

DIMENSIONALITAT EUCLIDIANA DE LES DISTÀNCIES ULTRAMÈTRIQUES

CARLES M. CUADRAS, FRANCESC CARMONA

UNIVERSITAT DE BARCELONA

Demostrem que tota distància ultramètrica definida en un conjunt de n elements, és representada en un espai euclidià amb dimensió $n-1$. Obtenim també alguns resultats sobre els valors propis de la matriu de productes escalaris associada a la distància.

ULTRAMETRIC DISTANCE; EUCLIDEAN SPACE.

Key words: Multidimensional scaling; Mathematical taxonomy.

1. INTRODUCCIÓ.

Sigui $E = \{1, 2, \dots, n\}$ un conjunt finit. Es diu que $U = (u_{ij})$ és una distància ultramètrica no degenerada sobre E , si u_{ij} representa una distància entre els elements i, j de E -- tal que

- a) $u_{ii} = 0 \quad \forall i \in E,$
- b) $u_{ij} > 0 \quad \forall i \neq j,$
- c) $u_{ij} \leq \max\{u_{ik}, u_{jk}\} \quad \forall i, j, k \in E. \quad (1)$

Es diu que $D = (d_{ij})$ és una distància euclíadiana m -dimensional sobre E si existeix una matriu de coordenades

$$X = \begin{pmatrix} x_{11} & \dots & x_{1m} \\ \dots & & \dots \\ x_{n1} & \dots & x_{nm} \end{pmatrix}$$

on m és el mínim senser tal que

$$d_{ij}^2 = \sum_{h=1}^m (x_{ih} - x_{jh})^2 \quad i, j = 1, \dots, n \quad (2)$$

L'objectiu d'aquest treball és demostrar que tota distància ultramètrica no degenerada sobre un conjunt de n elements és euclíadiana $(n-1)$ -dimensional.

La motivació d'aquesta propietat té relació amb les tècniques multivariables que permeten, mitjançant una transformació lineal, --

ajustar unes coordenades X a unes coordenades Y , resultat de dos mètodes diferents de representació multidimensional de dades. El criteri d'ajust és el dels mínims quadrats i la mesura de comparació és

$$\mu^2 = \text{tr}(X \cdot X') + \text{tr}(Y \cdot Y') - 2\text{tr}(X' \cdot Y \cdot Y' \cdot X) \quad (3)$$

Aquest criteri va ésser establert per Schönenmann i Carroll /9/, Gower /4/, i ha estat -- utilitzat per Mardia /7/, Lingoes i Borg /6/.

Hom sap /1/ que un algorisme de classificació jeràrquica consisteix en modificar una distància inicial $D = (d_{ij})$ fins a obtenir una ultramètrica $U = (u_{ij})$, que aleshores queda representada per un dendrograma (fig. 1). Per tenir - mida de la bona classificació obtinguda, el procediment clàssic consisteix en calcular la correlació cofenètica, és a dir, el coefficient de correlació entre els elements (d_{ij}) i els (u_{ij}) . Com un altra mesura més objectiva, Gower /4/ proposà associar a la distància D una configuració euclidiana representada -- per unes coordenades X , associar a U un altre configuració euclidiana Y , i utilitzar aleshores la quantitat (3). Un aspecte essencial -- d'aquest procediment es que $U = (u_{ij})$ sigui --- realment una distància euclidiana, propietat que Gower /4/ pren com a una conjectura, però que no demostra. Aquest criteri ha estat con-

- Carles M. Cuadras i

- Francesc Carmona - Facultat de Biologia - Dep. de Bioestadística - Universitat de Barcelona - Av. Diagonal, 637
Barcelona.

- Article rebut el Juny del 1983.

siderat per Rohlf /8/ com un dels mètodes -- per a comparar classificacions.




Fig. 1. Exemple de construcció d'una ultramètrica per el mètode del mínim i dendrograma corresponent.

2. CARACTERITZACIÓ DE LA PROPIETAT EUCLIDIANA.

Per reconèixer si $D=(d_{ij})$ és una distància euclidiana, cal aplicar el teorema 1. Siguin

$$\underline{l} = (1, \dots, 1)^T, \quad J = \underline{l} \cdot \underline{l}^T, \quad H = I - \frac{1}{n} J, \quad A = (a_{ij}), \quad (4)$$

essent

$$a_{ij} = -\frac{1}{2} d_{ij}^2,$$

I = matriu identitat d'ordre n .

