordări multidimensionale (Weisberg, 1974: 745), implicând plasarea obiectelor într-un spațiu cu mai multe dimensiuni, definite pe baza proprietăților acestora (McIver și Carmines, 1981: 13). Astfel, *dimensionalitatea datelor* trebuie definită ca „numărul de surse distincte și interesante de variație între obiecte” (Jacoby, 1991: 27). Analiza dimensionalității implică din partea cercetătorului considerarea simultană a două categorii de aspecte: (a) numărul caracteristicilor după care diferă între ele obiectele mulțimii și (b) relevanța acestora pentru obiectivele investigației științifice.

Tipuri de date

Sugeram anterior că există o legătură între tipul de date aflate la dispoziția cercetătorului și tehnicile de scalare care li se pot aplica. Pentru o dezvoltare a subiectului, o scurtă incursiune în *teoria datelor* este absolut necesară. O contribuție esențială la dezvoltarea acestui domeniu îi revine lui Clyde H. Coombs, care publică în 1964 extrem de influentul studiu „A Theory of Data”, bazându-se exclusiv pe o interpretare geometrică a datelor. Conform acestei viziuni, orice observație empirică presupune o comparație între două entități, care pot fi reprezentate ca puncte într-un spațiu. Poziționarea reciprocă a punctelor în acel spațiu depinde de modul în care analistul alege să interpreteze natura comparației dintre respectivele entități (Jacoby, 1991: 15). Spre exemplu, observația potrivit căreia „candidatul A este social-democrat” ar putea fi transpusă geometric printr-o poziționare apropiată în spațiu a punctelor corespunzătoare „candidatului A” și statutului de „social-democrat”. Sau, observația potrivit căreia „candidatul A obține mai multe voturi decât candidatul B” poate implica o reprezentare geometrică în care punctul „A” ocupă în spațiu o poziție mai apropiată de una din extremități decât punctul „B”. Astfel, se poate observa că natura datelor determină modul în care modelul geometric va fi construit pornind de la observațiile empirice (Jacoby, 1991: 15). În acest mod, reprezentarea geometrică va funcționa ca strategie de modelare abstractă a datelor.

În viziunea lui Coombs, datele pot fi clasificate pornind de la două criterii:

„(1) Cele două elemente constitutive ale perechii pot fi extrase din *mulțimi diferite*¹ (spre exemplu, un student și o întrebare la un test, un consumator și un produs, un stimul și un răspuns) sau pot fi extrase din *aceeași mulțime* (spre exemplu, studentul A și studentul B care completează același test, marca X și marca Y dintr-un set de produse de consum, stimulul 1 și stimulul 2 dintr-un pachet experimental).

¹ Este vorba despre entități de naturi diferite.

(2) Comparația dintre entitățile din pereche implică o *relație de dominanță* (spre exemplu, un student răspunde corect la întrebarea unui test, un cobai de laborator parcurge un labirint mai repede decât un altul, magnitudinea unui stimul depășește un anumit nivel marcat pe un instrument de măsură) sau o *relație de proximitate* (spre exemplu, două produse conțin un același ingredient, un membru al unui grup îl selectează pe altul ca partener de activitate, un răspuns specific însoțește un stimul dat).” (Coombs, Dawes și Tversky, 1970, apud. Jacoby, 1991: 16).

Cele două distincții dihotomice pot fi transpuse cu ușurință în plan grafic². Intersectând cele două criterii, Coombs definește patru mari tipuri de date: (a) *date de tip stimul unic*; (b) *date de tip comparație de stimuli*; (c) *date de similaritate* și (d) *date de tip alegere preferențială* (Figura 1).

În categoria *datelor de tip stimul unic* intră, în general, informațiile provenind din categoria măsurătorilor. Elementele sunt de același tip, iar relația dintre ele una de dominație. Cele două mulțimi de puncte vor reprezenta obiectele măsurate și, respectiv, unitățile de înregistrare ale instrumentului de măsură. Spre exemplu, dacă un obiect are 10 centimetri, atunci lungimea sa va domina toate semnele unei rigle situate mai jos de cel care indică 10 cm și va fi dominată de toate semnele superioare acestuia. Datele de acest tip pot fi modelate apelând la scale sumative, scale cumulative, analiză factorială și analiză cluster (Bădescu, 1999: 255).

		Perechea de puncte din observație	
		Aceeași mulțime	Mulțimi diferite
Relația dintre punctele din pereche	Domație	<i>Date de tip comparație de stimuli</i>	<i>Date de tip stimul unic</i>
	Proximitate	<i>Similarități</i>	<i>Alegere preferențială</i>

Figura 1: Cele patru tipuri de date conform teoriei lui Coombs

Sursă: Jacoby, 1991:18.

