

Analyse en Composantes Principales

Exploration multidimensionnelle des données

Dhafer Malouche

<http://essai.academia.edu/DhaferMalouche>
dhafer.malouche@me.com

Janvier 2014

Plan

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

Exemple 1 : decathlon

- ▶ **Source :** package FactoMineR
- ▶ **Cadre des données :**
 - ▶ JO athènes 23/24 Août 2004
 - ▶ Decastar 25/26 Septembre 2004
- ▶ **Variables :**
 - ▶ 10 scores des athlètes (épreuve du décathlon)
 - ▶ Total des points, classement des athlètes
 - ▶ Variable compétition.
- 12 Variables quantitatives, 1 Variable qualitative.
- ▶ **Individus :** 41 athlètes.

Exemple 1 : decathlon

Objectif

- ▶ Obtenir une typologie des athlètes par rapport à leurs performances.
- ▶ Définir des dimensions et des facteurs en commun entre les variables : un facteur de puissance, un facteur de rapidité...
- ▶ Interpréter la typologie par au score final et/ou rang de l'athlète.
- ▶ Y-a-t-il une différence entre les scores des JO d'Athènes et Decastar ?

Exemple 2 : Climat en Europe

- ▶ **Source :**

<http://www.factominer.free.fr/book/temperature.csv>

- ▶ **Description :** Une investigation du climat dans différentes villes en Europe.

- ▶ **Variables :**

- ▶ Température mensuelle (de Janvier à Décembre)
- ▶ Les coordonnées GPS de chaque ville.
- ▶ Amplitude thermale : Différence entre les températures maximales et minimales
- ▶ Moyenne Annuelle.
- ▶ Une variable qualitative : la direction (S, N, O, E).

- ▶ **Objectif :** Comprendre la variabilité de la température dans différentes villes européennes.

Exemple 3 : Données génomiques

- ▶ **Source :**

<http://factominer.free.fr/book/chicken.csv>

- ▶ **Description :** 43 poulets ayant subis 6 régimes : régime normal (N), Jeûne pendant 16h (F16), Jeûne pendant 16h et puis se réalimenter pendant 5h (F16R5), (F16R16), (F48), (F48R24)

- ▶ **Variables :** Après le régime, on a effectué une analyse des gènes utilisant une puce ADN : 7407 expressions de gènes.

- ▶ **Objectif :**

- ▶ Voir si les gènes s'expriment différemment selon le niveau de stress.
- ▶ Combien de temps lui faut-il le poulet pour revenir à la situation normale ?

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

- ▶ Commande `princomp`
- ▶ Package `FactoMineR` : commande PCA, un Plugin Rcmdr
- ▶ Package `ade4` : commande `dudi.pca` et une interface Tcl/Tk
- ▶ Package `pcaMethods` : différents types de méthodes d'ACP.
- ▶ Package `rattle`
- ▶ Package `JGR`, `Deducer..`

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

Les données : Individus et variables

- ▶ $E = \{w_1, \dots, w_n\}$ un échantillon de taille n .
- ▶ x^1, \dots, x^d , d variables **quantitatives**.
- ▶ y une variable quantitative supplémentaire, $y = f(x^1, \dots, x^d)$, **f inconnue**.
- ▶ A une variable qualitative supplémentaire à r modalités : a_1, \dots, a_r .
- ▶ les observations :
 - ▶ quantitatives : $x_i^j = x^j(w_i)$, $\forall i = 1 \dots n$ et $j = 1 \dots d$.
 - ▶ supplémentaire quantitative : $y_i = y(w_i)$, $\forall i = 1 \dots n$.
 - ▶ supplémentaire qualitative : $a_l = A(w_i)$, $\forall i = 1 \dots n$ et $l = 1 \dots r$.

x^1, \dots, x^d variables **actives**, y et A variables **supplémentaires** et $X = (x_i^j)$ est la matrice $n \times d$ des variables actives.

