

Recherche des valeurs propres :

$$A = \begin{bmatrix} 3 & -2 & 2 \\ -1 & 1 & 3 \\ 2 & 3 & 1 \end{bmatrix}$$

On pose

$$\begin{vmatrix} 3-\lambda & -2 & 2 \\ -1 & 1-\lambda & 3 \\ 2 & 3 & 1-\lambda \end{vmatrix} = 0$$

$$\Leftrightarrow \begin{vmatrix} 3-\lambda & 0 & 2 \\ -1 & 4-\lambda & 3 \\ 2 & 4-\lambda & 1-\lambda \end{vmatrix} = 0 \quad \Leftrightarrow \begin{vmatrix} 3-\lambda & 0 & 2 \\ -3 & 0 & 2+\lambda \\ 2 & 4-\lambda & 1-\lambda \end{vmatrix} = 0$$

$$\Leftrightarrow -(4-\lambda) \begin{vmatrix} 3-\lambda & 2 \\ -3 & 2+\lambda \end{vmatrix} = 0$$

...

$$\Leftrightarrow (\lambda-4)(-\lambda^2+\lambda+12) = 0$$

$$\Leftrightarrow \lambda-4 = 0 \quad \text{ou} \quad -\lambda^2+\lambda+12 = 0$$

$$\Leftrightarrow \lambda_1 = 4, \lambda_2 = -3, \lambda_3 = 4.$$

$$S = \{4; -3\}.$$

Recherche des vecteurs propres :

On part du même exemple que précédemment.

Pour $\lambda = -3$:

$$A\vec{u} = \lambda\vec{u}$$

$$\Leftrightarrow \begin{bmatrix} 3 & -2 & 2 \\ -1 & 1 & 3 \\ 2 & 3 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} = -3 \begin{bmatrix} x \\ y \\ z \end{bmatrix}$$

$$\Leftrightarrow \begin{bmatrix} 3x - 2y + 2z \\ -x + y + 3z \\ 2x + 3y + z \end{bmatrix} = \begin{bmatrix} -3x \\ -3y \\ -3z \end{bmatrix}$$

$$\Leftrightarrow \begin{bmatrix} 6 & -2 & 2 & 0 \\ -1 & 4 & 3 & 0 \\ 2 & 3 & 4 & 0 \end{bmatrix} \quad \text{matrice augmentée}$$

$$\Leftrightarrow \begin{bmatrix} 6 & -2 & 2 & 0 \\ 0 & 22 & 20 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad \Leftrightarrow \begin{cases} 6x - 2y + 2z = 0 \\ 22y + 20z = 0 \end{cases}$$

$$\Leftrightarrow \begin{cases} x = \frac{7}{10}y \\ z = -\frac{11}{10}y \end{cases} \quad \Rightarrow \vec{u} = \begin{bmatrix} \frac{7}{10}y \\ y \\ -\frac{11}{10}y \end{bmatrix} \quad y \in \mathbb{R}.$$

Faire de même pour $\lambda = 4$.

Analyse de données 2/6

Recherche des vecteurs propres unitaires :

On part du même exemple que précédemment.

$$\text{On a } \vec{u} = \begin{bmatrix} 7/10 y \\ y \\ 11/10 y \end{bmatrix} \quad y \in \mathbb{R}.$$

$$\text{On pose } \|\vec{u}\|^2 = 1 \quad (\text{car unitaire})$$

$$\Rightarrow (7/10 y)^2 + y^2 + (11/10 y)^2 = 1$$

$$\Rightarrow \frac{270 y^2}{100} = 1$$

$$\Rightarrow 270 y^2 = 100$$

$$\Rightarrow y^2 = 10/27$$

$$\Rightarrow y = \sqrt{10/27} \text{ ou } -\sqrt{10/27}$$

$$\rightarrow \begin{bmatrix} 7/10 \sqrt{10/27} \\ \sqrt{10/27} \\ 11/10 \sqrt{10/27} \end{bmatrix} \text{ ou } \begin{bmatrix} -7/10 \sqrt{10/27} \\ -\sqrt{10/27} \\ -11/10 \sqrt{10/27} \end{bmatrix}$$