Datele de tip comparație de stimuli sunt specifice situațiilor de comparare a unor obiecte similare pe baza unei caracteristici comune. Astfel, individului îi este prezentată o mulțime de stimuli, cerându-i-se să îl selecteze pe acela care are mai mult/mai puțin din respectiva caracteristică decât ceilalți (McIver și Carmines, 1981: 12). Se instituie astfel o relație de dominație după acea caracteristică, ce poate fi modelată geometric ca ordonare a punctelor corespunzând celor doi sau mai mulți stimuli după o axă numerică (Jacoby, 1991: 19). În această categorie de date intră

² Dacă elementele perechii provin din seturi diferite, spațiul se va numi *reunit* ('*joint space*'), deoarece va conține două seturi diferite de puncte (câte unul pentru fiecare entitate „observată” repetat). Dacă elementele provin din același set, atunci punctele se vor găsi într-un *spațiu obiect* ('*object space*'). Dacă entitățile sunt legate printr-o relație de dominanță, aceasta se va reflecta în ordonarea punctelor în spațiu. Punctul asociat entității dominante va fi amplasat într-o poziție mai apropiată de o extremitate (de obicei, mai mare numeric) după o dimensiune. Proximitatea este modelată ca distanță între puncte. Cu cât cele două obiecte sunt mai apropiate, cu atât distanța dintre punctele asociate lor devine mai mică și vice-versa. (Jacoby, 1991: 17)

situațiile în care individului i se cere să aleagă cea mai dulce dintre două tablete de ciocolată ori cel mai economic dintre două autoturisme, fără a fi implicată în vreun fel în alegere preferința sa. Altfel spus, selecția individuală va reflecta exclusiv diferențele dintre stimuli.

În cazul *datelor de similaritate*, avem de-a face cu situația în care perechi de stimuli de același tip sunt evaluați din perspectiva a cât de similari sunt. Modelarea se face numai sub aspectul distanței și nicidecum al ordinii. Cu cât stimulii sunt mai similari, cu atât apropierea (proximitatea) dintre ei crește și invers. Astfel, dacă asemănarea dintre autoturismele A și B este mai mare decât cea dintre autoturismele A și C, aceasta înseamnă că A seamănă mai mult cu B decât cu C, deci punctul A (ca reprezentare geometrică) va fi situat mai aproape de B decât de C. În procesul de evaluare a similarităților, indivizilor nu li se oferă nici un fel de indicații asupra dimensiunilor sau criteriilor pe care să le folosească (McIver și Carmines, 1981: 12), identificarea lor ulterioară fiind la latitudinea cercetătorului. Pentru datele de acest tip se aplică modelele de scalare multidimensională.

A patra categorie de date, în viziunea lui Coombs, o reprezintă cele *de tip alegere preferențială*. Se aplică comportamentelor de tip preferențial: cu cât unui individ îi „place” mai mult sau „preferă” un anumit stimul, cu atât este mai mare apropierea (proximitatea) dintre subiect și acel stimul. Din punct de vedere geometric, proximitățile sunt reprezentate ca distanțe între puncte într-un spațiu reunit. Creșterea proximității dintre un subiect și un stimul corespunde unei descreșteri a distanței dintre punctul asociat subiectului și punctul asociat stimulului. Informația conținută într-o singură alegere preferențială nu oferă nici un fel de informație în legătură cu ordonarea subiectului și a stimulilor în spațiu (Jacoby, 1991: 18-22). O situație de acest gen ar apărea, spre exemplu, atunci când unui individ X i s-ar cere să așeze în ordinea preferințelor candidații A, B, C și D, care concurează pentru funcția de primar al unei localități. Cu cât unul dintre candidați ar fi plasat mai sus în ordinea preferințelor, cu atât punctul asociat acestuia va fi mai apropiat în spațiul reunit de punctul corespunzător subiectului, însă identificarea criteriului/criteriilor de ordonare reprezintă o provocare adresată cercetătorului. Pentru scalarea acestui tip de date se aplică cel mai frecvent modelele numite *unfolding*.

Principii generale ale modelelor unfolding

Metoda *unfolding* încearcă să gestioneze datele de tip *alegere preferențială*. Este vorba despre situații în care unor subiecți umani li se oferă un set de stimuli și aceștia trebuie să-i ordoneze în funcție de preferințe. Prin *unfolding*, cercetătorul încearcă să identifice factorii care îi determină pe subiecți în alegerea ordinii de preferințe. Altfel spus, ce au oamenii în minte atunci când fac o astfel de alegere? Poate exista o *dimensiune* care gestionează alegerea (*unfolding* unidimensional) sau *mai multe* (*unfolding* multidimensional).

Există două strategii de a culege date de tip alegere preferențială. Dacă avem un număr redus de stimuli, subiecților li se poate cere să îi așeze într-o ordine de preferințe. Dacă însă avem un număr mai mare de stimuli, aceștia vor fi prezentați subiecților în perechi, cerându-li-se să își exprime preferința pentru un stimul din fiecare pereche posibilă. Pentru respondent, exprimarea preferințelor în perechi este, în mod evident, mai facilă. Pentru cercetător însă, există un risc semnificativ ca o bună parte din subiecți să nu respecte logica tranzitivității și, astfel, o bună parte a

datelor culese să fie distorsionate. Dintr-un atare motiv, este probabil ca, operând cu același set de stimuli, datele obținute să fie diferite, într-o mai mare sau mai mică măsură.