Les éléments de l'analyse

- p_i est le poids de chaque individu w_i dans l'échantillon E :

$$p_i \in [0, 1], \sum_{i=1}^n p_i = 1$$

- . Matrice des poids

$$D = \begin{pmatrix} p_1 & & 0 \\ & \ddots & \\ 0 & & p_n \end{pmatrix}$$

- **Nuage des individus** : chaque individu w_i est représenté par $x_i = {}^t(x_i^1, \dots, x_i^d) \in \mathbb{R}^d$. $\mathcal{N}_I = \{x_i \in \mathbb{R}^d, i = 1 \dots n\}$.
- **Nuage des variables** : chaque variable x^j est représentée par $x^j = {}^t(x_1^j, \dots, x_n^j) \in \mathbb{R}^n$. $\mathcal{N}_V = \{x^j \in \mathbb{R}^n, j = 1 \dots d\}$.

Géométries dans \mathbb{R}^n et \mathbb{R}^d

- Centre de gravité de \mathcal{N}_I , $g = {}^t(\bar{x}^1, \dots, \bar{x}^d) \in \mathbb{R}^d$ où

$$\bar{x}^j = \sum_{i=1}^n p_i x_i^j \text{ est la moyenne de } x^j$$

Pour la suite X est une matrice centrée $\Rightarrow g = 0$.

- \mathbb{R}^d est un espace euclidien muni du produit scalaire usuel :

$$\langle x_i, x_{i'} \rangle = {}^t(x_i) x_{i'} = \sum_{j=1}^d x_i^j x_{i'}^j.$$

- \mathbb{R}^n est un espace euclidien muni du produit scalaire :

$$\langle x^j, x^{j'} \rangle = {}^t(x^j) D x^{j'} = \sum_{i=1}^n p_i x_i^j x_i^{j'}.$$

C'est un produit scalaire de métrique D .

Variances, Covariances et Corrélations

- Variance de la variable x^j :

$$\text{Var}(x^j) = \sum_{i=1}^n p_i (x_i^j)^2$$

$\Rightarrow \text{Var}(x^j) = \|x^j\|^2$ dans \mathbb{R}^n .

- Covariance entre les variables x^j et $x^{j'}$

$$\text{Cov}(x^j, x^{j'}) = \sum_{i=1}^n p_i x_i^j x_i^{j'} = \langle x^j, x^{j'} \rangle.$$

- Corrélation entre les variables x^j et $x^{j'}$

$$\text{Cor}(x^j, x^{j'}) = \frac{\text{Cov}(x^j, x^{j'})}{\sqrt{\text{Var}(x^j) \text{Var}(x^{j'})}} = \frac{\langle x^j, x^{j'} \rangle}{\|x^j\| \|x^{j'}\|} = \cos \alpha$$

où α est l'angle entre les vecteurs x^j et $x^{j'}$ dans \mathbb{R}^n .

ACP : Problématique

- ▶ Trouver un sous-espace vectoriel de dimension faible (2 ou 3) pour faire une représentation des graphiques des variables et des individus.
- ▶ Cette représentation a pour objectif de bien montrer
 - ▶ les relations existantes entre les variables : les *corrélations*.
 - ▶ les similarités et les éventuels sous-groupes dans l'échantillon.
- ▶ Chercher une suite de variables **artificielles** C^1, \dots, C^k , $k \ll d$, qui
 - ▶ sont combinaisons linéaires des variables x^1, \dots, x^d ,
 - ▶ **non-corrélées** entre elles
 - ▶ et captent le maximum de variance du nuage des individus \mathcal{N}_I .

ACP : Deux approches, 1ère approche

- ▶ La variance totale du nuage des points :

$$I(\mathcal{N}_I) = \sum_{i=1}^n p_i d(0, x_i)^2 = \sum_{i=1}^n p_i \|x_i\|^2$$

- ▶ On va chercher $u \in \mathbb{R}^d$, $\|u\| = {}^t u u = 1$, tel que la variance totale de la projection de \mathcal{N}_I sur $\langle u \rangle$ soit maximale.

$$I(\mathcal{N}_I^\perp) = \sum_{i=1}^n p_i d\left(0, x_i^\perp\right)^2 = \sum_{i=1}^n p_i \|x_i^\perp\|^2$$

ACP : Deux approches, 1ère approche

- Or $x_i^\perp = \langle u, x_i \rangle u = {}^t x_i u u$, $\|x_i^\perp\|^2 = ({}^t x_i u)^2$ et donc

$$I(\mathcal{N}_I^\perp) = \sum_{i=1}^n p_i ({}^t x_i u)^2 = {}^t u V u$$

où $V = {}^t X D X$ est la matrice variance.

