

Analyse Factorielle des correspondances A. F. C.

I/ Introduction

Soient X et Y deux variables observées sur une population I de taille n . On suppose que X et Y ont respectivement p et q modalités (p et q classes dans le cas de variables quantitatives)

On note par M_1, \dots, M_p les modalités de X et par N_1, \dots, N_q celles de Y .

Soit X le tableau de contingence associé.

$$\begin{array}{c}
 X \\
 (p, q)
 \end{array}
 =
 \begin{array}{c}
 M_1 \\
 M_2 \\
 \vdots \\
 M_p
 \end{array}
 \begin{pmatrix}
 N_1 & N_2 & \dots & N_q \\
 n_{11} & & & \\
 & & & n_{ij} \\
 & & &
 \end{pmatrix}$$

n_{ij} est le nombre d'individus ayant la modalité M_i pour X et N_j pour Y .

$$\sum_{i=1}^p \sum_{j=1}^q n_{ij} = n.$$

Rp: Dans le cas où X et Y ne sont indépendantes, on désire remonter les liens pouvant exister entre les modalités de X et de Y .

II/ Problème posé

Rechercher la meilleure représentation entre les modalités de X et celles de Y . En d'autres termes, on désire représenter sur un même axe les points communs M_i et N_j $i=1, \dots, p$ et $j=1, \dots, q$.

L'A.F.C répond à ce type de problème. Ce qui revient à effectuer deux A.F.G, une sur le tableau profils lignes et l'autre sur le tableau profils colonnes. où \mathbb{R}^p et \mathbb{R}^q sont munies resp de métrique Q et S . qui on définira

Notation

$$n_{i\cdot} = \sum_{j=1}^q n_{ij} \text{ effectif de la modalité } M_i \quad i=1, \dots, p$$

$$f_{i\cdot} = \frac{n_{i\cdot}}{n} \text{ fréquence de } M_i$$

$$n_{\cdot j} = \sum_{i=1}^p n_{ij} \text{ effectif de la modalité } N_j \quad j=1, \dots, q$$

$$f_{\cdot j} = \frac{n_{\cdot j}}{n} \text{ fréquence de } N_j$$

On a $\sum_{i=1}^p n_{i0} = \sum_{j=1}^q n_{0j} = n$ taille de la population

$$f_{ij} = \frac{n_{ij}}{n}$$

$$\sum_{i=1}^p \sum_{j=1}^q f_{ij} = \sum_{i=1}^p f_{i0} = \sum_{j=1}^q f_{0j} = 1$$

III / Tableaux profils lignes et profils colonnes.

III.1 / Tableau profils lignes.

$$X_I = \begin{pmatrix} \frac{n_{11}}{n_{10}} & \frac{n_{12}}{n_{10}} & \dots & \frac{n_{1q}}{n_{10}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{n_{p1}}{n_{p0}} & \dots & \dots & \frac{n_{pq}}{n_{p0}} \end{pmatrix}$$

$\underline{x}_i = \left(\frac{n_{i1}}{n_{i0}}, \dots, \frac{n_{iq}}{n_{i0}} \right)$ et le i^{eme} profil ligne, $\underline{x}_i \in \mathbb{R}^q$
 $i=1, \dots, p$

III.2 / Tableau profils colonnes

$$X_J = \begin{pmatrix} \frac{n_{11}}{n_{01}} & \dots & \frac{n_{p1}}{n_{01}} \\ \frac{n_{12}}{n_{02}} & \dots & \frac{n_{p2}}{n_{02}} \\ \vdots & \ddots & \vdots \\ \frac{n_{1q}}{n_{0q}} & \dots & \frac{n_{pq}}{n_{0q}} \end{pmatrix}$$

$\underline{y}_j = \left(\frac{n_{1j}}{n_{0j}}, \dots, \frac{n_{pj}}{n_{0j}} \right)$ le j^{eme} profil colonne
 $j=1, \dots, q$

Effectuer l'AFG du tableau X revient à faire une

a. AFG du tableau X_I

b. AFG " " " X_J

Dans le cas des métriques suivantes.

III.3 / Choix de métriques.