Distance :

| individu | poids | taille | âge | note |
|----------|-------|--------|-----|------|
| Bob | 60 | 175 | 15 | 9 |
| Billy | 60 | 170 | 14 | 10 |
| Brian | 60 | 170 | 14 | 7 |

$$d^2(\text{Bob, Billy}) = (60-60)^2 + (175-170)^2 + (15-14)^2 + (9-10)^2 = 27.$$

$$d^2(\text{Bob, Brian}) = (60-60)^2 + (175-170)^2 + (15-14)^2 + (9-7)^2 = 30.$$

$$d^2(\text{Billy, Brian}) = (60-60)^2 + (170-170)^2 + (14-14)^2 + (10-7)^2 = 9.$$

Si l'on considère la taille en mètre, celle-ci devient très négligeable dans le calcul de la distance (par exemple $(1,75 - 1,70)^2 = 0,0025$). La distance entre Billy et Brian devient alors la plus élevée.

On appelle cela l'effet d'échelle.

Centrer les données ne modifie pas les distances.

Analyse de données ^{3/6}

Calcul du χ^2 (khi-deux) :

| | Caractère 1 | Caractère 2 | Total |
|----------|-------------|-------------|-------|
| Classe 1 | 68 | 60 | 128 |
| Classe 2 | 37 | 14 | 51 |
| Total | 105 | 74 | 179 |

On établit le tableau des k' . Pour chaque case, on multiplie le total ligne par le total colonne, et on divise par l'effectif total.

| | Caractère 1 | Caractère 2 | Total |
|----------|-------------|-------------|-------|
| Classe 1 | 75,1 | 52,9 | 128 |
| Classe 2 | 29,9 | 21,1 | 51 |
| Total | 105 | 74 | 179 |

Tableau des
effectifs
théoriques

Ensuite on utilise $\chi^2_{obs} = \sum_i \sum_j \frac{(k_{ij} - k'_{ij})^2}{k'_{ij}}$.

$$\chi^2_{obs} = \frac{(68 - 75,1)^2}{75,1} + \frac{(60 - 52,9)^2}{52,9} + \frac{(37 - 29,9)^2}{29,9} + \frac{(14 - 21,1)^2}{21,1}$$

$$= 0,671 + 0,953 + 1,686 + 2,389$$

$$= 5,699.$$

Ensuite, on cherche le χ^2_{th} .

On calcule le degré de liberté $\nu = (n-1)(p-1)$
 $= (2-1)(2-1)$
 $= 1$.

On va donc regarder la ligne 1 de la table des χ^2_{th} .

Selon le seuil demandé, on choisit sa colonne :

Seuil de 5% \rightarrow colonne $\chi^2_{0,95}$

Seuil de 10% \rightarrow colonne $\chi^2_{0,90}$

etc...

Prenons ici 5%, on regarde donc la colonne $\chi^2_{0,95}$ et la ligne 1.

On a $\chi^2_{th} = 3,84$.

On a ici $\chi^2_{obs} > \chi^2_{th}$ donc une dépendance entre nos classes et nos caractères.

Si c'était l'inverse, il y aurait eu indépendance.

Quelle méthode choisir ?

ACP \leftarrow n variables quantitatives de même importance

AFC \leftarrow 2 variables seulement, quelconques

ACT1 \leftarrow n variables quelconques

ACP

On utilise des données centrées réduites si :

- les unités sont différentes
- les ordres de grandeurs sont différents
- les variances/écart types, sont trop différents

① Choisir le type d'ACP (centrée ? centrée réduite ?)

② Analyser la matrice des corrélations

- Relever les fortes corrélations et anticorrélations

③ Choisir les axes

On relève les plus importantes valeurs propres λ et on donne le QGE (Qualité Globale d'Information).

$$\text{Qualité}_{\lambda_i} = \frac{\lambda_i}{\text{trace}} \cdot 100.$$

La trace est égale à la somme des valeurs propres.

