

L'Analyse Factorielle des Correspondances (AFC)

Marie Chavent

<http://www.math.u-bordeaux.fr/machaven/>

2014-2015

Le but est l'analyse des relations entre deux variables qualitatives. L'AFC s'applique au tableau de contingence \mathbf{K} obtenu à partir du croisement de deux variables qualitatives X_1 et X_2 sur un échantillon de taille n :

$$\mathbf{K} = \begin{array}{c|ccc|c} & 1 & \dots & s & \dots & m & \\ \hline 1 & & & & & & \\ \vdots & & & \vdots & & & \\ i & \dots & & n_{is} & \dots & & n_{i.} \\ \vdots & & & \vdots & & & \\ q & & & & & & \\ \hline & & & n_{.s} & & & \end{array}$$

1 Rappels et notations

Matrice des fréquences \mathbf{F} :

$$\mathbf{F} = \begin{array}{c|ccc|c} & 1 & \dots & s & \dots & m & \\ \hline 1 & & & & & & \\ \vdots & & & \vdots & & & \\ i & \dots & & f_{is} = \frac{n_{is}}{n} & \dots & & f_{i.} \\ \vdots & & & \vdots & & & \\ q & & & & & & \\ \hline & & & f_{.s} & & & \end{array}$$

On note :

- $\mathbf{r} = (f_{1.}, \dots, f_{i.}, \dots, f_{q.})^t \in \mathbb{R}^q$
- $\mathbf{c} = (f_{.1}, \dots, f_{.s}, \dots, f_{.m})^t \in \mathbb{R}^m$
- $\mathbf{D}_r = \text{diag}(\mathbf{r})$
- $\mathbf{D}_c = \text{diag}(\mathbf{c})$

Matrice des profil-lignes \mathbf{L} :

$$\mathbf{L} = \begin{array}{c|ccc|c} & 1 & \dots & s & \dots & m \\ \hline 1 & & & & & \\ \vdots & & & & & \\ i & \dots & & f_{is}/f_{i.} & \dots & \\ \vdots & & & & & \\ \hline \mathbf{c}' & & & f_{.s} & & \end{array}$$

On a :

- $\mathbf{L} = \mathbf{D}_r^{-1} \mathbf{F}$
- Profil ligne moyen : \mathbf{c}

Matrice des profil-lignes centrés \mathbf{L} :

$$\mathbf{L} = \begin{array}{c|ccc|c} & 1 & \dots & s & \dots & m \\ \hline 1 & & & & & \\ \vdots & & & & & \\ i & \dots & & \frac{f_{is} - f_{i.} f_{.s}}{f_{i.}} & \dots & \\ \vdots & & & & & \\ q & & & & & \\ \hline & & & & & \end{array}$$

On a :

- $\mathbf{L} = \mathbf{D}_r^{-1} (\mathbf{F} - \mathbf{r} \mathbf{c}^t)$
- Profil-ligne moyen : origine de \mathbb{R}^m

Matrice des profil-colonnes \mathbf{C} :

$$\mathbf{C} = \begin{array}{c|ccc|c} & 1 & \dots & s & \dots & m & \mathbf{r} \\ \hline 1 & & & & & & \\ \vdots & & & & & & \\ i & \dots & & f_{is}/f_{.s} & \dots & & f_{i.} \\ \vdots & & & & & & \\ q & & & & & & \\ \hline & & & & & & \end{array}$$

On a :

- $\mathbf{C} = \mathbf{F} \mathbf{D}_c^{-1}$
- Profil colonne moyen : \mathbf{r}

Matrice des profil-colonnes centrés \mathbf{C} :

$$\mathbf{C} = \begin{array}{c|ccc|c} & 1 & \dots & s & \dots & m \\ \hline 1 & & & & & \\ \vdots & & & & & \\ i & \dots & & \frac{f_{is} - f_{i.}f_{.s}}{f_{.s}} & & \dots \\ \vdots & & & & & \\ q & & & & & \\ \hline & & & & & \end{array}$$

