Pub. Mat. UAB N° 22 Nov. 1980 Actes VII JMHL

UNA CONTRIBUCION AL ANALISIS DE PROXIMIDADES

Carles M. Cuadras, Carmen Ruiz-Rivas

Dpto. de Bioestadística. Universidad de Barcelona Doto. de Estadística. Universidad Autónoma de Madrid

1. COORDENADAS PRINCIPALES

Sea $\Delta = (\delta_{i,j})$ una matriz de distancias no euclideas sobre un conjunto finito $\Omega = \{1, ..., 1, ..., n\}$. Se llama preordenación sobre Ω asociada a $\delta_{ extbf{ij}}$ a la relación binaria definida en $\Omega extbf{x}\Omega$:

(i,j)
$$\preccurlyeq$$
 (i',j') siysőlosi $\delta_{ij} \leqslant \delta_{i'j}$

 $(i,j) \ \leqslant \ (i',j') \quad \text{si y solo si} \quad \delta_{ij} \ \leqslant \delta_{i',j'}$ Sean $^p_1, \dots, ^p_n$ puntos del espacio euclídeo $\quad \text{R}^m \quad \text{de coordenadas eucl} \underline{\textbf{1}}$ deas $X = (x_{i,j})$ y distancia

$$d_{ij}^2 = d^2(P_i, P_j) = \sum_{h=1}^{m} (x_{ih} - x_{jh})^2$$
.

Se dice que la configuración X realiza la preordenación si se verifica $d_{ij} \leq d_{i'j'}$ si y sólo si $\delta_{ij} \leq \delta_{i'j'}$.

La obtención de una configuración que realice total o aproximadamente una preordenación es un problema clásico de Análisis de Proximidades. El aná lisis de coordenadas principales (Gower, 1966) puede sintetizarse en el sigui ente resultado:

Teorema 1: Sean I (matriz identidad), $E=(1,\ldots,1)$, $H=I_n-\frac{1}{n}E.E'$, $A=(a_i)$, con $a_{ij} = -\frac{3}{2} \delta_{ij}^2$, y B = HAH. Supongamos B semid. positiva de rango k ((n-1)), sean $\lambda_1, \ldots, \lambda_k$ los valores propios positivos y

$$x = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nk} \end{pmatrix} \qquad \lambda_{i} = \sum_{h=1}^{n} x_{hi}^{2}$$

la matriz de vectores propios(por columnas) >> normalizados. Entonces X es una configuración euclídea, con centroide en el origen, cuyas distancias euclideas reproducen exactamente $\delta_{i,j}$.

El anál. de coord. princ. (ACP) es el mejor método para reproducir, en dimensión reducida d, una distancia euclídea. El ACP toma las d primeras co-ordenadas X_d de X. Se verifica B=X'X, mientras que $B^*=X_d^*X_d$ representa una aproximación a B en el sentido de los mínimos cuadrados. Eckart y Young (1936) demuestran que este mínimo es k

D se toma como una medida de distorsión al representar en dimensión d .

2. SOLUCION DE LINGOES

Si δ_{ij} no es euclídea B tiene valores propios positivos v negativos y al menos uno nulo. Sean estos

$$\lambda_1 \geqslant \dots \geqslant \lambda_r \geqslant 0 \geqslant \lambda_1' \geqslant \dots \geqslant \lambda_s'$$
 (1)

Tomando d coord. princ. (d < r), la distorsión es

$$D = \sum_{i=d+1}^{r} \lambda_{i}^{2} + \sum_{j=1}^{s} \lambda_{j}^{2}$$
 (2)

Por transformación monótona de $\int_{i,j}$ es posible obtener una distancia euclídea que realice la preordenación. Una solución de este tipo se debe a Lingoes (1971), que puede enunciarse en la forma siguiente:

Teorema 2: Con las mismas notaciones del teorema 1, sean (1) los valores propios de By seala matriz $A^* = A - \lambda_s^i (I_p - \frac{1}{p} E.E^i)$. Se verifica:

- 1) La matriz B* = HA*H es semidef. posit. de rango n-2.
- 2) Diagonalizando B*, en la forma B*= X'.X, se obtiene una configuración euclídea X que realiza la preordenación.
- 3) La distancia euclídea es

$$d_{ij}^{*2} = \delta_{ij}^{2} - 2\lambda_{s}^{*} \quad \text{si } i \neq j ,$$

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

La solución de Lingoes tiene una distorsión $D=(n-1)\lambda_S^{*\,2}$, que en general será notablemente superior a (2). Es una solución que realiza exactamente la preordenación, pero a costa de incrementar la dimensión.

3. SOLUCION DE MARDIA

Si se considera la distorsión, no respecto a la distancia original, si no respecto a la distancia transformada

$$d_{ij}^{*2} = \delta_{ij}^{2} - 2a \qquad \text{si } i \neq j ,$$

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

la distorsión es entonces (indicando por $\lambda_1,\ldots,\lambda_{n-1}$ los val. prop. de B)

$$D(a) = \sum_{i=d+1}^{n-1} (\lambda_{i-d})^{2}$$

Mardia(1978) propone tomar como valor de a el que hace mínimo D(a), es decir,

$$a_d = (\sum_{i=d+1}^{n-1} \lambda_i) / (n-d+1)$$

Esta solución proporciona menos distorsión que la de Lingoes, la cual toma a = λ_c^* . Sin embargo, para d igual a 2 , 3 u otros valores pequeños. la solución a veces no existe (d_{ij}^* resulta negativa).