În analiza dimensională a datelor prin tehnica unfolding, fiecare stimul va fi reprezentat ca un punct pe o axă de tipul *îmi place – nu îmi place* ('like – dislike'). Fiecare axă de acest gen va reprezenta, în analiză, câte o dimensiune a alegerii, altfel spus ca o sursă de variabilitate a preferințelor. De partea cealaltă, fiecare subiect va fi reprezentat pe acea axă printr-un *punct ideal*, reprezentând punctul de maximă preferință al individului în raport cu dimensiunea respectivă. Semnificația punctului ideal pentru un individ este următoarea – este punctul în care dacă ar fi poziționat un stimul, atunci acel stimul ar fi preferat de respectivul individ în raport cu oricare alt stimul. El „măsoară” poziționarea fiecărui individ în raport cu acea dimensiune.




Figura 2: Cum pot fi „dezdoite” două scale de preferințe individuale (I1 și I2) pentru a forma scala comună (J), respectiv cum poate fi „îndoită” scala comună (J) pentru a reprezenta scalele preferințelor individuale (I1 și I2)

Notă: A, B, C, D, E reprezintă stimulii individuali, iar I1 și I2 pozițiile a doi subiecți.

Sursă: McIver și Carmines, 1981: 73.

Modelul unfolding urmează o regulă simplă: dacă un subiect preferă stimulul A stimulului B, atunci distanța de la punctul său ideal la A va fi mai mică decât distanța de la punctul său ideal la B:

$$\text{dist}(I, A) < \text{dist}(I, B)$$

Denumirea de „unfolding” ('to fold' din limba engleză poate fi tradus prin a *îndoi* și 'to unfold' prin a *dezdoi*) asociată modelului sugerează tocmai principiul de modelare geometrică a datelor de tip alegere preferențială. Astfel, asumția

fundamentală este aceea potrivit căreia n axe ale preferințelor individuale (în care punctul ideal al individului este plasat la una dintre extremități) ar putea fi „dezdoite” pe o unică scală a preferințelor (soluția unidimensională)³, cu care toate axele să fie consistente și care să reflecte dimensiunea folosită pentru ordonarea stimulilor (Figura 2). Pornind de la regula enunțată mai sus, vor face obiectul reprezentării grafice pe scala unică toate punctele asociate celor k (stimuli), respectiv n (indivizi).

Simularea unui caz de *unfolding* unidimensional

Pentru a exemplifica tehnica de *unfolding*⁴, să imaginăm situația în care unui număr de n subiecți (reprezențați pe linii în matricea datelor) li se cere să așeze cinci localități în ordinea preferinței de stanilire a domiciliului (deci cinci stimuli reprezentați pe coloane în matricea datelor): Iași (I), Bacău (B), Suceava (S), Onești (O) și Târgu Ocna (T). Intrările în celulele matricei vor reprezenta poziția stimulului de pe coloană în ordinea de preferințe a individului de pe linie: 1 reprezintă prima preferință, 2 a doua, 3 a treia ș.a.m.d. Rezultă o matrice de proximitate: cu cât este mai mic un scor, cu atât va fi mai „apropiată” individului acea localitate (Figura 3).

Fie cazul unidimensional, în care asumăm premisa că ordinele preferențiale au în background o unică dimensiune evaluativă. Altfel spus, fiecare subiect compară stimulii folosind același criteriu. Evident, vom opera cu o singură axă de tipul *îmi place – nu îmi place*, reprezentând unica dimensiune latentă. Într-o primă etapă, vom reprezenta pe axă punctele asociate celor cinci stimuli (I, B, S, O și T). La acest nivel intervine o primă problemă – în ce ordine vom reprezenta stimulii pe axa *îmi place – nu îmi place*? Pentru aceasta, primul pas îl constituie analiza ordinilor de preferințe exprimate de către subiecți.

	I	B	S	O	T	Ordine
Individ 1	3	1	2	4	5	BSIOT
Individ 2	5	4	2	1	3	OSTBI
Individ 3	5	3	2	1	4	OSBTI
Individ 4	1	2	3	4	5	IBSOT
Individ 5	4	1	2	3	5	BSOIT
Individ n

Figura 3: Exemplu de matrice a datelor pentru *unfolding*

Pentru k stimuli vor exista întotdeauna $k!$ ordonări posibile. Dacă însă modelul nostru asumat unidimensional este corect (implicit respectă și regula tranzitivității), în practică vor fi posibile mai puține ordonări, adică doar:

$$\frac{k(k-1)}{2} + 1$$

³ Sau pe câteva, pentru soluția multidimensională.