On a :

- $\mathbf{C} = (\mathbf{F} - \mathbf{r}\mathbf{c}^t)\mathbf{D}_c^{-1}$
- Profil-colonne moyen : origine de \mathbb{R}^q

Deux nuages de points pondérés :

Le nuage des q profil-lignes centrés de \mathbb{R}^m avec :

- \mathbf{r} comme pondération,
- \mathbf{D}_r comme métrique sur \mathbb{R}^q (métrique des poids),
- \mathbf{D}_c^{-1} comme métrique sur \mathbb{R}^m (distance du χ^2).

Le nuage des m profil-colonnes centrés de \mathbb{R}^q avec :

- \mathbf{c} comme pondération,
- \mathbf{D}_r^{-1} comme métrique sur \mathbb{R}^q (distance du χ^2),
- \mathbf{D}_c comme métrique sur \mathbb{R}^m (métrique des poids).

Les inerties de ces deux nuages de points avec ces métriques et pondérations vérifient la propriété suivante :

$$I(\mathbf{L}) = I(\mathbf{C}) = \chi^2/n$$

Objectif de l'AFC et plan du cours :

Il s'agira d'analyser les deux nuages de points pondérés c'est à dire le nuage des profil-lignes (les lignes de la matrice \mathbf{L}) et le nuage des profil-colonnes (les colonnes de la matrice \mathbf{C}). On va donc analyser les lignes et les colonnes de deux matrices différentes (alors qu'en ACP, on analyse les lignes et les colonnes de la même matrice de données quantitatives \mathbf{Z}).

Pour cela, on va projeter "au mieux" :

- les profil-lignes (les modalités de X_1) dans une sous-espace vectoriel (s.e.v.) de \mathbb{R}^m ,
- les profil-colonnes (les modalités de X_2) dans une sous-espace vectoriel (s.e.v.) de \mathbb{R}^q .

Dans ce cours nous allons présenter l'AFC comme une double ACP (ACP de \mathbf{L} et ACP de \mathbf{C}). Puis nous montrerons que les résultats de cette double ACP peuvent être obtenus à partir de l'ACP d'une seule et même matrice c'est à dire à partir de la décomposition en valeurs

singulières (DVSG) de la matrice dite des écarts à l'indépendance. Nous utiliserons ce résultat pour démontrer les propriétés barycentriques qui sont fondamentale pour l'interprétation des résultats.

2 ACP de la matrice des profil-lignes centrés

Les q modalités de la variable X_1 sont décrites par les lignes de la matrice des profil-lignes centrés $\mathbf{L} = \mathbf{D}_r^{-1}(\mathbf{F} - \mathbf{r}\mathbf{c}^t)$. Les profil-lignes centrés sont des points de \mathbb{R}^m :

- Ces points sont pondérés par les poids des lignes (vecteur \mathbf{r}).
- On utilise comme métrique pour comparer deux profil-ligne la distance du χ^2 définie par \mathbf{D}_c^{-1} .

On veut projeter “au mieux” les q modalités de X_1 sur un s.e.v. de \mathbb{R}^m de dimension k (pour $k=2$ on projette sur un plan par exemple) : on veut que les distances entre les modalités projetées soient “aussi proche que possible” des distances entre les modalités dans leur espace d'origine. Ce s.e.v est défini par k axes $\Delta_1, \dots, \Delta_k$, tels que pour chaque axe, la variance des \mathbf{D}_c^{-1} -projections (projections \mathbf{D}_c^{-1} orthogonales) des profil-lignes soit maximale (\mathbf{D}_r norme maximale). Ces axes sont engendrés par des vecteurs $\mathbf{v}_1, \dots, \mathbf{v}_k$ de \mathbb{R}^m . Ces vecteurs doivent être \mathbf{D}_c^{-1} -normés à 1 ($\mathbf{v}_\alpha^t \mathbf{D}_c^{-1} \mathbf{v}_\alpha = 1, \alpha = 1, \dots, k$) et \mathbf{D}_c^{-1} -orthogonaux ($\mathbf{v}_\alpha^t \mathbf{D}_c^{-1} \mathbf{v}_{\alpha'} = 0, \forall \alpha \neq \alpha'$).

