

POSITIONNEMENT MULTIDIMENSIONNEL

(MDS)

On considère n individus.

Les données sont le $\frac{n(n-1)}{2}$ valeurs d'un indice (distance, similitude ou dissimilarité)

observés ou construits par chaque couple d'individus. L'objectif est de construire, à partir de cette matrice d'indices une représentation (euclidienne) des individus dans un espace de dimension réduite qui approche "au mieux" les indices observés.

Distances entre variables

Pourquoi, le MDS peut servir à comprendre la structure de liaison d'un grand ensemble de variables.

2 variables qualitatives : $d^2(X, Y) = 1 - \cos(X, Y)$

(supposés centrés sur leur moyenne)

pour : la distance associée à un cosinus

2 variables quantitatives : $d^2(P, Q) = 1 - T^2(X, Y)_{\substack{\text{à} \\ \text{la p. } i}}$

$$T = \sqrt{\frac{\chi^2_{\text{obs}}}{n \nu}} \quad , \quad \nu = (r-1)(s-1)$$

$$\text{et } \chi^2_{\text{obs}} = \sum_{l=1}^r \sum_{h=1}^s \left[\frac{n_{lh}^2}{n_l \cdot n_h} - 1 \right]$$

(n_{lh} := nb d'individus v.g.

$P=l$ et $Q=h$; n_l et n_h : compte marginaux)

→ donne une approximation

empirique de $\frac{P(P=l, Q=h)}{P(P=l) \cdot P(Q=h)}$, rapport

égal à 1 ssi P et Q sont indépendants

1 variable qualitative / 1 variable quantitative : $d^2(X, C) = 1 - R_v^2(X, C)$

ou $R_v^2(X, C)$ est le rapport de variances expliquées sur

totale : $R_v^2(X, C) = \frac{\text{Var expliquée (par les effets de la variable qualitative } C)}{\text{Var totale}}$

$$= \frac{\sum_{i=1}^n (x_i - \mu)^2}{\sum_{k=1}^K (\mu_k - \mu)^2}$$

Maintenant, à partir d'une matrice Δ

de distances Δ_{ij} , $i=1, \dots, n$, $j=1, \dots, n$ entre points

de \mathbb{R}^n , on cherche une configuration de ces

points dans un espace de dimension q ($q=2$ le + souvent)

qui minimise de façon rigoureuse et au mieux
les Δ_{ij} .

Mis sous forme d'un problème d'optimisation,

on cherche argmin $\|X X^T - \tilde{\Delta}\|_F$

$X \in \mathbb{R}^{n \times q}$

pour norme de Frobenius = racine carrée de la somme des carrés des éléments

n points dans un espace de dimension q
 $\tilde{\Delta} = \frac{1}{n} \mathbb{1} \mathbb{1}^T$ "matrice de tous les uns"

où $\tilde{\Delta} := -\frac{1}{2} J \cdot \Delta_2 \cdot J$ et $(\Delta_2)_{ij} = \Delta_{ij}^2, \forall i, j$

- remarques :
- si Δ est euclidienne, on trouve que le minimum ci-dessus vaut 0. Δ euclidienne $\Leftrightarrow \tilde{\Delta}$ a toutes ses valeurs propres ≥ 0
 - J est la matrice de projection sur le sous-espace orthogonal à $\begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix} = \mathbb{1}$

Si on diagonalise $\tilde{\Delta} = U \cdot \Lambda \cdot U^T$, la solution du problème est donnée par $X = U \Lambda^{1/2}$; on a les coordonnées des vecteurs de la première dimension euclidienne. Si on ne garde que les 2 premières valeurs propres, X a n lignes et 2 colonnes.

ex : (\mathbb{R}) libray (PASS); loc \leftarrow cm d'scale (eurochiv);
 $x \leftarrow$ loc [1, 2]; $y \leftarrow$ loc [1, 2]; plot(x, y, 'type="b"');
 text(x, y, "nom du loc", "eurochiv")