- Notre problème, dans une ACP, est

$$\max_{u \in \mathbb{R}^d, \|u\|=1} {}^t u V u$$

- Solution u^1 sera appelée **1er facteur principale (Loadings)**.

ACP : Deux approches, 2ième approche

- ▶ Chercher une variable artificielle C , combinaison linéaire des variables x^1, \dots, x^d , et qui soit de variance maximale.
- ▶ D'une façon équivalente : chercher les réels u_1, \dots, u_d tels que $C = \sum_{j=1}^d u_j x^j$ soit de variance maximale.
Les u_j doivent vérifier $\sum_{j=1}^d (u_j)^2 = 1$.
- ▶ Notre problème, dans une ACP, est

$$\max_{u \in \mathbb{R}^d, \|u\|=1} {}^t u V u$$

- ▶ Solution C^1 sera appelée **1ère composante principale**.

Solution

- ▶ Posons

$$\mathcal{L}(\lambda) = {}^t u V u = {}^t u V u - \lambda({}^t u u - 1)$$

- ▶ u est un maximum si

$$\frac{\partial}{\partial u} {}^t u V u = 0, \iff \frac{\partial}{\partial u} \mathcal{L}(\lambda) = 0$$

- ▶ Mais

$$\frac{\partial}{\partial u} \mathcal{L}(\lambda) = 2V u - 2\lambda u$$

- ▶ Si u est un maximum de ${}^t u V u$ alors u est un vecteur propre de V de norme 1.
- ▶ V étant une matrice définie positive : V admet d valeurs propres positives

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d.$$

- ▶ u est le vecteur propre associé à la plus grande valeur de V .

Solution...suite

- ▶ $u^1 = {}^t(u_1^1, \dots, u_d^1) \in \mathbb{R}^d$ un vecteur propre, $\| u^1 \| = 1$, associé à λ_1 .
- ▶ On a ${}^t(u^1)Vu^1 = \lambda_1 {}^t(u^1)u^1 = \lambda_1$.
- ▶ La coordonnée de chaque individu w_i sur $\langle u^1 \rangle$ est ${}^t x_i u^1 = \sum_{j=1}^d x_i^j u_j^1$.
- ▶ Les coordonnées de tous les individus s'écrivent dans la matrice colonne suivante

$$C^1 = X u^1 = {}^t \left(\sum_{j=1}^d x_1^j u_j^1, \dots, \sum_{j=1}^d x_n^j u_j^1 \right) = \sum_{j=1}^d u_j^1 x^j$$

- ▶ $\text{Var}(C^1) = {}^t(C^1)DC^1 = {}^t(u^1){}^t XDXu^1 = {}^t(u^1)Vu^1 = \lambda_1$.

Précautions

- ▶ Comme $C^1 = u_1^1 x^1 + \dots + u_j^1 x^j$, donc x^1, \dots, x^d doivent être mesurées avec la **même unité**.
- ▶ Comme $\text{Var}(C^1)$ est maximale, donc il faut que les valeurs des variances de x^1, \dots, x^d ne soient pas très différentes les unes des autres.
- ▶ Solution : réduire toutes les variables
 $x^1, \dots, x^d \rightarrow z^1, \dots, z^d$

$$z_i^j = \frac{x_i^j - \bar{x}^j}{\sigma^j}.$$

C'est l'Analyse en Composantes Principales **normée**.

- ▶ Par contre, si toutes les variables x^j sont des variables ordinaires (enquêtes de satisfaction) il est souhaitable d'utiliser une ACP non-normée.