On note $\mathbf{x}^\alpha = \mathbf{L}\mathbf{D}_c^{-1}\mathbf{v}_\alpha$ le vecteur de \mathbb{R}^q des projections des q modalités sur l'axe Δ_α avec \mathbf{v}_α qui maximise $\text{Var}(\mathbf{x}^\alpha)$. Les vecteurs \mathbf{v}_α sont les colonnes d'une matrice notée \mathbf{V}_k de dimension $m \times k$. On note enfin $\mathbf{X} = \mathbf{L}\mathbf{D}_c^{-1}\mathbf{V}_k$ la matrice de dimension $q \times k$ des coordonnées des profil-lignes projetés sur $\Delta_1, \dots, \Delta_k$:

- \mathbf{X} est la matrice des coordonnées factorielles des profil-lignes.
- \mathbf{x}^α est la α ème composante principale des profil-lignes.

L'ACP du triplet $(\mathbf{L}, \mathbf{D}_r, \mathbf{D}_c^{-1})$ donne les résultats suivant :

- a) $\mathbf{X} = \mathbf{L}\mathbf{D}_c^{-1}\mathbf{V}_k$ où \mathbf{V}_k est la matrice dont les colonnes sont les k vecteurs propres associés aux k plus grandes valeurs propres $\lambda_1, \dots, \lambda_k$ de $\mathbf{L}^t \mathbf{D}_r \mathbf{L} \mathbf{D}_c^{-1}$.
 \mathbf{V}_k est \mathbf{D}_c^{-1} -orthonormée : $\mathbf{V}_k^t \mathbf{D}_c^{-1} \mathbf{V}_k = \mathbb{I}_k$.
- b) $\text{Var}(\mathbf{x}^\alpha) = \lambda_\alpha$ et $\bar{\mathbf{x}}^\alpha = 0$.
- c) Si $k = \text{rang}(\mathbf{L})$ alors $I(\mathbf{X}) = \lambda_1 + \dots + \lambda_k = I(\mathbf{L}) = \chi^2/n$.

Remarque notation : En ACP, on notait Ψ la matrice des coordonnées factorielles des lignes d'une matrice quantitative \mathbf{Z} et Φ la matrice des coordonnées factorielles des colonnes de cette même matrice. Ici \mathbf{X} correspond à la matrice Ψ des coordonnées factorielles de \mathbf{L} . On ne s'intéresse pas à la matrice Φ des coordonnées factorielles des colonnes de \mathbf{L} .

Exercice 1 : Démontrer a) b) et c) en vous aidant du poly “Rappels sur l'ACP avec métrique”.

Exemple

3 ACP de la matrice des profil-colonnes centrés

Les m modalités de la variable X_2 sont décrites par les colonnes de la matrice des profil-colonnes centrés $\mathbf{C} = (\mathbf{F} - \mathbf{rc}^t)\mathbf{D}_c^{-1}$. Les profil-colonnes centrés sont de points de \mathbb{R}^q :

- Ces points sont pondérés par les poids des colonnes (vecteur \mathbf{c}).
- On utilise comme métrique pour comparer deux profil-colonnes la distance du χ^2 définie par \mathbf{D}_r^{-1} .