⁴ Simularea urmează succesiunea etapelor de modelare *unfolding* prezentate de William J. Jacoby în cursul „Scaling and Dimensional Analysis”, Ann Arbor, MI: ICPSR Program in Social Statistics, 2002. Materialele de curs sunt disponibile online la adresa: <http://polisci.msu.edu/jacoby/icpsr/scaling>.

ordini preferențiale. În cazul nostru, pentru 5 stimuli, ar trebui să existe cel mult 11 ordini preferențiale valide.


În această etapă, dintre ordinele preferențiale exprimate de către subiecți, urmează să identificăm stimuli care apar cel mai adesea pe ultima poziție, deci care sunt cel mai frecvent cel mai puțin preferați. Să exemplificăm pe cazul ideal, în care operăm cu 11 ordini preferențiale consistente cu un model unidimensional, așa cum sunt ele exprimate de 11 subiecți:

BSIOT
OSTBI
OSBTI
IBSOT
BSOIT
TOSBI
BISOT
SBOTI
SBOIT
SOBTI
OTSBI

Pentru un model unidimensional pur, pe ultima poziție nu se vor putea afla decât 2 stimuli, în cazul nostru T și I. Dacă în ordinele preferențiale exprimate de către subiecți apar mai mult de 2 stimuli pe ultimele poziții exprimate individual, înseamnă fie că modelul este multidimensional, fie că se încalcă regula tranzitivității. Odată identificați cei 2 stimuli cel mai puțin preferați, am identificat *cele două extreme ale axei* – pentru cazul nostru T și I.

În a doua etapă se caută ordinele preferențiale care au cei doi stimuli pe primul loc. Odată identificate, acestea ar trebui să fie reciproc imagini în oglindă. Studiind răspunsurile celor 11 respondenți, ne oprim asupra următoarelor ordini preferențiale: IBSOT și TOSBI. Dacă, pentru un model aparent unidimensional, identificăm două sau mai multe perechi de ordini preferențiale imagini în oglindă având stimuli extremi pe prima poziție, atunci este foarte probabil ca modelul nostru să fie totuși multidimensional.

Revenind la exemplul nostru, observăm că IBSOT și TOSBI sunt imagini în oglindă. Acestea vor fi ordinele de poziționare a stimulilor pe axă, pornind de la o extremă a sa ori de la cealaltă. Reprezentând grafic axa, obținem:



Trebuie făcută o observație importantă: punctul ideal al oricărui respondent care a ales ordinea preferențială IBSOT va fi situat pe axă la stânga lui I, în timp ce punctul ideal al oricărui respondent care alege TOSBI va fi situat pe axă la dreapta lui T.

În a treia etapă, pentru a ușura operațiile ulterioare, simbolurile asociate stimulilor, în ordinea poziționării lor pe axă, sunt înlocuite cu litere ordonate alfabetic. Astfel, reetichetăm stimuli după cum urmează:

I (Iași) devine	A
B (Bacău) devine	B
S (Suceava) devine	C
O (Onești) devine	D

T (Târgu Ocna) devine E.

Pentru etapele următoare, vom opera cu un concept nou, și anume acela de *punct median*. Punctul median este acel punct care împarte un interval în două subintervale de dimensiuni identice. Spre exemplu, pe axa stimulilor, intervalul dintre punctele A și B va avea punctul median notat AB. Pentru cinci stimuli, obținem combinații de 5 luate câte 2 puncte mediane, deci 10 puncte mediane: AB, AC, AD, AE, BC, BD, BE, CD, CE și DE, care vor împărți axa în 11 *subintervale*. Importanța acestor subintervale este enormă, prin faptul că unui punct ideal plasat oriunde pe un astfel de subinterval îi corespunde *o ordine preferențială și numai una*.

Următoarea etapă constă în identificarea ordinii preferențiale asociate fiecărui subinterval. La acest nivel intervine un subterfugiu metodologic, bazat tocmai pe caracteristica ordinală (la nivel de alfabet) a etichetelor A, B, C, D și E. În acest mod, pentru fiecare *ordine preferențială* putem afla câte puncte mediane lasă la stânga sa și câte la dreapta sa. Cum procedăm? Fie prima ordine preferențială, BSIOT, devenită după recodare BCADE. Începem cu prima literă din ordinea preferențială și ne deplasăm spre dreapta numărând literele care o precedă în alfabet. În cazul lui B o precedă doar A, deci îi asociem un scor de 1:

B 1

Continuăm cu a doua literă din ordinea preferențială și repetăm procedura. În cazul lui C, mergând spre dreapta, observăm că o precedă doar A, deci îi asociem un scor de 1:

C 1

Repetăm pentru a treia literă, A, și apoi pentru a patra, D:

A 0

D 0

Totalizând aceste scoruri, obținem un scor de 2 asociat ordinii preferențiale, ce trebuie interpretat ca *numărul de puncte mediane situate la stânga*.