Les autres composantes principales

- ▶ Chercher un vecteur unitaire $u \in \mathbb{R}^d$ **orthogonal** à u^1 et tel que

$$\sum_{i=1}^n p_i d(x_i, x_i^\perp)^2$$

soit minimale où x_i^\perp pour tout $i = 1, \dots, n$, est la projection orthogonale de x_i sur $\langle u \rangle$.

- ▶ Solution : u^2 un vecteur propre associé à $\lambda_2 \leq \lambda_1$ et orthogonal à u^1 .
- ▶ $C^2 = X u^2 = \sum_{j=1}^d u_j^2 x^j$ est la **deuxième composante principale**.
- ▶ C^1 et C^2 sont deux variables non corrélées :

$$\text{Cov}(C^1, C^2) = {}^t(C^1)D(C^2) = {}^t(u^1) {}^t X D X(u^2) = \lambda_2 {}^t(u^1)u^2 = 0$$

Propriétés

- ▶ On peut construire toutes les composantes principales C^1, C^2, \dots, C^d telles

$$C^k = X u^k = \sum_{j=1}^d u_j^k x^j, \quad \text{Var}(C^k) = \lambda_k$$

où u^1, \dots, u^d est une base orthonormée de vecteurs propres de V :

$$\langle u^k, u^{k'} \rangle = \delta_{kk'} \quad \text{et} \quad Vu^k = \lambda_k u^k.$$

- ▶ Posons $\mathbf{C} = (C^1 | \dots | C^d)$ ($n \times d$) et $\mathbf{u} = (u^1 | \dots | u^d)$ ($d \times d$) :

$$\mathbf{C} = X\mathbf{u} = (C_i^k), \quad {}^t\mathbf{C}\mathbf{D}\mathbf{C} = \Lambda \quad \text{et} \quad \mathbf{u} {}^t\mathbf{u} = I_d \quad \text{où} \quad \Lambda = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_j \end{pmatrix}.$$

¹Cette Conditionne entraîne que ${}^t\mathbf{u}\mathbf{u} = I_d \Rightarrow {}^t\mathbf{u} = \mathbf{u}^{-1}$ et donc $\mathbf{u} {}^t\mathbf{u} = I_d$

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

Reconstitution des données

► $\mathbf{C} = X\mathbf{u} \iff X = \mathbf{C}^t \mathbf{u}$

$$\Rightarrow \forall i = 1, \dots, n, x_i = \sum_{k=1}^d C_i^k u^k.$$

(C_i^1, \dots, C_i^d) sont les coordonnées de l'individu w_i dans la BON $\{u^1, \dots, u^d\}$ et si $(x_i)_k^\perp$ est le projeté orthogonal de x_i sur $\langle u^k \rangle$ (le k -ième **axe principal**) est

$$(x_i)_k^\perp = C_i^k u^k = \left(\sum_{j=1}^d x_i^j u_j^k \right) u^k.$$

- Pour représenter les individus sur le plan engendré par les deux premiers axes principaux, il suffit de considérer les deux premières colonnes de \mathbf{C} .

Qualité de la représentation

- ▶ $\mathcal{N}_I^k = \{(x_1)_k^\perp, \dots, (x_n)_k^\perp\}$ est la projection du nuage \mathcal{N}_I sur $\langle u^k \rangle$.
- ▶ L'inertie totale du nuage \mathcal{N}_I s'exprime par

$$I = \sum_{i=1}^n p_i d(0, x_i)^2 = \sum_{i=1}^n p_i {}^t(x_i) x_i = \text{tr}({}^t X D X) = \sum_{j=1}^d (\sigma_j^2) = \sum_{k=1}^d \lambda_k$$

- ▶ L'inertie du nuage \mathcal{N}_I^k s'exprime par

$$I_k = \sum_{i=1}^n p_i d(0, (x_i)_k^\perp)^2 = \sum_{i=1}^n p_i {}^t((x_i)_k^\perp) (x_i)_k^\perp = {}^t(u^k) {}^t X D X u^k = \lambda_k.$$

- ▶ La qualité de la représentation sur $\langle u^k \rangle$ se mesure par

$$\frac{\lambda_k}{\sum_{l=1}^d \lambda_l}.$$

Qualité de la représentation...