On veut maintenant projeter “au mieux” les m modalités de X_2 sur un s.e.v. de \mathbb{R}^q de dimension k . Ce s.e.v est défini par k axes G_1, \dots, G_k , tels que pour chaque axe, la variance des \mathbf{D}_r^{-1} -projections des profil-colonnes soit maximale (\mathbf{D}_c norme maximale). Ces axes sont engendrés par des vecteurs $\mathbf{u}_1, \dots, \mathbf{u}_k$ de \mathbb{R}^q . Ces vecteurs doivent être \mathbf{D}_r^{-1} -normés à 1 et \mathbf{D}_r^{-1} -orthogonaux.

On note $\mathbf{y}^\alpha = \mathbf{C}^t \mathbf{D}_r^{-1} \mathbf{u}_\alpha$ le vecteur de \mathbb{R}^m des projections des m modalités sur l'axe G_α avec \mathbf{u}_α qui maximise $\text{Var}(\mathbf{y}^\alpha)$. Les vecteurs \mathbf{u}_α sont les colonnes de la matrice \mathbf{U}_k de dimension $q \times k$. On note enfin $\mathbf{Y} = \mathbf{C}^t \mathbf{D}_r^{-1} \mathbf{U}_k$ la matrice de dimension $m \times k$ des coordonnées des profil-lignes projetés sur G_1, \dots, G_k :

- \mathbf{Y} est la matrice des coordonnées factorielles des profil-colonnes.
- \mathbf{y}^α est la α ème composante principale des profil-colonnes.

L'ACP du triplet $(\mathbf{C}, \mathbf{D}_r^{-1}, \mathbf{D}_c)$ donne les résultats suivant :

- a) $\mathbf{Y} = \mathbf{C}^t \mathbf{D}_r^{-1} \mathbf{U}_k$ où les colonnes de la matrice \mathbf{U}_k sont les k vecteurs propres associés aux k plus grandes valeurs propres $\lambda_1, \dots, \lambda_k$ de la matrice $\mathbf{C} \mathbf{D}_c \mathbf{C}^t \mathbf{D}_r^{-1}$.
 \mathbf{U}_k est \mathbf{D}_c^{-1} -orthonormée : $\mathbf{U}_k^t \mathbf{D}_c^{-1} \mathbf{U}_k = \mathbb{I}_k$.
- b) $\text{Var}(\mathbf{y}^\alpha) = \lambda_\alpha$ et $\bar{\mathbf{y}}^\alpha = 0$
- c) Si $k = \text{rang}(\mathbf{C})$ alors $I(\mathbf{X}) = \lambda_1 + \dots + \lambda_k = I(\mathbf{C}) = I(\mathbf{L}) = \chi^2/n$.

Remarque notation : Ici \mathbf{Y} correspond à la matrice Φ des coordonnées factorielles des colonnes de \mathbf{C} . On ne s'intéresse pas à la matrice Ψ des coordonnées factorielles des lignes de \mathbf{C} .

Exemple

4 AFC : la SVD généralisée d'une seule matrice

Les matrices \mathbf{X} et \mathbf{Y} des coordonnées factorielles des profil-lignes et des profil-colonnes obtenus dans les deux sections précédentes à partir de l'ACP de deux triplets, peuvent être obtenus à partir de l'ACP du seul triplet $(\mathbf{Z}, \mathbf{N}, \mathbf{M})$ avec :

- $\mathbf{Z} = \mathbf{D}_r^{-1}(\mathbf{F} - \mathbf{rc}^t)\mathbf{D}_c^{-1}$ la matrice des écarts à l'indépendance
- $\mathbf{N} = \mathbf{D}_r$
- $\mathbf{M} = \mathbf{D}_c$

