



Université de Poitiers Département de Mathématiques

Statistique descriptive, 1er semestre, année univ. 2009-2010

Fiche 9

Analyse factorielle des correspondances

Exercice 1

Table de contingence, lois marginales, lois conditionnelles

Soit $N = (n_{ij})_{i \in I, j \in J}$ une table de contingence $p \times q$ croisant deux variables qualitatives X et Y respectivement à p et q modalités. Le terme n_{ij} désigne le nombre d'individus ayant les modalités $X = i$ et $Y = j$. On note $n = \sum_{i,j} n_{ij}$ le nombre total d'individus, ainsi que $n_{i.} := \sum_{j \in J} n_{ij}$ le nombre d'individu ayant la modalité $X = i$ et $n_{.j} = \sum_{i \in I} n_{ij}$ le nombre d'individu ayant la modalité $Y = j$. On note enfin $F := (f_{ij})_{i \in I, j \in J}$ le tableau des fréquences donné par $F = \frac{1}{n}N$, $f_{i.} := \frac{1}{n}n_{i.}$ et $f_{.j} := \frac{1}{n}n_{.j}$. On note $D_I := \text{diag}(f_{i.})$ et $D_J := \text{diag}(f_{.j})$ les matrices diagonales $p \times p$ et $q \times q$ respectivement.

- 1) Montrer que F définit une loi de probabilité sur $I \times J$ dont les marginales sur I et J sont données respectivement par $(f_{i.})_{i \in I}$ et $(f_{.j})_{j \in J}$.
- 2) Montrer que le i -ème profil-ligne $\text{PrL}(i) \in \mathbb{R}^q$ donné comme la i -ème ligne de la matrice $Z_I = D_I^{-1}F$ s'interprète comme la loi conditionnelle de Y sachant $X = i$.
- 3) De même, montrer que le j -ème profil-colonne $\text{PrC}(j) \in \mathbb{R}^p$ donné comme la j -ème colonne de la matrice $Z_J = FD_J^{-1}$ s'interprète comme la loi conditionnelle de X sachant $Y = j$.
- 4) Que deviennent ces quantités si la loi de probabilité F sur $I \times J$ est une loi produit *i.e.* lorsque les échantillons X et Y sont indépendants ?

Exercice 2

Espaces, poids, métriques et inertie en AFC

À la matrice des fréquences F on associe le nuage des p profils-lignes dans \mathbb{R}^q donné comme les lignes de la matrice $Z_I = D_I^{-1}F$. La i -ème ligne est affectée du poids $f_{i.}$ et D_I est la matrice des poids. On utilise le produit scalaire sur \mathbb{R}^q associé à la matrice D_J^{-1} et la distance d_{χ^2} associée *i.e.*

$$\langle u; v \rangle_{\chi^2} = u' D_J^{-1} v. \quad (1)$$

- 1) Quel est le centre de gravité G_I du nuage des profils-lignes ?
- 2) Que vaut l'inertie totale du nuage des profils-lignes calculée par rapport à G_I ?
- 3) Montrer que OG_I est orthogonal à l'hyperplan $\sum_j u_j = 1$ contenant \mathcal{N}_I .
- 4) Soit u un vecteur de \mathbb{R}^q normé. Montrer que le vecteur ϕ_u des projections orthogonales des points de \mathcal{N}_I sur la droite passant par O et dirigée par u est donné par $\phi_u = Z_I D_J^{-1} u \in \mathbb{R}^p$.
- 5) Montrer que l'inertie du nuage projeté sur u calculé en O est donnée par

$$I^{\text{vect}(u)}(\mathcal{N}) = u' D_J^{-1} Z_I' D_I Z_I D_J^{-1} u.$$

- 6) Soit M_I la matrice définie par $M_I := Z_I' D_I Z_I D_J^{-1}$. Montrer que M_I s'écrit également

$$M_I = F' D_I^{-1} F D_J^{-1} = Z_I' Z_I$$

puis que M_I est symétrique et positive pour le produit scalaire donné par (1). Ainsi M_I se diagonalise en base orthonormée (pour le produit scalaire défini en (1)) et a des valeurs propres réelles positives.

- 7) Montrer que la droite d'inertie maximale est dirigée par un vecteur propre de M_I associée à la plus grande valeur propre.
- 8) Montrer que 1 est la plus grande valeur propre, associée au vecteur propre $\mathbf{1}_J$ (cela ne dépend pas du tableau de données et donc n'importe pas dans l'AFC).

Exercice 3

Propriété d'équivalence distributionnelle pour la distance du χ^2

- 1) Vérifier que si deux profils-lignes $\text{PrL}(i_1) = (\frac{f_{i_1j}}{f_{i_1.}})_{j \in J}$ et $\text{PrL}(i_2) = (\frac{f_{i_2j}}{f_{i_2.}})_{j \in J}$ de poids respectifs $f_{i_1.}$ et $f_{i_2.}$ sont égaux *i.e.*

$$\text{PrL}(i_1) = \text{PrL}(i_2)$$

dans une analyse de type AFC, ils peuvent être remplacés par une nouvelle modalité $\blacksquare i_1 + i_2 \blacksquare$ et un unique profil-ligne

$$\text{PrL}(i_1 + i_2) = \text{PrL}(i_1) = \text{PrL}(i_2).$$

de poids $f_{i_1.} + f_{i_2.}$

- 2) Vérifier que les distances entre profils-colonnes $d_{\chi^2}(\text{PrC}(j_1), \text{PrC}(j_2))$ ne sont pas modifiées.

Exercice 4

Dualité en AFC

On considère le nuage des q profils-colonnes dans \mathbb{R}^p donné par les colonnes de la matrice $Z_J = FD_J^{-1}$. La j -ème colonne est affectée du poids $f_{.j}$ et D_J est la matrice des poids. On utilise le produit scalaire sur \mathbb{R}^p associé à la matrice D_J^{-1} et la distance d_{χ^2} associée.

- 1) Comment s'adaptent les résultats obtenus sur les profils-lignes pour les profils-colonnes ?
- 2) Soit M_J la matrice définie par $M_J = Z_J Z_J'$: montrer que M_I et M_J ont les mêmes valeurs propres non nulles, avec même multiplicité. Quelles relations existent entre les vecteurs propres ?
- 3) En déduire les relations quasi-barycentriques.