Procedura se reia pentru toate ordinele preferențiale consistente cu modelul unidimensional:

BCADE=2

DCEBA=8

DCBEA=7

ABCDE=0

BCDAE=3

EDCBA=10

BACDE=1

CBDEA=5

CBDAE=4

CDBEA=6

DECBA=9

Așezând crescător ordinele preferențiale în funcție de numărul de puncte mediane la stânga, putem să le ordonăm/ poziționăm pe axa stimulilor. De la stânga la dreapta, ordinele preferențiale vor fi:

ABCDE 0

BACDE 1

BCADE 2

BCDAE 3

CBDAE 4

CBDEA	5
CDBEA	6
DCBEA	7
DCEBA	8
DECBA	9
EDCBA	10

Rămâne să identificăm punctele mediane ce despart subintervalele asociate ordinilor preferențiale de mai sus. Aceasta se va realiza urmărind perechile de litere inversate în fiecare două ordini preferențiale consecutive. Astfel, pentru primele două ordini preferențiale, ABCDE și BACDE, observăm inversarea perechii de litere AB (respectiv BA). Aceasta înseamnă că subintervalele definite prin ordinele de preferințe ABCDE și, respectiv, BACDE vor fi separate de punctul median AB. Procedura se repetă pentru toate celelalte subintervale:

Ordini de preferințe	Numărul de puncte mediane la stânga	Puncte mediane intersectate (de graniță)
ABCDE	0	
		AB
BACDE	1	
		AC
BCADE	2	
		AD
BCDAE	3	
		BC
CBDAE	4	
		AE
CBDEA	5	
		BD
CDBEA	6	
		CD
DCBEA	7	
		BE
DCEBA	8	
		CE
DECBA	9	
		DE
EDCBA	10	

Figura 4: Ordini de preferințe și puncte mediane

În aceste condiții, putem ordona pe axă punctele mediane. Ordonând aceste puncte, introducem informație spațială în ordinea stimulilor, în sensul că le estimăm nu doar ordinea, ci și „distanțele” care îi separă după dimensiunea analizată. Această etapă precede momentul culminant al analizei de tip *unfolding*, când are loc extragerea de *informație metrică* din date de tip alegere preferențială.

Informația metrică va fi conținută de punctele mediane „îmbrățișate”. Porțiunea liniară de axă cuprinsă între două puncte poate fi interpretată ca un segment. Acesta este definit printr-o anumită lungime. Între punctele mediane putem

considera existența unor segmente pe axa dimensională. Atunci când un astfel de segment este conținut într-un altul mai lung, de aceeași natură, cele patru puncte mediane care definesc extremitățile celor două segmente sunt *puncte mediane îmbrățișate* ('*enveloping midpoints*'). Pentru a ușura înțelegerea conceptului, poate fi avută în vedere analogia cu poezia și utilizarea rimei îmbrățișate.

Înainte de a continua demonstrația, vom introduce o convenție de notare. Dacă \overline{AB} desemnează punctul median al intervalului cuprins între A și B, \overline{AB} va desemna segmentul de linie delimitat prin punctele A și B. În plus, imaginând axa ca fiind „imprimată” cu o unitate de măsură pentru lungime, fiecărui punct îi corespunde o informație metrică de poziționare (abscisă).

Primul pas constă în listarea exhaustivă a segmentelor ce pot fi definite pe axă de către punctele asociate celor cinci stimuli. Vom avea:

- a) segmente de dreaptă primare: \overline{AB} , \overline{BC} , \overline{CD} și \overline{DE} ;
- b) segmente de dreaptă secundare (unesc două segmente de dreaptă primare): \overline{AC} , \overline{BD} și \overline{CE} ;
- c) segmente de dreaptă terțiare (unesc trei segmente de dreaptă primare): \overline{AD} și \overline{CE} .

Al doilea pas constă în compararea lungimilor segmentelor de dreaptă. În acest scop vom recurge la compararea punctelor mediane și nu a segmentelor de dreaptă în sine. Vom putea compara la acest moment doar segmentele de dreaptă care îndeplinesc două condiții, adică: nu au o extremitate comună și nu se suprapun. În continuare, vom parcurge toate combinațiile de două segmente posibile:

1) \overline{AB} vs. \overline{BC}

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

2) \overline{AB} vs. \overline{CD}

Comparăm punctele mediane definite de literele interioare și exterioare din perechea de segmente.⁵ Urmărim ordinea punctelor mediane obținută anterior:

$$AD < BC$$

Operând cu abscise, obținem:

$$AD = \frac{A + D}{2} \text{ și } BC = \frac{B + C}{2}$$

Deci:

$$\frac{A + D}{2} < \frac{B + C}{2}$$

$$A + D < B + C$$

⁵ Pentru fiecare segment de dreaptă literele trebuie ordonate alfabetic.