On effectue donc la DVS de \mathbf{Z} avec les métriques \mathbf{N} et \mathbf{M} :

$$\mathbf{Z} = \mathbf{U} \mathbf{\Lambda} \mathbf{V}^t$$

où

- $\Lambda = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_r})$ est la matrice des valeurs singulières de $\mathbf{Z}\mathbf{N}\mathbf{Z}^t\mathbf{M}$ et $\mathbf{Z}^t\mathbf{N}\mathbf{Z}\mathbf{M}$.
- \mathbf{U} est la matrice de dimension $n \times r$ dont les colonnes sont les vecteurs propres de $\mathbf{Z}\mathbf{M}\mathbf{Z}^t\mathbf{N}$ et $\mathbf{U}^t\mathbf{N}\mathbf{U} = \mathbb{I}_r$ (les vecteurs propres sont \mathbf{N} -orthonormés).
- \mathbf{V} est la matrice de dimension $p \times r$ dont les colonnes sont les vecteurs propres de $\mathbf{Z}^t\mathbf{N}\mathbf{Z}\mathbf{M}$ et $\mathbf{V}^t\mathbf{M}\mathbf{V} = \mathbb{I}_r$ (les vecteurs propres sont \mathbf{M} -orthonormés).

On a alors

$$\begin{cases} \mathbf{X} = \mathbf{Z}\mathbf{M}\mathbf{V}_k \\ \mathbf{Y} = \mathbf{Z}^t\mathbf{N}\mathbf{U}_k \end{cases}$$

et on en déduit

$$\begin{cases} \mathbf{X} = \mathbf{U}_k\Lambda_k \\ \mathbf{Y} = \mathbf{V}_k\Lambda_k \end{cases}$$

En pratique, pour effectuer la SVD généralisée d'une matrice \mathbf{Z} avec les métriques \mathbf{N} et \mathbf{M} , on effectue la SVD de $\tilde{\mathbf{Z}} = \mathbf{N}^{1/2}\mathbf{Z}\mathbf{M}^{1/2}$ avec les métriques \mathbb{I}_n et \mathbb{I}_p (implémentée dans les logiciels comme R). On trouve $\tilde{\mathbf{Z}} = \tilde{\mathbf{U}}\tilde{\Lambda}\tilde{\mathbf{V}}^t$ et on a ensuite :

$$\begin{aligned} \mathbf{U} &= \mathbf{N}^{-1/2}\tilde{\mathbf{U}} \\ \mathbf{V} &= \mathbf{M}^{-1/2}\tilde{\mathbf{V}} \\ \Lambda &= \tilde{\Lambda} \end{aligned}$$

5 Propriétés barycentriques

Une composante principale standardisée est une composante divisée par son écart-type : $\mathbf{x}_\alpha/\sqrt{\lambda_\alpha}$ ou $\mathbf{y}_\alpha/\sqrt{\lambda_\alpha}$. La matrice Λ_k étant la matrice diagonale des racines carrés des valeurs propres, les matrices \mathbf{X}^* et \mathbf{Y}^* des coordonnées factorielles standardisés s'écrivent :

$$\begin{cases} \mathbf{X}^* = \mathbf{X}\Lambda_k^{-1} \\ \mathbf{Y}^* = \mathbf{Y}\Lambda_k^{-1} \end{cases} \quad \text{donc} \quad \begin{cases} \mathbf{X}^* = \mathbf{U}_k \\ \mathbf{Y}^* = \mathbf{V}_k \end{cases}$$

On a les relations suivantes :

$$\begin{cases} \mathbf{X} = \mathbf{D}_r^{-1}(\mathbf{F} - \mathbf{r}\mathbf{c}^t)\mathbf{Y}^* \\ \mathbf{Y} = \mathbf{D}_c^{-1}(\mathbf{F} - \mathbf{r}\mathbf{c}^t)^t\mathbf{X}^* \end{cases}$$

Exercice 2 : Retrouvez ces relations.

Ces deux relations s'interprètent aussi en terme de moyennes réciproques : la coordonnée factorielle d'une modalité d'une variable est la moyenne (pondérée) des coordonnées factorielles (standardisées) des modalités de l'autre variable.