Pour l'analyse de X_I , on se place sur \mathbb{R}^q , et on muni \mathbb{R}^q de la métrique \mathcal{Q}_q et \mathbb{R}^p de la métrique \mathcal{D}_p

$$Q_q = \begin{pmatrix} \frac{1}{f_{\cdot 1}} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{f_{\cdot q}} \end{pmatrix}$$

$$D_p = \begin{pmatrix} f_{1\cdot} & & 0 \\ & \ddots & \\ 0 & & f_{p\cdot} \end{pmatrix}$$

Proposition

On a $X_I = D_p^{-1} F$ F tableau des fréquences $F = \left(\frac{n_{ij}}{n} \right)_{\substack{1 \leq i \leq p \\ 1 \leq j \leq q}}$

Pour l'analyse du tableau X_I , on muni \mathbb{R}^p de la métrique Φ'_p et \mathbb{R}^q de la métrique Δ'_q et on se place sur \mathbb{R}^p

$$\Phi'_p = D_p^{-1} = \begin{pmatrix} \frac{1}{f_{1\cdot}} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{f_{p\cdot}} \end{pmatrix} \quad \Delta'_q = Q_q^{-1} = \begin{pmatrix} f_{\cdot 1} & & 0 \\ & \ddots & \\ 0 & & f_{\cdot q} \end{pmatrix}$$

IV / Analyse factorielle

IV.1 / Analyse factorielle du tableau profils lignes

Soit X_I le tableau de profils lignes de dim (p, q) , on se place sur (\mathbb{R}^q, Φ_q) , et on muni (\mathbb{R}^p, Δ_p)

On suit les mêmes étapes de l'A.F.G., on se ramène à la diagonalisation de la matrice ${}^t X_I \Delta_p X_I \Phi_q$
 $(q, p) \quad (p, p) \quad (p, q) \quad (q, q)$

Rq: Le tableau X_I n'est pas centré.

Déf: La matrice ${}^t X_I \Delta_p X_I \Phi_q$ est dite matrice d'inertie

Les axes factoriels sont les droites passant par l'origine de \mathbb{R}^p et engendrés par les vecteurs propres normés de ${}^t X_I \Delta_p X_I \Phi_q$ associés aux plus grandes valeurs propres.

Soit w_i la projection Φ_q -orthogonale du $i^{\text{ème}}$ profil ligne sur Δ_p

$$w_i = \left\langle \frac{{}^t x_i}{\|x_i\|}, u \right\rangle_{\Phi_q} = \frac{{}^t x_i}{\|x_i\|} \Phi_q u$$

$w = \begin{pmatrix} w_1 \\ \vdots \\ w_p \end{pmatrix} = X_I \Phi_q u$ le vecteur des projections de p profils lignes

Centre de gravité du nuage profils lignes.

$$N(I) = \left\{ \begin{matrix} \underline{x}_i, i=1, \dots, p \\ \text{et } \underline{x}_i \in \mathbb{R}^{q \times 1} \end{matrix} \right.$$

$$\underline{g}_I = \sum_{i=1}^p \frac{1}{f_{i \cdot}} \underline{x}_i = \sum_{i=1}^p \frac{1}{f_{i \cdot}} \begin{pmatrix} \frac{n_{i1}}{n_{i \cdot}} \\ \vdots \\ \frac{n_{iq}}{n_{i \cdot}} \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^p \frac{n_{i1}}{n} \times \frac{n_{i1}}{n_{i \cdot}} \\ \vdots \\ \sum_{i=1}^p \frac{n_{iq}}{n} \times \frac{n_{iq}}{n_{i \cdot}} \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^p \frac{n_{i1}}{n} \\ \vdots \\ \sum_{i=1}^p \frac{n_{iq}}{n} \end{pmatrix} = \begin{pmatrix} f_{1 \cdot} \\ \vdots \\ f_{q \cdot} \end{pmatrix}$$

Proposition

On pose $F = (f_{ij})_{\substack{1 \leq i \leq p \\ 1 \leq j \leq q}}$ tableau de fréquence.