On a ainsi quelque chose comme :

$$\text{Axe 1 : } \frac{\lambda_1}{\text{trace}} \cdot 100 = 47,25\%$$

$$\text{Axe 2 : } \frac{\lambda_2}{\text{trace}} \cdot 100 = 19,27\%$$

$$\text{Axe 3 : } \frac{\lambda_3}{\text{trace}} \cdot 100 = 12,49\%$$

$$\text{QGE} = 47,25 + 19,27 + 12,49 = 79,01\%$$

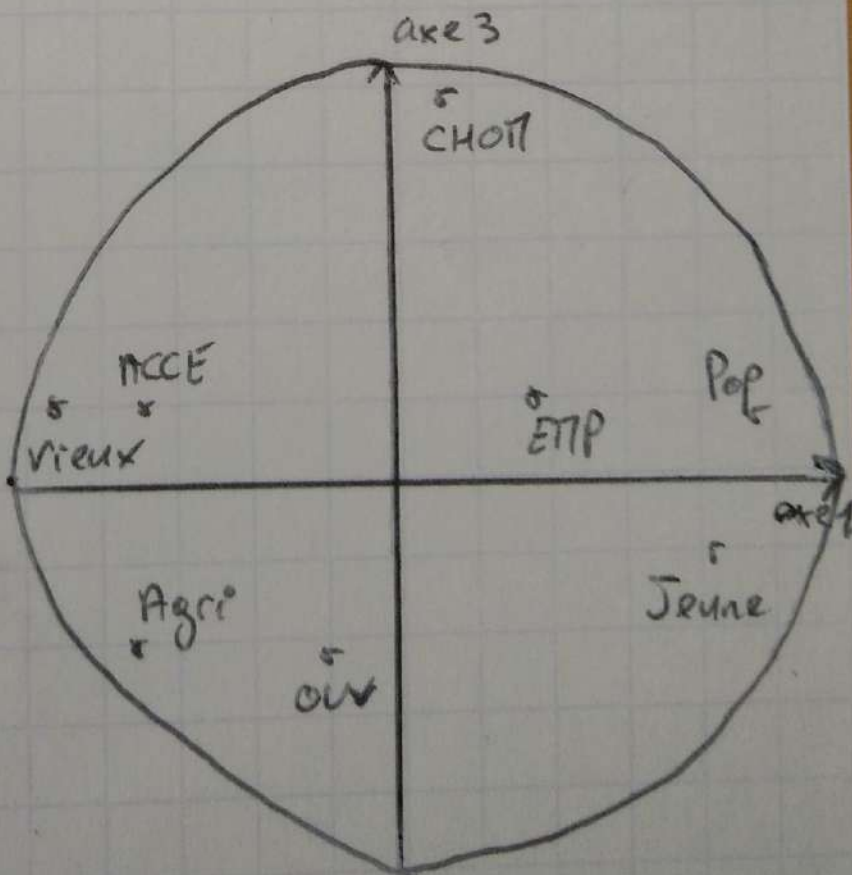
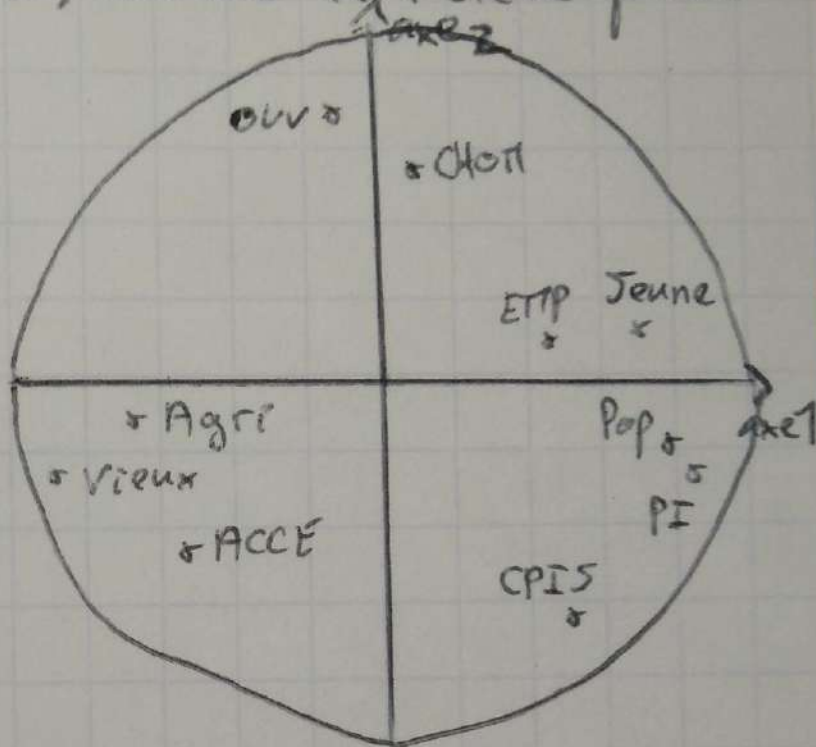
④ Cercles de corrélations