TEOREMA 1: Considerem la matriu $B=HAH$. Aleshores si B és semi-definida positiva de $m \times m$, D és euclidiana m -dimensional i les coordenades X verificant (2) són els elements d'una matriu $n \times m$ tal que

$$B = XX'$$

Reciprocament, si B té valors propis negatius, aleshores D es distància no euclidiana.

DEMOSTRACIÓ: Veure /1/.

En el cas que D és euclidiana, un procediment per obtenir les coordenades que verifiquen (2) consisteix en trobar els valors propis de B

$$\lambda_1 \geq \dots \geq \lambda_m \geq \lambda_{m+1} = \dots = \lambda_n = 0.$$

Aleshores els vectors propis λ -normalitzats formen les columnes d'una matriu X que ens dona la configuració euclidiana buscada. ---

Aquest procediment s'anomena "mètode de les coordenades principals".

3. DIMENSIONALITAT DE LES ULTRAMÈTRIQUES -- EUCLIDIANES.

Sigui $U=(u_{ij})$ una ultramètrica i f una funció monòtona creixent. Aleshores

$$u_{ij}^* = f(u_{ij})$$

verifica

$$u_{ij}^* \leq u_{i'j}' \text{ si i només si } u_{ij} \leq u_{i'j}. \quad (5)$$

i la propietat (1) segueix essent certa. Darem doncs que dues ultramètriques són equivalents si existeix una funció f verificant -- (5). Indiquem $[u_{ij}]$ la classe de les ultramètriques que són equivalents a u_{ij} . Es evident que les ultramètriques d'una mateixa classe d'equivalència defineixen la mateixa classificació jeràrquica, variant només en l'índex de la jerarquia.

LEMA. Existeix un representant de $[u_{ij}]$ que és distància euclidiana.

DEMOSTRACIÓ: Es conseqüència de que sempre és possible transformar una distància segons una funció monòtona per convertir-la en euclidiana. Dos exemples de transformacions són:

a) Lineal:

$$u_{ij}^* = \alpha u_{ij} + \beta \quad /3/$$

b) Additiva:

$$(u_{ij}^*)^2 = u_{ij}^2 - 2\alpha \quad /5/ \text{ i } /7/$$

Tenim doncs que u_{ij} és euclidiana, o bé -- equivalent a alguna ultramètrica euclidiana. Ara bé, provar que tot altre representant de $[u_{ij}]$ es distància euclidiana, el qual vol dir que qualsevol ultramètrica té la propietat euclidiana, no és tan evident. Els teoremes 2 i 3 ens demostren aquesta - propietat.

TEOREMA 2: Tota ultramètrica euclidiana definida sobre un conjunt E de n elements és $(n-1)$ -dimensional.

DEMOSTRACIÓ: Per hipòtesi, existeixen n punts P_1, \dots, P_n d'un espai euclidià tal que

$$u_{ij} = d(P_i, P_j)$$

on d significa distància euclidiana. Considerem ara els vectors v_1, \dots, v_{n-1} , essent

$$v_i = \overrightarrow{P_1 P_{i+1}} \quad i=1, \dots, n-1.$$

Hem de demostrar que v_1, \dots, v_{n-1} són vectors linealment independents. Ho farem provant que la matriu de productes escalar associada a $\langle v_i \rangle$ és definida positiva.

Suposem que u_{12} és la mínima distància entre els elements de E

$$u_{12} = \min\{u_{ij} \mid i \neq j, i, j \in E\}$$




Fig. 2: El triangle $(1, 2, i+1)$ es isòsceles com a conseqüència de la propietat ultramètrica.

Aleshores (1) implica

$$u_{12} \leq u_{1i+1} = u_{2i+1}$$

i per tant tenim (fig. 2) que $v_i - v_1 = \overrightarrow{P_1 P_{i+1}}$ verifica

$$\|v_i - v_1\| = \|v_i\|$$

i aleshores, indicant $v_h \cdot v_k$ el producte escalar euclidià, tenim

$$v_i \cdot v_i = v_i \cdot v_i + v_1 \cdot v_1 - 2v_i \cdot v_1$$

doncs

$$v_1 \cdot v_i = \frac{1}{2} v_1 \cdot v_1 = \frac{u_{12}^2}{2} = a \quad i=2, \dots, n-1$$

A més a més, de

$$\|v_i - v_j\|^2 = \|v_i\|^2 + \|v_j\|^2 - 2v_i \cdot v_j$$

deduïm

$$v_i \cdot v_j = \frac{1}{2}(u_{1i+1}^2 + u_{1j+1}^2 - u_{i+1j+1}^2) \quad 1 < i \neq j$$