On a $X_I = D_p^{-1} F$

Preuve

$$D_p^{-1} F = \begin{pmatrix} \frac{1}{f_{1 \cdot}} & & & \\ & \ddots & & \\ & & \ddots & \\ 0 & & & \frac{1}{f_{p \cdot}} \end{pmatrix} \begin{pmatrix} f_{11} & \dots & f_{1q} \\ \vdots & & \vdots \\ f_{p1} & \dots & f_{pq} \end{pmatrix} = \begin{pmatrix} \frac{f_{11}}{f_{1 \cdot}} & \dots & \frac{f_{1q}}{f_{1 \cdot}} \\ \vdots & & \vdots \\ \frac{f_{p1}}{f_{p \cdot}} & \dots & \frac{f_{pq}}{f_{p \cdot}} \end{pmatrix} = X_I$$

on a $\frac{f_{ij}}{f_{i \cdot}} = \frac{\frac{n_{ij}}{n}}{\frac{n_{i \cdot}}{n}} = \frac{n_{ij}}{n_{i \cdot}} =$ ~~$\frac{1}{f_{i \cdot}}$~~ composante de \underline{x}_i

Rq: la matrice à diagonaliser devient:

$${}^t(D_p^{-1} F) D_p (D_p^{-1} F) Q_p = {}^t F D_p^{-1} F Q_p$$

II.2) Analyse factorielle du tableau profils colonnes.

Soit X_J le tableau profil colonne de dimension (q, p) , on se place sur $(\mathbb{R}^p, \Phi_p) = (\mathbb{R}^p, \Delta_p)$ et on munit $(\mathbb{R}^q, \Delta_q) = (\mathbb{R}^q, \Phi_q)$

On effectue l'A.F.G du tableau X_J , on se ramène à la diagonalisation de la matrice ${}^t X_J \Delta_q X_J \Phi_p$ ~~${}^t X_J \Delta_p X_J \Phi_p$~~

De même X_J n'est pas forcément centré

et ${}^t X_J \Delta_q X_J$ ~~Φ_p~~ est dite matrice d'inertie.

Les axes factoriels sont les droites engendrées par les vecteurs propres normés de ${}^t X_J \Delta_q X_J \Phi_p$ associés aux plus grandes valeurs propres.

On note par \mathcal{J}^s la projection du j-ème profil colonne sur Δ^s .

$$\mathcal{J}^s = \langle \mathcal{Y}_j^s, \mathcal{Y}_j^s \rangle_{\mathcal{Q}_p} = \mathcal{Y}_j^s \mathcal{Q}_p' s$$

$\mathcal{J} = \begin{pmatrix} \mathcal{J}^1 \\ \vdots \\ \mathcal{J}^q \end{pmatrix}$ le vecteur de projections des q profils colonnes.

$$\boxed{\mathcal{J} = X_J \mathcal{Q}_p' s}$$

Centre de gravité du nuage profils colonnes

$$N(J) = \left\{ \frac{\mathcal{Y}_j^s}{f_{0j}}, j=1, \dots, q \text{ et } \mathcal{Y}_j^s \in \mathbb{R}^p \right\}$$

$$\mathcal{G}_J = \sum_{j=1}^q f_{0j} \frac{\mathcal{Y}_j^s}{f_{0j}} = \sum_{j=1}^q f_{0j} \begin{pmatrix} \frac{n_{1j}}{n_{0j}} \\ \vdots \\ \frac{n_{pj}}{n_{0j}} \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^q f_{0j} \frac{n_{1j}}{n_{0j}} \\ \vdots \\ \sum_{j=1}^q f_{0j} \frac{n_{pj}}{n_{0j}} \end{pmatrix} = \begin{pmatrix} \sum_{j=1}^q \frac{n_{0j}}{n} \frac{n_{1j}}{n_{0j}} \\ \vdots \\ \sum_{j=1}^q \frac{n_{0j}}{n} \frac{n_{pj}}{n_{0j}} \end{pmatrix} = \begin{pmatrix} \frac{f_{11}}{f_{01}} \\ \vdots \\ \frac{f_{p1}}{f_{01}} \\ \vdots \\ \frac{f_{1q}}{f_{0q}} \\ \vdots \\ \frac{f_{pq}}{f_{0q}} \end{pmatrix} = \begin{pmatrix} \frac{n_{11}}{n_{01}} \\ \vdots \\ \frac{n_{p1}}{n_{01}} \\ \vdots \\ \frac{n_{1q}}{n_{0q}} \\ \vdots \\ \frac{n_{pq}}{n_{0q}} \end{pmatrix} = X_J$$