Scadem la stânga și la dreapta un C:

$$A+D-C < B+C-C$$

$$A+D-C < B$$

Scadem la stânga și la dreapta un A:

$$A-A+D-C < B-A$$

$$D-C < B-A$$

D și C sunt extremitățile segmentului \overline{CD} , deci diferența celor două abscise va da lungimea segmentului. La fel pentru segmentul \overline{AB} . De unde rezultă:

$$\overline{CD} < \overline{AB}$$

$$3) \overline{AB} \text{ vs. } \overline{DE}$$

$$AE < BD$$

$$\frac{A+E}{2} < \frac{B+D}{2}$$

$$A+E < B+D$$

$$E < B+D-A$$

$$E-D < B-A$$

$$\overline{DE} < \overline{AB}$$

$$4) \overline{BC} \text{ vs. } \overline{CD}$$

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

$$5) \overline{BC} \text{ vs. } \overline{DE}$$

$$CD < BE$$

$$C+D < B+E$$

$$C+D-B < E$$

$$C-B < E-D$$

$$\overline{BC} < \overline{DE}$$

$$6) \overline{CD} \text{ vs. } \overline{DE}$$

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

$$7) \overline{AC} \text{ vs. } \overline{BD}$$

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

$$8) \overline{BD} \text{ vs. } \overline{CE}$$

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

$$9) \overline{AC} \text{ vs. } \overline{CE}$$

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

10) \overline{AD} vs. \overline{BE}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

Segmentele de dreaptă terțiare au o extremitate comună sau se suprapun parțial cu orice alt segment. Din acest motiv le vom exclude din toate comparațiile ulterioare.

11) \overline{AB} vs. \overline{AC}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

12) \overline{AB} vs. \overline{BD}

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

13) \overline{AB} vs. \overline{CE}

$$BC < AE$$

$$B+C < A+E$$

$$B-A < E-C$$

$$\overline{AB} < \overline{CE}$$

14) \overline{BC} vs. \overline{AC}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

15) \overline{BC} vs. \overline{BD}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

16) \overline{BC} vs. \overline{CE}

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

17) \overline{CD} vs. \overline{AC}

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

18) \overline{CD} vs. \overline{BD}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

19) \overline{CD} vs. \overline{CE}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

20) \overline{DE} vs. \overline{AC}

$$AE < CD$$

$$A+E < C+D$$

$$A+E-D < C$$

$$E-D < C-A$$

$$\overline{DE} < \overline{AC}$$

21) \overline{DE} vs. \overline{BD}

Comparația nu este posibilă, deoarece segmentele au o extremitate comună.

22) \overline{DE} vs. \overline{CE}

Comparația nu este posibilă, deoarece segmentele se suprapun parțial.

Recapitulând, am obținut:

$$\overline{CD} < \overline{AB}$$


$$\overline{DE} < \overline{AB}$$

$$\overline{BC} < \overline{DE}$$

$$\overline{AB} < \overline{CE}$$

$$\overline{DE} < \overline{AC}$$

Așezăm segmentele într-o diagramă, în care un segment de dreaptă este mai lung cu cât este mai sus amplasat.



În plus față de informația transmisă prin poziționare, în diagramă, relației de comparație între perechile de segmente este reprezentată printr-o linie care unește respectivele segmente.

Cum obținem informația metrică? Răspunsul este unul simplu: pe diagramă atașăm ca lungimi pentru segmentele reprezentate orice seturi de numere care sunt consistente cu modelul. A formula în termeni de „orice seturi de numere” poate părea o asumție cu o raționalitate destul de neclară. Însă, poate fi demonstrat statistic că, orice seturi de numere consistente cu modelul am atașa, fiecare set va fi foarte aproape de o *transformare liniară*⁶ a oricărui alt set de numere consistent cu modelul (un coeficient de corelație $r > 0,9$).

Să pornim de la cel mai scurt dintre segmentele comparate, \overline{BC} , și să îi acordăm, în mod absolut arbitrar, valoarea 1:

$$\overline{BC} = 1$$

La un prim nivel, segmentul \overline{BC} este mai scurt decât \overline{DE} și \overline{CD} , segmente care, însă, nu pot fi comparate între ele. Deci, singura condiție impusă de model

⁶ De tipul $y_i = a + bx_i$.

(diagramă) este ca cele două segmente să fie mai lungi decât \overline{BC} . Să asumăm, din nou arbitrar, că ele iau valorile:

$$\begin{aligned} \overline{CD} &= 4 \\ \overline{DE} &= 5 \end{aligned}$$

În aceste condiții, putem calcula și lungimea segmentului \overline{CE} , care va fi suma lungimilor segmentelor enumerate anterior:

$$\overline{CE} = \overline{CD} + \overline{DE} = 4 + 5 = 9$$

Deci:

$$\overline{CE} = 9$$

În acest moment, lipsesc evaluări metrice pentru două segmente, \overline{AB} și \overline{AC} . Din punct de vedere al lungimii, asupra segmentului \overline{AB} acționează două categorii de constrângeri din partea modelului: (a) trebuie să fie mai lung decât \overline{CD} și \overline{DE} (deci mai lung de 5 unități), dar mai scurt decât suma lor, \overline{CE} (deci mai scurt de 9 unități) și (b) trebuie să fie mai scurt decât \overline{AC} , deoarece este doar o parte a acestuia ($\overline{AC} = \overline{AB} + \overline{BC}$).