L'expressió de la matriu simètrica \sum , -- d'ordre $(n-1) \times (n-1)$, de productes escalar, és

$$\sum = \begin{pmatrix} 2a & a & a & a \\ a & u_{13}^2 & (u_{13}^2 + u_{14}^2 - u_{34}^2)/2 & (u_{13}^2 + u_{15}^2 - u_{35}^2)/2 \\ a & (u_{13}^2 + u_{14}^2 - u_{34}^2)/2 & u_{14}^2 & (u_{14}^2 + u_{15}^2 - u_{45}^2)/2 \\ a & (u_{13}^2 + u_{15}^2 - u_{35}^2)/2 & (u_{14}^2 + u_{15}^2 - u_{45}^2)/2 & \dots \end{pmatrix} \quad (6)$$

Seguidament demostrarem per inducció que el més petit valor propi λ_1 de \sum verifica

$$\lambda_1 \geq \frac{u_{12}^2}{2} = a \quad (7)$$

Sigui

$$P(\lambda) = \det(\sum - \lambda I)$$

el polinomi característic. Per a $n=3$ és

$$P(\lambda) = \lambda^2 - (2a + u_{13}^2)\lambda + (2au_{13}^2 - a^2),$$

i la seva derivada verifica:

$$P'(\lambda) = -(u_{13}^2 - \lambda) - (u_{12}^2 - \lambda) < 0 \text{ si } \lambda \leq a.$$

A més

$$P(a) = a(u_{13}^2 - u_{12}^2) \geq 0.$$

Això ens demostra que $P(\lambda)$ és decreixent -- per tot $\lambda \leq a$, i no negativa per $\lambda = a$. Per tant $P(\lambda)$ s'anularà només per valors $\lambda \geq a$.

Suposem ara que (7) és certa per $n-1$. Demostrem que llavors ho serà també per n . La derivada del polinomi característic és

$$P'(\lambda) = -P_1(\lambda) - \dots - P_{n-1}(\lambda)$$

on $P_j(\lambda)$ és el polinomi característic de la matriu que s'obté suprimint la fila j i la columna j de \sum . Per hipòtesi d'inducció, el menor valor propi d'aquesta matriu verifica $\lambda_1 \geq a$ i per tant

$$P_j(\lambda) \geq 0 \text{ si } \lambda \leq a \quad j=1, \dots, n-1 \quad (8)$$

Això és clar per $j > 1$. Per $j=1$, al suprimir la primera fila i columna de \sum , no obtenim una estructura similar a (6), però mitjançant un canvi de base apropiat, que deixarà invariant els valors propis, podem afirmar que $P_1(\lambda) \geq 0$ si $\lambda \leq u_{hk}^2/2$, essent $u_{hk} = \min\{u_{ij} \mid 2 \neq i \neq j \neq 2\} \geq a$. Així (8) és vàlid també per $j=1$.

Podem afirmar llavors que

$$P'(\lambda) \leq 0 \quad \text{si } \lambda \leq a \quad (9)$$

que vol dir que $P(\lambda)$ és decreixent per $\lambda \leq a$.

Passem a calcular $P(a)$. Restant a la diagonal de \sum el número a i tot seguit restant a cada fila la primera, ens queda un determinant que podem desenvolupar per la primera columna.

$$\Delta = \begin{vmatrix} a & a & a & a \\ 0 & (u_{13}^2 - u_{12}^2) & (u_{13}^2 + u_{14}^2 - u_{34}^2 - u_{12}^2)/2 & (u_{13}^2 + u_{15}^2 - u_{35}^2 - u_{12}^2)/2 \dots \\ 0 & (u_{14}^2 - u_{12}^2) & (u_{14}^2 + u_{15}^2 - u_{45}^2 - u_{12}^2)/2 \dots \\ \vdots & \dots & \dots & \dots \end{vmatrix}$$

$$\Delta = a \det(\sum)$$

Considerem ara la ultramètrica \bar{u}_{ij} tal que

$$\begin{aligned} \bar{u}_{ij}^2 &= u_{ij}^2 - u_{12}^2 & 2 \neq i \neq j \neq 2 \\ &= 0 & i=j \neq 2. \end{aligned}$$