- Contribution d'un individu w_i à l'inertie totale

$$\text{Ctr}(x_i) = \frac{p_i^T(x_i)x_i}{I} = \frac{\sum_{k=1}^d (C_i^k)^2}{\sum_{k=1}^d \lambda_k}$$

$\text{Ctr}(x_i)$ permet d'indiquer la présence d'une observation aberrante.

- Contribution d'un individu w_i à l'inertie du k -ième axe principal $\langle u^k \rangle$

$$\text{Ctr}_k(x_i) = \frac{(C_i^k)^2}{\sum_{l=1}^d \lambda_l}$$

- \cos^2 de l'angle entre x_i et $(x_i)_k^\perp$ mesure la qualité de la représentation de x_i sur $\langle u^k \rangle$

$$\cos_k^2(x_i) = \frac{(C_i^k)^2}{t(x_i)x_i}$$

Reconstitution des données

► $\mathbf{C} = X\mathbf{u} \iff X = \mathbf{C}^t \mathbf{u}$

$$\Rightarrow \forall j = 1, \dots, d, x^j = \sum_{k=1}^d u_j^k C^k.$$

- Comme $\{C^1, \dots, C^d\}$ est une famille de vecteurs orthogonaux 2 à 2 dans \mathbb{R}^n muni de la métrique D , $\forall k \neq k'$,

$$\text{Cov}(C^k, C^{k'}) = \langle C^k, C^{k'} \rangle = {}^t(C^k)D(C^{k'}) \text{ et } \|C^k\| = \sqrt{\lambda_k}.$$

On considère la famille $\{Z^1, \dots, Z^d\}$ où $\forall k = 1, \dots, d$

$$Z^k = \frac{C^k}{\sqrt{\lambda_k}}$$

$\langle Z^k \rangle$ est appelé le k -ième **axe unitaire**.

- La projection orthogonale de x^j sur $\langle Z^k \rangle$, s'exprime alors

$$(x^j)^\perp = u_j^k \sqrt{\lambda_k} Z^k.$$

$\Rightarrow u_j^k \sqrt{\lambda_k}$ est la coordonnée de x^j sur $\langle Z^k \rangle$.

Interprétation et qualités

- ▶ Rappelons que

$$\forall, j = 1, \dots, d, \quad x^j = \sum_{k=1}^d u_j^k \sqrt{\lambda_k} Z^k$$

$$\forall, k = 1, \dots, d, \quad C^k = \sum_{j=1}^d u_j^k x^j$$

$$\Rightarrow \text{Var}(x^j) = \|x^j\|^2 = \sum_{k=1}^d (u_j^k)^2 \lambda_k$$

$\Rightarrow \text{Ctr}_k(x^j \sim Z^k) = \frac{(u_j^k)^2 \lambda_k}{\text{Var}(x^j)}$ est la contribution de Z^k dans l'explication de x^j .

Interprétation et qualités

- ▶ Comme $\sum_{j=1}^d (u_j^k)^2 = 1 \Rightarrow \lambda_k = \sum_{j=1}^d (u_j^k)^2 \lambda_k$, et comme $\text{Var}(C^k) = \lambda_k$ et $\text{Var}((x^j)_k^\perp) = (u_j^k)^2 \lambda_k$.
- $\Rightarrow \text{Ctr}_k(C^k \sim x^j) = (u_j^k)^2$
- ▶ Calculons la corrélation entre x^j et C^k ?

$$\text{Cor}(x^j, C^k) = \text{Cor}(x^j, Z^k) = \frac{\langle x^j, Z^k \rangle}{\sqrt{\text{Var}(x^j) \text{Var}(Z^k)}} = \frac{u_j^k \sqrt{\lambda_k}}{\sqrt{\text{Var}(x^j)}}.$$

Si X est une matrice centrée-réduite (i.e., $\text{Var}(x^j) = 1$, $\forall j$).