En effet on a les relations barycentriques suivantes :

$$\begin{cases} x_{i\alpha} = \sum_{s=1}^m \frac{f_{is}}{f_{i.}} y_{s\alpha}^* \\ y_{s\alpha} = \sum_{i=1}^q \frac{f_{is}}{f_{.s}} x_{i\alpha}^* \end{cases}$$

Et on en déduit les relations quasi-barycentriques suivantes :

$$\begin{cases} x_{i\alpha} = \frac{1}{\sqrt{\lambda_\alpha}} \sum_{s=1}^m \frac{f_{is}}{f_{.i}} y_{s\alpha} \\ y_{s\alpha} = \frac{1}{\sqrt{\lambda_\alpha}} \sum_{i=1}^q \frac{f_{is}}{f_{.s}} x_{i\alpha} \end{cases}$$

Exercice 3 : Retrouvez ces relations.

Interprétations et conséquences de ces relations :

- Au coefficient de dilatation $\frac{1}{\sqrt{\lambda_\alpha}}$ près, les coordonnées factorielles d'un nuage de points sont, sur un axe, les barycentres des coordonnées factorielles de l'autre nuage.
- Les relations quasi-barycentriques justifient la représentation simultanée des profil-lignes et des profil-colonnes sur un même graphique. Mais attention, la distance entre un profil-ligne et un profil-colonne sur ce graphique s'interprète en terme de liaison.
- La coordonnée de la modalité i est la moyenne des coordonnées des modalités s de l'autre variable, pondérée par les fréquences conditionnelles de s sachant i .

Exemple

6 Interprétation des résultats d'une AFC

Les nuages des profil-lignes et des profil-colonnes sont représentés dans les plans de projection formés par les axes factoriels pris deux à deux. La lecture de ces graphiques nécessite des règles d'interprétation.

6.1 Inertie et test d'indépendance

En ACP normée, l'inertie totale du nuage des point-individus est égale à p le nombre de variables. En AFC, on a vu que l'inertie totale du nuage des profil-lignes est égale à l'inertie totale du nuage des profil-colonnes, et est égale au χ^2 d'indépendance entre les deux variables qualitatives :

$$I(\mathbf{L}) = I(\mathbf{C}) = \chi^2(X_1, X_2)/n$$

La valeur de l'inertie est donc un indicateur de la dispersion des nuages de points et une mesure de liaison entre les deux variables qualitatives encore appelée mesure d'écart à l'indépendance.

De plus, on a vu que l'inertie des nuages de points est égale à l'inertie des matrices des coordonnées factorielles \mathbf{X} et \mathbf{Y} "complètes" (lorsque $k = r$). En AFC, il y a au plus $r = \min(q - 1, m - 1)$ valeurs propres non nulles et l'inertie totale vaut $\lambda_1 + \dots + \lambda_r$. Chaque composante principale explique donc une partie de l'inertie mesurée par :

$$\frac{\lambda_\alpha}{\lambda_1 + \dots + \lambda_r} * 100$$

qui s'interprète comme :

- le pourcentage de l'inertie totale expliquée par l'axe α ,
- la part de la liaison entre X_1 et X_2 expliquée par cet axe.

En pratique :

- On peut d'abord réaliser un test du χ^2 pour conclure ou non à l'indépendance entre X_1 et X_2 . On ne réalisera à priori une AFC que si l'on conclue que X_1 et X_2 ne sont pas indépendantes.
- pour savoir combien d'axes retenir, on peut comme en ACP utiliser l'une des règles suivantes :
 - On peut utiliser le pourcentage d'inertie expliquée par les k premiers axes et choisir le nombre k d'axes tel que cette inertie expliquée dépasse un certain seuil (75% par exemple). Attention, il reste néanmoins la nécessité de ne retenir que des axes principaux utiles pour l'interprétation, c'est à dire interprétable.
 - On peut ne retenir que les valeurs propres supérieures à leur moyenne (règle empirique de Kaiser)
 - On peut utiliser la règle du coude :
 - i) calculer les différence premières : $\epsilon_1 = \lambda_1 - \lambda_2, \epsilon_2 = \lambda_2 - \lambda_3, \dots$
 - ii) calculer les différence secondes : $\delta_1 = \epsilon_1 - \epsilon_2, \delta_2 = \epsilon_2 - \epsilon_3, \dots$
 - iii) retenir le nombre k tel que $\delta_1, \dots, \delta_{k-1}$ soient toutes positives et que δ_k soit négative.