On trace un ou plusieurs cercles de corrélation en fonction du nombre d'axes choisis. On y place les variables grâce aux coordonnées de la matrice des saturations.

Analyse de données 5/6

On relève pour chaque variable l'axe où la saturation est la plus forte (en valeur absolue). Si elle n'est pas notable, on ne la relève pas.

| | axe1 | axe2 | axe3 |
|-------|--------|--------|--------|
| Pop | 0,490 | -0,279 | 0,213 |
| Jeune | 0,743 | 0,456 | -0,201 |
| Vieux | -0,945 | -0,154 | 0,187 |
| Agri | -0,826 | -0,068 | -0,312 |
| ACCE | -0,574 | -0,449 | 0,178 |
| CPIS | 0,724 | -0,589 | -0,098 |
| PI | 0,882 | -0,221 | -0,245 |
| ETP | 0,539 | 0,315 | 0,238 |
| OUV | -0,185 | 0,898 | -0,271 |
| CHOTI | 0,124 | 0,331 | 0,892 |



Axe 1: Pop, PI, CPIS, jeune
- vieux, agri

Axe 2: OUV

Axe 3: CHOTI

⑤ Choix et analyse des individus intéressants

Relever les individus illustrants le mieux les axes, à partir du tableau des composantes principales.

| Axe 1 | | Axe 2 | | Axe 3 | |
|------------|---|-------|----|-------|---|
| ⊖ | ⊕ | ⊖ | ⊕ | ⊖ | ⊕ |
| individu 3 | 4 | 2 | 27 | | |
| 12 | 5 | 14 | | | |
| 8 | | | | | |
| | | | | | |

⑥ Synthèse

↳ Conclure l'analyse

AFC

① Test d'indépendance

• Comparer χ_{obs}^2 et χ_{th}^2

• $\chi_{obs}^2 = NR$ avec N l'effectif total et R l'inertie totale (somme des λ)

• $\chi_{obs}^2 > \chi_{th}^2 \Rightarrow$ dépendance

② Analyse des PFL et PFC

Pour chaque variable, on note sa fréquence totale (par exemple 25%). Puis, on détermine un pourcentage (par exemple 10%) de cette fréquence afin d'avoir un intervalle (22,5 - 27,5). Pour chaque variable, on relève alors les classes sous-représentées (sous l'intervalle) et sur-représentées (après l'intervalle) sur le tableau des PFL. Faire de même pour les PFC.

③ Choix des axes

Idem que pour l'ACP avec les 2 et le QSE

④ Représentations graphiques

Idem que pour l'ACP mais sans le cercle
Plus on est proche du centre, plus on est proche du profil moyen.

⑤ Synthèse

• Conclure l'analyse

ACT1

• Généralisation de l'APC

• On remplace les données qualitatives par des données quantitatives via un codage (que l'on choisit sur le coup au plus pratique).

$$r R = \frac{m}{q} - 1$$

m : nombre de modalités (vieux, jeune, homme, femme, etc...)
q : nombre de variables (âge, sexe, etc...)