$$\text{Cor}(x^j, C^k) = u_j^k \sqrt{\lambda_k}.$$

Qualité de représentation des variables

- ▶ On calcule de \cos^2 de l'angle entre x^j et $(x^j)_k^\perp$:

$$\cos^2 \left(x^j, (x^j)_k^\perp \right) = \frac{\| (x^j)_k^\perp \|^2}{\| x^j \|^2} = \frac{(u_j^k)^2 \lambda_k}{\text{Var}(x^j)} = (\text{Cor}(x^j, C^k))^2.$$

- ▶ Dans le cas d'une ACP normée, $\text{Var}(x^j) = \| x^j \|^2 = 1, \forall j$.
 - ▶ $\| (x^j)_k^\perp \|^2 \leq \| x^j \|^2 = 1 \Rightarrow$ la projection de x^j se trouve à l'intérieur d'un cercle de rayon : **cercle de corrélation**.
 - ▶ $\| (x^j)_k^\perp \|^2 = \cos^2 (x^j, (x^j)_k^\perp) = (\text{Cor}(x^j, C^k))^2 = (u_j^k)^2 \lambda_k$
 - ⇒ Si $(x^j)^\perp$ est la projection de x^j sur le plan $\langle Z^1, Z^2 \rangle$, alors $(x^j)^\perp$ se trouve à l'intérieur du cercle de corrélation.

Récapitulation

1. Centrer ou Centrer et réduire X , Calculer $V = {}^t X D X$
2. Diagonaliser V : Λ matrice diagonale des valeurs propres, u : matrices des vecteurs propres, ${}^t u u = I_d$
3. Matrice coordonnées des individus dans $\{u^1, \dots, u^d\}$:

$$\mathbf{C} = X \mathbf{u}$$

4. Matrice coordonnées des variables dans $\{Z^1, \dots, Z^d\}$:

$$\mathbf{u} \sqrt{\Lambda}$$

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

Représentation d'une variable quantitatives dans \mathbb{R}^n .

1. \mathbb{R}^n est l'espace des variables
2. $y = {}^t(y_1, \dots, y_n)$ les observations d'une variable quantitative supplémentaire.
La variable y a subi les **mêmes transformations** que x^1, \dots, x^d : y est centrée (réduite) si x^1, \dots, x^d sont centrées (réduites).
3. On représente $(y^k)^\perp$ la projection orthogonale de y sur un k -ième axe unitaire $\langle Z^k \rangle$

$$(y^k)^\perp = {}^t(y)DZ^k \cdot Z^k = \frac{1}{\sqrt{\lambda_k}} {}^t(y)DZ^k \cdot C^k$$

4. Comme $C^k = \sum_{j=1}^d u_j^k x^j$, $\Rightarrow (y^k)^\perp = \sum_{j=1}^d \frac{{}^t(y)DZ^k}{\sqrt{\lambda_k}} u_j^k \cdot x^j$.

Coefficient de corrélation partiel

- Le coefficient de corrélation partiel fourni par $(y^k)^\perp$ entre y et x^1, \dots, x^d est le coefficient de corrélation entre y et $(y^k)^\perp$

$$R_{y|x^1, \dots, x^d}^k = \text{Cor}(y, (y^k)^\perp) = \frac{\langle y, (y^k)^\perp \rangle}{\|y\| \| (y^k)^\perp \|} = \frac{\| (y^k)^\perp \|}{\|y\|}$$

Comme $\|y\|^2 = \| (y^k)^\perp \|^2 + \|y - (y^k)^\perp\|^2$ (**Pythagore**).

Alors

$$\left(R_{y|x^1, \dots, x^d}^k\right)^2 = 1 - \frac{\|y - (y^k)^\perp\|^2}{\|y\|^2}$$

mesure la *part* de $(y^k)^\perp$ dans l'explication de y .

- Si **ACP-normée** alors $(R_{y|x^1, \dots, x^d}^k)^2 = \| (y^k)^\perp \|$ et
- $\sum_{k=1}^d (R_{y|x^1, \dots, x^d}^k)^2$ mesure le coefficient de corrélation partiel fourni par les composantes principales entre y et x^1, \dots, x^d

Représentation d'une variable qualitative dans \mathbb{R}^d .