D'autres critères peuvent être trouvés p.209 du livre de G. Saporta (2006).

Remarque : les valeurs propres sont toujours inférieures ou égales à 1.

Exemple

6.2 Contributions

La contribution d'une modalité i de X_1 et d'une modalité s de X_2 à l'inertie de l'axe α sont :

$$\begin{cases} \text{Ctr}_\alpha(i) = \frac{f_i \cdot x_{i\alpha}^2}{\lambda_\alpha} \\ \text{Ctr}_\alpha(s) = \frac{f_{\cdot s} y_{s\alpha}^2}{\lambda_\alpha} \end{cases}$$

La contribution $\text{Ctr}_\alpha(i)$ est la part de la variance de l'axe α expliquée par la modalité i . Ce coefficient permet de connaître les modalités responsables de la construction de l'axe α , et permet de trouver une éventuelle signification aux axes.

Attention : En AFC, les points les plus excentrés sur les axes ne sont pas nécessairement ceux qui contribuent le plus (à cause des poids f_i et $f_{\cdot s}$).

Exercice 4 : Dans l'exemple, retrouvez le calcul de la contribution de la modalité marron à l'axe 1.

6.3 Cosinus carrés

Le cosinus carré de l'angle entre le profil-ligne \mathbf{l}_i et l'axe Δ_α mesure la qualité de la projection de ce profil sur cet axe :

$$\cos_\alpha^2(i) = \frac{x_{i\alpha}^2}{d^2(\mathbf{l}_i, \mathbf{c})}$$

où $d^2(\mathbf{l}_i, \mathbf{c}) = \sum_{s=1}^m \frac{1}{f_{i.s}} (f_{is}/f_{i.} - f_{.s})^2$ est la distance du χ^2 entre le profil-ligne \mathbf{l}_i et le profil-ligne moyen \mathbf{c} .

De même pour les modalités s de la variable X_2 , on calcule le cosinus carré de l'angle entre le profil-colonne \mathbf{c}_s et l'axe G_α pour mesurer la qualité de la projection de ce profil sur cet axe :

$$\cos_\alpha^2(s) = \frac{y_{s\alpha}^2}{d^2(\mathbf{c}_s, \mathbf{r})}$$

où $d^2(\mathbf{c}_s, \mathbf{r}) = \sum_{i=1}^m \frac{1}{f_{i.s}} (f_{is}/f_{.s} - f_{i.})^2$ est la distance du χ^2 entre le profil-ligne \mathbf{c}_s et le profil-colonne moyen \mathbf{r} .

Pour analyser les proximités entre les points sur les graphiques factoriels, on s'intéresse surtout aux points bien projetés (ayant un \cos^2 élevé) car les proximités entre ces points observées sur le graphique est "proche" de celle dans l'espace d'origine.

Exercice 5 : Dans l'exemple, retrouvez le calcul du \cos^2 de la modalité marron sur l'axe 1.

Attention : Pour interpréter des proximités entre deux points sur un graphique il faut prendre des précautions :

- Si deux modalités d'une même variable sont proches et bien projetées (bien représentées), cela signifie que leurs profils sont semblables.
- Par contre, la proximité entre une modalité d'une variable et une modalité de l'autre, est plus délicate à interpréter. Elle s'interprète avec les relations barycentriques.

7 Références

- "Statistique exploratoire multidimensionnelle", Lebart & al., Dunod.
- "Probabilité, analyse des données, statistique", G. Saporta, Technip.