Răspunzând acestor constrângeri, să îi acordăm segmentului \overline{AB} lungimea de 6 unități:

$$\overline{AB} = 6$$

În aceste condiții:

$$\overline{AC} = \overline{AB} + \overline{BC} = 6 + 1 = 7$$

Deci:

$$\overline{AC} = 7$$

Recapitulând, am asumat:

$$\begin{array}{c} \overline{CE} (9) \\ | \quad \overline{AC} (7) \\ \overline{AB} (6) \quad | \\ | \quad \backslash \quad | \\ \overline{CD} (4) \quad \overline{DE} (5) \\ \quad \quad | \\ \quad \quad \overline{BC} (1) \end{array}$$

Aceste date ne permit să localizăm metric cei cinci stimuli (A, B, C, D și E) pe axa reprezentând dimensiunea studiată. Deoarece A este stimulul aflat cel mai la stânga⁷, pentru a ne ușura calculele, putem să îl asumăm ca origine, altfel spus:

$$A = 0$$

Punctul B va fi la 6 unități de A, deoarece $\overline{AB} = 6$, iar C la 7 unități, deoarece $\overline{AC} = 7$. Deci:

$$B = 6$$

⁷ Sau cel mai la dreapta, dacă am porni de la imaginea în oglindă.

$$C=7$$

Punctul D va fi situat la 4 unități spre dreapta de punctul C, deoarece $\overline{CD}=4$, iar E la 9 unități, deoarece $\overline{CE}=9$. De unde:

$$D=C+4=7+4=11 \qquad D=11$$

și:

$$E=C+9=7+9=16 \qquad E=16$$

Reprezentând grafic, obținem:




Figura 5: Poziționarea stimulilor pe scală în baza informației metrice

Analizând dimensionalitatea pentru cazul alegerilor preferențiale, ne propunem să identificăm criteriile la care recurg subiecții atunci când evaluează respectivii stimuli. În spatele fiecărei dimensiuni stă *un criteriu* sau un *cumul de criterii*, care va fi/vor fi cu atât mai semnificativ/-e cu cât ordinele preferențiale consistente cu acea dimensiune sunt mai frecvente.

Revenind la modelul nostru, presupus unidimensional, următorul pas constă în identificarea dimensiunii care „gestionează” ordinele preferențiale analizate. Ca și în cazul altor tehnici de scalare și analiză dimensională, criteriile rezultate din analiză nu se dezvăluie singure, nu sunt evidente și, nicidecum, transparente. Este nivelul la care intervin maximal experiența, flerul și imaginația cercetătorului. De asemenea, trebuie subliniat că nu întotdeauna putem avea certitudinea că interpretarea aleasă este optimă și, nicidecum, unică.

O privire atentă asupra rezultatelor prezentei analize va indica faptul că, cel mai probabil, criteriul utilizat de către respondenții noștri în evaluarea celor cinci categorii de orașe este cel al *mărimii localității* (cu toate implicațiile conexe asupra stilului de viață, resurselor și oportunităților), mergând de la un oraș foarte populat cum este Iași (I) și până la dimensiunile extrem de restrânse ale unui oraș predominant turistic cum este Târgu Ocna (T). Mai mult, informația metrică extrasă ne permite să comparăm *diferențele percepute* de respondenți între cele cinci localități. Spre exemplu, sub aspectul implicațiilor mărimii orașului, diferența percepută între Bacău (B) și Suceava (S) este de patru ori mai mică decât cea dintre Suceava (S) și Onești (O). Se cuvine subliniat încă o dată că relativa simplitate a interpretării criteriului de ordonare este dată de caracterul particular al datelor „fabricate” și totodată ideale pe care s-a construit acest exemplu. În practică însă, datele reale nu vor furniza niciodată certitudinea relevanței și unicității soluției găsite.