1. \mathbb{R}^d l'espace des individus.
2. A est la variables qualitative à r modalités $\{A_1, \dots, A_r\}$. On peut définir r sous-groupes d'individus E_1, \dots, E_r où

$$E_I = \{w_i \in E, A(w_i) = a_I\}$$

3. On définit g_1, \dots, g_r les centres de gravité resp. de E_1, \dots, E_r : $\forall I = 1, \dots, r$, g_I a pour coordonnées dans \mathbb{R}^d , $x_I = {}^t(x_I^1, \dots, x_I^d)$ où

$$x_I^j = \sum_{w_i \in E_I} p_i x_i^j$$

4. On représente $(g_I)_k^\perp$ la projection orthogonale de g_I sur le k -ième axe principal $\langle u^k \rangle$,

$$(g_I)_k^\perp = ({}^t g_I u^k) \cdot u^k$$

Représentation d'une variable qualitative dans \mathbb{R}^d .

- ▶ Décomposition de la variance :

$$\text{Variance Totale} = \text{Variance intra-classes} + \text{Variance inter-classes}$$

- ▶ Appliquée à notre échantillon E

$$\sum_{i=1}^r p_i d(0, w_i)^2 = \sum_{l=1}^r q_l \sum_{w_i \in E_l} \frac{p_i}{q_l} d(w_i, g_l)^2 + \sum_{l=1}^r q_l d(0, g_l)^2$$

où $q_l = \sum_{w_i \in E_l} p_i$.

- ▶ Pouvoir de séparation de la k -ième composante est

$$\Lambda_k = \frac{1}{\lambda_k} \sum_{l=1}^r q_l d(0, (g_l)_k^\perp)^2$$

Λ_k est le rapport entre la variance totale de E^k la projection de E sur $\langle u^k \rangle$ et la variance inter-classe de E^k , $\Lambda_k \in [0, 1]$.

Individus supplémentaires

- ▶ w_s un individu supplémentaire qu'on a envie de le représenter sur un k -ième axe principal $\langle u^k \rangle$.
- ▶ $\forall j = 1 \dots d$, $x_s^j = x^j(w_s)$. Donc w_s a pour coordonnées dans \mathbb{R}^d : $x_s = {}^t(x_s^1, \dots, x_s^d)$.
- ▶ D'abord, il faut faire subir à x_s les mêmes transformations que les x_i :

centrer $x_s^j - \bar{x}^j$ ou centre et réduire $\frac{x_s^j - \bar{x}^j}{\sigma^j}$

où \bar{x}^j et σ^j sont resp. la moyenne et l'écart-type de la variable x^j (**sans l'observation x_s**).

- ▶ La représentation de w_s sur $\langle u^k \rangle$ se fait par projection orthogonale :

$$(x_s)^\perp = ({}^t x_s u^k) \cdot u^k.$$

Exemple de données

Le logiciel R

La construction d'une ACP

Représentations Graphiques

Représentation des individus

Représentation des variables

Représentation des variables supplémentaires

La mise en œuvre d'une ACP

Les données decathlon

- ▶ Importation des données à partir du package
 - > library(FactoMineR)
 - > data(decathlon)

- ▶ Utilisation du package FactoMineR
 - > res.pca <- PCA(decathlon,
 - + quanti.sup=11:12,quali.sup=13)

- ▶ 11 et 12 étant les numéros des colonnes des variables “rang” et “score obtenues” : variables traitées comme des variables quantitatives supplémentaires.

- ▶ 13 est le numéro de la variable “compétition” : variable qualitative supplémentaire.