Proposition

$$\text{On a } X_J = \mathcal{D}_q^{-1} F = \mathcal{Q}_p' F$$

Preuve (9.19)

$$\mathcal{Q}_p' F = \begin{pmatrix} 1/f_{01} & & & \\ & \ddots & & \\ & & 1/f_{0q} & \\ & & & \ddots \end{pmatrix} \begin{pmatrix} f_{11} & \dots & f_{p1} \\ \vdots & & \vdots \\ f_{1q} & \dots & f_{pq} \\ \vdots & & \vdots \end{pmatrix} = \begin{pmatrix} \frac{f_{11}}{f_{01}} & \dots & \frac{f_{p1}}{f_{01}} \\ \vdots & & \vdots \\ \frac{f_{1q}}{f_{0q}} & \dots & \frac{f_{pq}}{f_{0q}} \\ \vdots & & \vdots \end{pmatrix}$$

et $\frac{f_{ij}}{f_{0j}} = \frac{n_{ij}}{n_{0j}} = \frac{n_{ij}}{n}$

$$= \begin{pmatrix} \frac{n_{11}}{n_{01}} & \dots & \frac{n_{p1}}{n_{01}} \\ \vdots & & \vdots \\ \frac{n_{1q}}{n_{0q}} & \dots & \frac{n_{pq}}{n_{0q}} \end{pmatrix} = X_J$$

La matrice à diagonaliser devient

$$\mathcal{Q}_p' (Q_q' F) \mathcal{D}_q^{-1} (Q_q' F) \mathcal{Q}_p = F \mathcal{D}_q^{-1} F \mathcal{Q}_p'$$

Prop: $\|g_{\mathbb{I}}\|_{\mathcal{Q}_p} = \|g_{\mathbb{J}}\|_{\mathcal{Q}_p'} = 1$. En effet

$$\|g_{\mathbb{I}}\|_{\mathcal{Q}_p}^2 = \mathcal{Q}_p' g_{\mathbb{I}} g_{\mathbb{I}} = \begin{pmatrix} f_{01} & \dots & f_{0q} \end{pmatrix} \begin{pmatrix} 1/f_{01} & & 0 \\ & \ddots & \\ 0 & & 1/f_{0q} \end{pmatrix} \begin{pmatrix} f_{01} \\ \vdots \\ f_{0q} \end{pmatrix}$$

$$= (1, \dots, 1) \begin{pmatrix} f_{01} \\ \vdots \\ f_{0q} \end{pmatrix} = \sum_{j=1}^q f_{0j} = 1$$

$$\begin{aligned} \|\mathbf{g}_j\|_{\mathcal{Q}_p}^2 &= {}^t \mathbf{g}_j \mathcal{Q}_p' \mathbf{g}_j = \begin{pmatrix} f_{10} & \dots & f_{p0} \end{pmatrix} \begin{pmatrix} 1/f_{10} & & 0 \\ & \ddots & \\ 0 & & 1/f_{p0} \end{pmatrix} \begin{pmatrix} f_{10} \\ \vdots \\ f_{p0} \end{pmatrix} \\ &= (1, \dots, 1) \begin{pmatrix} f_{10} \\ \vdots \\ f_{p0} \end{pmatrix} = \sum_{i=1}^p \frac{f_{i0}}{f_{i0}} = 1 \end{aligned}$$

V/ Relation entre les espaces propres.

Proposition

Les matrices ${}^t F \Delta_p^{-1} F \mathcal{Q}_q$ et $F (\Delta_q)^{-1} {}^t F \mathcal{Q}_p'$ ont les mêmes valeurs propres. (q, q) (p, p)

Preuve : voir l'A.F.G.