Ultima etapă în demersul nostru rezidă în localizarea (metrică) a punctelor ideale ale respondenților după dimensiunea analizată. Astfel, valoarea numerică asociată fiecărei ordini preferențiale alese va fi media aritmetică a valorilor punctelor mediane care mărginesc subintervalul asociat respectivei ordini preferențiale. Să exemplificăm cu situația unui individ care alege ordinea preferențială BACDE. Subintervalul asociat acestei ordini preferențiale este

delimitat de punctele mediane AB și AC, localizate numeric la 3 și, respectiv, 3,5 unități de origine (A):

$$AB = \frac{A + B}{2} = \frac{0 + 6}{2} = 3$$

și:

$$AC = \frac{A + C}{2} = \frac{0 + 7}{2} = 3,5$$

Potrivit regulii indicate anterior, punctul ideal al unui individ care alege ordinea preferențială BACDE va fi situat la:

$$I_{BACDE} = \frac{AB + AC}{2} = \frac{3 + 3,5}{2} = 3,25$$

unități de origine. Aceste valori numerice ale punctelor ideale individuale, odată identificate, pot face obiectul altor analize de ordin cantitativ. Dacă replicăm procedura pentru ceilalți 10 indivizi, obținem informația metrică privind poziționarea pe axă a tuturor punctelor ideale corespunzătoare celor 11 ordini preferențiale (Tabel 1).

Ordine de preferințe	Puncte mediane învecinate		Punct ideal	Ordine stimuli corespunzătoare
BCADE	AC=3,5	AD=5,5	4,50	BSIOT
DCEBA	BE=11	CE=11	11,25	OSTBI
DCBEA	CD=9	BE=11	10	OSBTI
ABCDE	A=0	AB=3	1,50	IBSOT
BCDAE	AD=5,5	BC=6,5	6	BSOIT
EDCBA	DE=13,5	E=16	14,75	TOSBI
BACDE	AB=3	AC=3,5	3,25	BISOT
CBDEA	AE=8	BD=8,5	8,25	SBOTI
CBDAE	BC=6,5	AE=8	7,25	SBOIT
CDBEA	BD=8,5	CD=9	8,75	SOBTI
DECBA	CE=11,5	DE=13,5	12,5	OTSBI

Tabel 1: Informație metrică privind punctele ideale corespunzătoare celor 11 ordini preferențiale consistente cu modelul unidimensional

Odată extrasă informația metrică, se poate obține reprezentarea geometrică fidelă a punctelor asociate stimulilor, punctelor mediane și, respectiv, intervalelor de ordine preferențială pe axa identificată, în cazul nostru cea a *mărimii localității* (Figura 6), practic ultima etapă a modelării unfolding.

Sintetizând, modelele de unfolding unidimensional își propun scalarea simultană a stimulilor și indivizilor, astfel încât ordinele preferențiale ale diferiților indivizi să fie consistente cu pozițiile alocate respectivilor indivizi pe un continuum (McIver și Carmines, 1981: 84-85). Această metodă are la bază principiul proximității în modelarea geometrică, materializat în reflectarea proximității psihologice între stimul și individ (relevată de ordonarea preferințelor) în apropiere între punctele corespunzătoare acestora într-un spațiu unidimensional. În ciuda utilizării mai degrabă rare a acestei metode de scalare în spațiul științelor sociale, există o serie de avantaje ale implementării sale, ce pot fi cu greu ignorate. Avem în

vedere, în primul rând, capacitatea de a integra stimuli și poziții relative ale unor indivizi într-un continuum unidimensional înzestrat cu consistență internă, facilitând astfel identificarea criteriilor latente implicate în alegeri individuale. În al doilea rând, modelele unfolding oferă o cale consistentă de extragere a informației metrice din date de tip ordinal, prin „măsurarea” pozițiilor individuale și ale stimulilor de-a lungul dimensiunii latente identificate. Odată extrasă această informație metrică, ea poate fi integrată în analize suplimentare de ordin statistic.




Figura 6: *Unfolding unidimensional: puncte asociate stimulilor, puncte mediane și intervale de ordine preferențială*

Bibliografie:

- Bădescu, Gabriel (1999) „Metode de reducere a datelor”, în Traian Rotariu (coord.); Gabriel Bădescu; Irina Culic; Elemér Mezei și Cornelia Mureșan, *Metode statistice aplicate în științele sociale*, Iași: Polirom, pp. 254-271.
- Coombs, Clyde H. (1964) *A Theory of Data*, New York: John Wiley and Sons.
- Culic, Irina (2004) *Metode avansate în cercetarea socială. Analiza multivariată de interdependență*, Iași: Polirom.
- Jacoby, William J. (1991) *Data Theory and Dimensional Analysis*, Newbury Park: Sage Publications.
- Jacoby, William J. (1982) „Unfolding the Party Identification Scale: Improving the Measurement of an Important Concept”, în *Political Methodology*, vol. 8, no. 2, pp. 33-59.
- McIver, John P. și Edward G. Carmines (1981) *Unidimensional Scaling*, Newbury Park: Sage Publications.
- Norpoth, Helmut (1979) „The Parties Come to Order! Dimensions of Preferential Choice in the West German Electorate, 1961-1976”, în *The American Political Science Review*, vol. 73, no. 3, pp. 724-736.
- Weisberg, Herbert F. (1974) „Dimensionland: An Excursion into Spaces”, în *American Journal of Political Science*, vol. 18, no. 4, pp. 743-776.