Podem veure que \sum és la matriu de productes escalars de $n-2$ vectors associats a la ultramètrica \bar{u}_{ij} , i que té la mateixa estructura que \sum , però d'ordre $(n-2)$. En efecte, si suposem que

$$u_{13} = \min\{u_{ij} \mid 2 \neq i \neq j \neq 2\}$$

tindrem que

$$\sum = \begin{pmatrix} \bar{u}_{13}^2 & \bar{u}_{13/2}^2 & \bar{u}_{13/2}^2 & \dots \\ \bar{u}_{14}^2 & (\bar{u}_{14}^2 + \bar{u}_{15}^2 - \bar{u}_{45}^2)/2 & \dots & \dots \end{pmatrix}$$

En cas que aquest mínim fos u_{hk} ($h \neq 1$), efectuant un canvi de base apropiat, arribaríem a la mateixa conclusió. Si \bar{u}_{ij} és degenerada ($\bar{u}_{ij}=0$ per a algú $i \neq j$) es tindrà $\det(\sum) = 0$. En cas contrari $\det(\sum) > 0$. Tenim doncs

$$P(a) = a \det(\sum) \geq 0$$

Finalment, com que a més a més $P(\lambda)$ és decreixent per $\lambda \leq a$, tenim que $P(\lambda) \geq 0$ per a tot $\lambda \leq a$. Això demostra que $\lambda_1 \geq a$, \sum és definida positiva $\text{ran}(\sum) = n-1$. En conseqüència, la dimensió euclidiana de u_{ij} és $(n-1)$.

4. TOTA ULTRAMÈTRICA ÉS EUCLIDIANA.

La demostració que tota ultramètrica u_{ij} és euclidiana és una conseqüència del teorema 3.

TEOREMA 3: Sigui u_{ij} una distància ultramètrica. Tot representant de la classe $[u_{ij}]$ - distància euclidiana.

DEMOSTRACIÓ: Ho demostrarem per reducció a l'absurd. Suposem que u_{ij} no és euclidiana. Considerem el representant de $[u_{ij}]$

$$\begin{aligned} \bar{u}_{ij}^2 &= u_{ij}^2 - 2\alpha > 0 & \text{si } i \neq j, \\ &= 0 & \text{si } i=j. \end{aligned}$$

on α és una constant. Amb les notacions -- del teorema 1, siguin

$$A = (a_{ij}) \quad \bar{A} = (\bar{a}_{ij}) \quad a_{ij} = -\frac{1}{2} u_{ij}^2 \quad \bar{a}_{ij} = -\frac{1}{2} \bar{u}_{ij}^2$$

Aleshores

$$\bar{A} = A - \alpha(I - J)$$

i també és fàcil veure que

$$J = \frac{1}{n} J \cdot J \quad J \cdot H = 0 \quad H \cdot H = H$$

i per tant

$$\bar{B} = H \bar{A} H = (I - \frac{1}{n} J)(A - \alpha(I - J))(I - \frac{1}{n} J) = B - \alpha H$$

Com que hem suposat u_{ij} no euclidiana, els valors propis i vectors propis de $B = HAH$ serien

$$\lambda_1 \geq \dots \geq \lambda_r > 0 \geq \lambda'_1 \geq \dots \geq \lambda'_s$$

$$U_1, \dots, U_r, \underline{l}, V_1, \dots, V_s$$

\underline{l} és vector propi de valor propi 0, aleshores

$$\underline{l}' \cdot U_i = \underline{l}' \cdot V_i = 0$$

i per tant

$$\bar{B}U_i = BU_i - \alpha(I - \frac{1}{n}J)U_i = (\lambda_i - \alpha)U_i \quad i=1, \dots, r$$

$$\bar{B}V_j = (\lambda_j - \alpha)V_j \quad j=1, \dots, s$$

$$\bar{B}I = 0$$

Els valors i vectors propis de \bar{B} són

$$\lambda_1 - \alpha \geq \dots \geq \lambda_r - \alpha \geq \lambda'_1 - \alpha \geq \dots \geq \lambda'_s - \alpha, \quad 0$$

$$U_1, \dots, U_r; V_1, \dots, V_s; I$$

Prenem $\alpha = \lambda'_s$. Aleshores \bar{B} serà semidefinida positiva i tendrà com a mínim 2 valors propis nuls. La matriu \bar{B} està lligada a la distància ultramètrica no degenerada

$$\bar{u}_{ij}^2 = u_{ij}^2 + 2|\lambda'_s| > 0 \quad \text{si } i \neq j,$$

$$= 0 \quad \text{si } i = j,$$

que, d'acord amb el teorema 1, serà euclíadiana m -dimensional, on $m \leq n-2$. Però això ens contradiss el teorema 2. Hem d'admetre doncs que u_{ij} , i tot representant de $[u_{ij}]$, és distància euclidiana.