4. SOLUCION LINEAL

En el presente trabajo se propone la transformación lineal

$$\hat{\mathbf{a}}_{ij} = \mathbf{a} \int_{ij} + \mathbf{b} \qquad \text{si } i \neq j,$$

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

a fin de obtener una realización euclídea de la preordenación. Sin embargo, la diagonalización de B(a,b) relativa a d_{ij} es mucha más compleja que la diagonalización de B(a) relativa a d*.. Como alternativa para resolver este problema, se propone el siguiente algoritmo iterativo:

Paso 1: Se ajusta δ_{ij} a una distancia euclidea $d_{ij}^{(0)}$ por ACP y se obtiene $\hat{d}_{ij}^{(1)}$ por transformación monótona lineal de δ_{ij} $\hat{d}_{ij}^{(1)} = a_1 \delta_{ij} + b_1$

 $G_1 = \sum_{i < j} (\hat{d}_{ij}^{(1)} - d_{ij}^{(0)})^2$ sea mínimo. con la condición de que

 $\frac{\text{Paso N:}}{\text{dij}} \text{ Se ajusta } \hat{d}_{ij}^{(N)} \text{ a una distancia euclidea } d_{ij}^{(N)} \text{ por ACP y se obstiene}$ tiene $\frac{\hat{d}_{ij}^{(N+1)}}{\hat{d}_{ij}^{(N+1)}} = a_N \hat{d}_{ij}^{(N)} + b_N$

$$\hat{\mathbf{d}}_{\mathbf{ij}}^{(N+1)} = \mathbf{a}_{\mathbf{N}} \hat{\mathbf{d}}_{\mathbf{ij}}^{(N)} + \mathbf{b}_{\mathbf{N}}$$

con la condición de que $G_N = \sum_{i \neq j} (\hat{a}_{ij}^{(N+1)} - a_{ij}^{(N)})^2$ sea mínimo.

Se verifica

$$G_1 \gtrsim G_2 \geqslant \dots \geqslant G_N \geqslant \dots$$

tomándose como solución aquella configuración euclídea $\mathbf{x}^{(N)}$, con distancias $\mathbf{d_{ij}^{(N)}}$ para la que G se estabiliza. Los coeficientes $\mathbf{a_{ij}}$ y $\mathbf{b_{ij}}$ que minimi-

$$\hat{a}_{N} = \frac{\sum_{i < j} \hat{d}_{ij}^{(N)} \cdot d_{ij}^{(N)} - p\bar{\xi} \cdot \bar{d}}{\sum_{i < j} (d_{ij}^{(N)})^{2} - p\bar{\xi}^{2}}, \quad \hat{b}_{N} = \bar{d} - a_{N}\bar{\delta},$$

siendo
$$p = n(n-1)/2$$
, $\bar{d} = \frac{1}{p} \frac{1}{i \cdot j} d_{ij}^{(N)}$, $\bar{d} = \frac{1}{p} \sum_{i \cdot j} d_{ij}^{(N)}$.

Si los coeficientes hallados verifican

$$\hat{\mathbf{a}}_{ij}^{(N+1)} = \hat{\mathbf{a}}_{N} \hat{\mathbf{a}}_{ij}^{(N)} + \hat{\mathbf{b}}_{N} < 0$$

para algún $\hat{d}_{ij}^{(N)}$, la solución no es válida. Si \hat{d}_{min} es el menor de los $\hat{d}_{ij}^{(N)}$, bastará minimizar G_N sujeto a la condición

$$a_N \hat{d}_{min} + b_N = 0$$
.

La solución es entonces

$$\hat{a}_{N}^{'} = \frac{\sum_{i < j} d_{ij}^{(N)} (\hat{d}_{ij}^{(N)} - \hat{d}_{min})}{\sum_{i < j} (\hat{d}_{ij}^{(N)} - \hat{d}_{min})^{2}} , \quad \hat{b}_{N}^{'} = -\hat{a}_{N}^{'} \cdot \hat{d}_{min}^{'}.$$

CONCLUSIONES

Esta solución lineal ha sido ensavada con ejemplos numéricos v aplicaciones prácticas(distancias genéticas no euclídeas), con referencia a cuatro medidas diferentes de distorsión, llegándose a las siguientes conclusiones:

- 1) En general son necesarias pocas iteraciones para que ${\bf G}_{\hat{\bf N}}$ se estabilice.
- 2) La distorsión obtenida en dimensión reducida resulta sensiblemen te inferior a las soluciones de Lingoes. Mardia y por coordenadas principales.
- 3) En dimensión n-2 se obtiene una realización euclidea de la preordenación asociada a δ_{ij} .

6. BIBLIOGRAFIA

- Eckart, C., Young, G. (1936) The aproximation of one matrix by another of lower rank. Psychometrika,1,211-218.
- Gower, J.C. (1966) Some distance properties of latent root and vector methods used in multivariate analysis. Biometrika, 53,325-338.
- Lingoes, J.C. (1971) Some boundary conditions for a monotone analysis of symmetric matrices. Psychometrika, 36, 195-203.
- Mardia, K.V. (1978) Some properties of classical multi-dimensional scaling. Commun.Statist.-Theor.Meth.,A7(13), 1233-1241.