Sortie PCA de FacoMineR

```
> res.pca
**Results for the Principal Component Analysis (PCA)**
name description
1  "$eig" "eigenvalues"
2  "$var" "results for the variables"
3  "$var$coord" "coordinates of the variables"
4  "$var$cor" "correlations variables - dimensions"
5  "$var$cos2" "cos2 for the variables"
6  "$var$contrib" "contributions of the variables"
7  "$ind" "results for the individuals"
8  "$ind$coord" "coord. for the individuals"
9  "$ind$cos2" "cos2 for the individuals"
10 "$ind$contrib" "contributions of the individuals"
11 "$quanti.sup" "results for the supplementary quantitative variables"
12 "$quanti.sup$coord" "coord. of the supplementary quantitative variables"
13 "$quanti.sup$cor" "correlations suppl. quanti. variables - dimensions"
14 "$quali.sup" "results for the supplementary categorical variables"
15 "$quali.sup$coord" "coord. of the supplementary categories"
16 "$quali.sup$vtest" "v-test of the supplementary categories"
17 "$call" "summary statistics"
18 "$call$centre" "mean for the variables"
19 "$call$ecart.type" "standard error for the variables"
20 "$call$row.w" "weights for the individuals"
21 "$call$col.w" "weights for the variables"
```


Choix du nombre des axes

- ▶ On examine la part de variance de chaque axe :

```
> round(res.pca$eig,3)
      eigenvalue percentage of variance cumulative percentage of variance
comp 1      3.272           32.719                      32.719
comp 2      1.737           17.371                      50.090
comp 3      1.405           14.049                      64.140
comp 4      1.057           10.569                     74.708
comp 5      0.685            6.848                      81.556
comp 6      0.599            5.993                      87.548
comp 7      0.451            4.512                     92.061
comp 8      0.397            3.969                     96.030
comp 9      0.215            2.148                     98.178
comp 10     0.182            1.822                    100.000
```

- ▶ On trace un graphe appelé ébouli des valeurs propres (scree plot) :

```
> barplot(res.pca$eig[,1],main="Eigenvalues",
+         names.arg=paste("dim",1:nrow(res.pca$eig)))
```



Etude du nuage des points

- ▶ Les coordonnées des individus sur les quatre premiers axes principaux :

```
> res.pca$ind$coord[,1:4]
```

- ▶ La qualité de la représentation de chaque individu sur les quatre premiers axes principaux.

```
> res.pca$ind$cos2[,1:4]
```


- ▶ La contribution de chaque individu dans la variance des quatre premiers axes principaux.

```
> res.pca$ind$contrib[,1:4]
```

- ▶ Pour représenter les individus sur les deux premiers axes principaux.

```
> plot(res.pca, choix="ind", axes=1:2)
```

Individuals factor map (PCA)



Etude de la représentation des variables

- ▶ Les coordonnées des variables sur les quatre premiers axes principaux :

```
> res.pca$var$coord[,1:4]
```

- ▶ La qualité de la représentation de chaque variable sur les quatre premières axes principales.


```
> res.pca$ind$cos2[,1:4]
```

- ▶ La contribution de chaque variable dans la variance des quatre premières composantes principales.

```
> res.pca$var$contrib[,1:4]
```

- ▶ Pour représenter les individus sur les deux premières composantes principales.

```
> plot(res.pca, choix="var", axes=1:2)
```



Relation variables ACP

- ▶ Test de corrélation composantes principales et variables actives.

```
> dimdesc(res.pca)
$Dim.1
$Dim.1$quanti
      correlation      p.value
Points        0.9561543 0.000000e+00
Long.jump     0.7418997 2.849886e-08
...
$Dim.2
$Dim.2$quanti
      correlation      p.value
Discus        0.6063134 2.650745e-05
Shot.put      0.5983033 3.603567e-05
```

- ▶ Test des moyennes des coordonnées pour la variable quantitative supplémentaire (Test d'ANOVA).

```
$Dim.1$quali
      R2      p.value
Competition 0.05110487 0.1552515

$Dim.1$category
      Estimate      p.value
OlympicG  0.4393744 0.1552515
Decastar -0.4393744 0.1552515
```

Les données temperature

- ▶ Positionner les 23 capitales selon leurs températures moyennes mensuelles.
- ▶ Les variables sont de même unités : on ne réduit pas les données.
- ▶ Mise en œuvre sous R

```
> library(FactoMineR)
> temperature <- read.table("temperature.csv",
+ header=TRUE,sep=";",dec=".",
+ row.names=1)
> res<-PCA(temperature,scale.unit=F,
+ ind.sup=24:35,quanti.sup=13:16,quali.sup=17)
```