Finalment, podem obtenir un resultat relatiu al mínim valor propi no nul de la matriu de productes escalars B associada a una ultramètrica u_{ij} .

TEOREMA 4: Sigui u_{ij} una distància ultramètrica i sigui $B = HAH$ la matriu introduïda en el teorema 1. Es verifica:

- 1) B es semidefinida positiva,
- 2) $\text{ran}(B) = n-1$,
- 3) El menor valor propi no nul de B és

$$\lambda_{n-1} = \frac{\bar{u}^2}{2} \quad (10)$$

essent $\bar{u} = \min\{u_{ij} \mid i \neq j\}$.

DEMOSTRACIÓ: Els apartats 1) i 2) son conseqüència dels teoremes anteriors. Suposem que (10) no sigui certa. Donat $\epsilon > 0$, considerem la ultramètrica equivalent

$$\begin{aligned} \bar{u}_{ij}^2 &= u_{ij}^2 - \bar{u}^2 + \epsilon > 0 & i \neq j, \\ &= 0 & i = j. \end{aligned}$$

Seguint els mateixos passos del teorema anterior agafant

$$\alpha = \frac{\bar{u}^2}{2} - \frac{\epsilon}{2},$$

els valors propis no nuls de la matriu \bar{B} associada a \bar{u}_{ij} seran

$$\bar{\lambda}_1 = \lambda_1 - \frac{\bar{u}^2}{2} + \frac{\epsilon}{2} \geq \dots \geq \bar{\lambda}_{n-1} = \lambda_{n-1} - \frac{\bar{u}^2}{2} + \frac{\epsilon}{2}$$

Aleshores, si fos $\lambda_{n-1} < \bar{u}^2/2$, podem trobar un ϵ suficientment petit per a que sigui $\bar{\lambda}_{n-1} < 0$, i això entraria en contradicció amb el teorema 3. Observem també que per $\epsilon=0$ s'obté una ultramètrica \bar{u}_{ij} degenerada, i per tant $\bar{\lambda}_{n-1}=0$ que implica (10).

5. CONCLUSIONS.

Hom sap que una distància mètrica, es a dir, verificant la desigualtat triangular, no és necessàriament euclidiana. En aquest treball hem demostrat que si es verifica la propietat més restrictiva (1), anomenada desigualtat ultramètrica, aleshores la distància es sempre euclidiana. Això només es vèlid quan està definida sobre un conjunt finit. Aquesta propietat té conseqüències dins les tècniques de comparació de mètodes d'ordenació i classificació de dades.

Seguint un camí diferent, /2/ obté l'estructura dels valors i vectors propis de la matriu B de productes escalars associada a una ultramètrica U sobre un conjunt E . Troba també que les coordenades principals de U donen representacions espacials dels elements de E , que descriuen geomètricament l'estructura jerárquica sobre E definida per U .

6. BIBLIOGRAFIA.

/1/ CUADRAS, C.M., "Métodos de Análisis Multivariante", Eunibar, Barcelona, 642pp., -- (1981).

/2/ CUADRAS, C.M., "Análisis algebraico sobre distancias ultramétricas", Com. pres. sl 449 Per de Ses. del Inst. Intern. de Estadística, Madrid, (1983).

- /3/ CUADRAS, C.M., RUIZ-RIVAS, C. "Una contribución al análisis de proximidades" - P. Secc. Mat. U. Aut. Barcelona, 22, 103-106, (1980).
- /4/ GOWER, J.C. "Statistical methods of comparing different multivariate analysis - of the same data", A: Mathematics in the Archaeological and Historical Sciences, - (Hodson, F.R., Kendall, D.G. i Tautu, P., eds.), Edinburgh University Press, Edinburgh, pp. 138-149, (1971).
- /5/ LINGOES, J.C. "Some boundary conditions for a monotone analysis of symmetric matrices", Psychometrika, 36, 195-203, --- (1971).
- /6/ LINGOES, J.C., BORG, I. "A direct approach differences scaling using increasingly complex transformations" ---- Psychometrika, 43(4), 491-519, (1978).
- /7/ MARDIA, K.V., "Some properties of classical multidimensional scaling", Comm.Stat. A7(13), 1233-1241, (1978).
- /8/ ROHLF, F.J., "Methods of comparing classifications", Ann. Rev. Ecol. System., 5, 101-113, (1974).
- /9/ SCHONEMANN, P.H., CARROLL, R.M., "Fitting one matrix to another under choice of a central dilation and a rigid motion" ---- Psychometrika, 35, 245-255, (1970).