On note par u un \vec{v}^1 de ${}^t F \Delta_q^{-1} F \mathcal{Q}_q$ et par s un \vec{v}^p norme de $F (\Delta_q)^{-1} {}^t F \mathcal{Q}_p'$ associés à la même λ

Les vecteurs $\alpha = \mathcal{Q}_q u$ et $\beta = \mathcal{Q}_p' s$ sont dits facteurs $(q, 1)$ $(p, 1)$

Proposition

on a

$$\beta = \frac{1}{\sqrt{\lambda}} X_I \alpha$$

et
$$\alpha = \frac{1}{\sqrt{\lambda}} X_J \beta$$

ce qui donne les formules de transition suivantes

$$\begin{cases} \beta_{(p,1)} = \frac{1}{\sqrt{\lambda}} F \mathcal{Q}_q u \\ \alpha_{(q,1)} = \frac{1}{\sqrt{\lambda}} {}^t F \mathcal{Q}_p' s \end{cases}$$

Preuve : voir A.F.G.

VI/ Projection simultanée.

On se place sur $(\mathbb{R}^q, \mathcal{Q}_q)$, la matrice à diagonaliser ${}^t F \Delta_p^{-1} F \mathcal{Q}_q$, on note par u ses \vec{v}^p et λ λ λ

! Projection des profils colonnes.

$$w_i = x_i Q_p u \quad \text{et} \quad \boxed{w = X_I Q_p u}$$

Projection des profils colonnes.

$$y_j' = y_j Q_p' s = y_j Q_p' \left(\frac{1}{\sqrt{\lambda}} F Q_p u \right) \left(\Delta_p^{-1} F \right)$$

$$y = \begin{pmatrix} y_1 \\ \vdots \\ y_p \end{pmatrix} = X_J Q_p' \left(\frac{1}{\sqrt{\lambda}} F Q_p u \right) = \left(\frac{1}{\sqrt{\lambda}} F Q_p' \right) \Delta_p^{-1} \left(\frac{1}{\sqrt{\lambda}} F Q_p u \right) = \frac{1}{\sqrt{\lambda}} F Q_p' F Q_p u$$

$$\boxed{y = \frac{1}{\sqrt{\lambda}} F Q_p' F Q_p u} \quad Q_p = \left(\Delta_p^{-1} \right)$$

On se place sur (\mathbb{R}^p, Q_p') ou $(\mathbb{R}^p, \Delta_p^{-1})$

Projection des profils lignes.

$$w_i = x_i Q_p u = x_i Q_p \left(\frac{1}{\sqrt{\lambda}} F Q_p' s \right)$$

$$w = \begin{pmatrix} w_1 \\ \vdots \\ w_n \end{pmatrix} = X_I Q_p \left(\frac{1}{\sqrt{\lambda}} F Q_p' s \right) = \left(\Delta_p^{-1} F \right) Q_p \left(\frac{1}{\sqrt{\lambda}} F Q_p' s \right)$$

$$= \frac{1}{\sqrt{\lambda}} \Delta_p^{-1} \left(F Q_p F Q_p' s \right) = \frac{1}{\sqrt{\lambda}} \Delta_p^{-1} (\lambda s) = \sqrt{\lambda} \Delta_p^{-1} s = \sqrt{\lambda} Q_p' s$$

Projection des profils colonnes.

$$y_j' = y_j Q_p' s \quad y = \begin{pmatrix} y_1 \\ \vdots \\ y_p \end{pmatrix} Q_p' s = \boxed{X_J Q_p' s}$$

Aide à l'interprétation

1) Contribution absolue

• Profils lignes $Ca(i) = \frac{f_{i0}}{\lambda} |w_i|^2$

• Profils colonnes $Ca(j^0) = \frac{f_{0j}}{\lambda} = \frac{1}{\lambda} |y_j|^2$

2) Contribution relative

• Profils lignes $Cr(i) = \frac{2 |w_i|^2}{\sum_{i=0}^n (x_i, \frac{q}{\sqrt{\lambda}})^2}$

• Profils colonnes $Cr(j^0) = \frac{2 |y_j|^2}{\sum_{j=0}^p (y_j, \frac{q}{\sqrt{\lambda}})^2}$

Rg

$$d_{\mathcal{Q}_g}^2(x_i, g_I) = \|x_i - g_I\|_{\mathcal{Q}_g}^2 = (x_i - g_I) \mathcal{Q}_g (x_i - g_I)$$

$$d_{\mathcal{Q}'_g}^2(y_j, g_J) = \|y_j - g_J\|_{\mathcal{Q}'_g}^2 = (y_j - g_J) \mathcal{Q}'_g (y_j - g_J)$$