

I Objectif de l'ADD

- faciliter l'interprétation, la classification des données

3 types de méthode d'ADD :

1. Analyse en composantes principales (ACP)
2. Analyse factorielle des correspondances (AFC)
3. Analyse des composantes multiples (ACM)

• ce sont des méthodes d'analyse factorielle

Démarche :

- Traiter les données initiales afin d'éliminer les biais statistiques (ou effets d'échelle)
- Quantifier la notion d'information
 - utilisation de la variance, la covariance, corrélation
 - introduction de la notion de "distances" entre les points et un point "central".
- Réalisation de changements d'axe permettant de hiérarchiser l'information
- Choix des axes de projection en contrôlant la perte d'information
- Projection et analyse du nuage de points en validant l'analyse par des paramètres numériques

II Types de données

2. 1) Tableaux de données

Ce sont des tableaux à double-entrée

- les lignes du tableau peuvent correspondre aux individus étudiés (ACP) ou aux modalités d'une variable (AFC)
- les colonnes correspondent aux variables (ACP - ACM) ou aux modalités d'une variable (AFC)

- Le tableau contient les modalités des variables (ACP - ACM) ou les effectifs (AFC)

2.2) Variables

- en ACP : variables quantitatives de même importance (à peu près)
- en AFC : 2 variables
- en ACM : x variables

III Calcul matriciel et ADD

3.1) Matrice symétrique

Propriété : Soit M une matrice quelconque. Alors les matrices transposées

$${}^t M \times M \text{ et } M \times {}^t M \text{ sont symétriques} \quad M = \begin{pmatrix} 3 & 4 \\ 1 & 2 \end{pmatrix} \quad {}^t M = \begin{pmatrix} 3 & 1 \\ 4 & 2 \end{pmatrix}$$

3.2) Diagonalisation

Propriété : Toute matrice symétrique est diagonalisable dans \mathbb{R}

3.3) Distance

u et v 2 vecteurs colonnes dans une base orthonormée

$$u = \begin{pmatrix} 1 \\ 2 \end{pmatrix} \quad v = \begin{pmatrix} -3 \\ 4 \end{pmatrix}$$

$$\|u\| = \sqrt{1^2 + 2^2} = \sqrt{{}^t u \times u}$$

$$\begin{aligned} {}^t u \times u &= (1 \ 2) \begin{pmatrix} 1 \\ 2 \end{pmatrix} \\ &= 1^2 + 2^2 \end{aligned}$$

produit scalaire de u et v

$$u \cdot v = 1 \times (-3) + 2 \times 4$$

$${}^t u \times v = (1 \ 2) \begin{pmatrix} -3 \\ 4 \end{pmatrix} = 1 \times (-3) + 2 \times 4$$

IV Approche géométrique à l'ellipsoïde d'inertie

Voir image.

Chapitre II: Paramètres d'un nuage de points (ACP)

Approche statistique

I Paramètres statistiques

- X variable statistique ou aléatoire
- n nbre d'individus
- écart type $\sigma_X = \sqrt{V(X)}$
- $\rho(X, Y) \in [-1, 1]$
- $\text{cov}(X, X) = V(X)$
- $\rho(X, X) = 1$
- corrélation très forte si $\rho(X, Y) \approx 1$
- ———— faible si ———— ≈ 0
- anticorrélation très forte si $\rho(X, Y) \approx -1$

$$\text{Variance: } V(X) = E[(X - \bar{X})^2] = \frac{1}{n} \sum (x - \bar{X})^2$$

$$\text{Moyenne: } \bar{X} = E(X) = \frac{1}{n} \sum x$$

$$\text{Covariance: } \text{cov}(X, Y) = E[(X - \bar{X})(Y - \bar{Y})] \\ = \frac{1}{n} \sum (x - \bar{X})(y - \bar{Y})$$

$$\text{Corrélation: } \rho(X, Y) = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}$$

Variables (vecteurs) centrées: X^c

$$X^c = X - \bar{X} \Rightarrow \bar{X}^c = 0$$

Variables (vecteurs) centrées et réduites: X^s

$$X^s = \frac{X - \bar{X}}{\sigma_X} \Rightarrow \bar{X}^s = 0 \text{ et } V(X^s) = 1$$

II Approche géométrique

A.D.B

m points (m individus)

p variables

variables centrées \Rightarrow centre du nuage de point = origine du repère

2.1) Matrice de variance - covariance

X Matrice des données initiales

$$\dim X = (m, p)$$

X^c Matrice des données centrées

$$\dim X^c = (m, p)$$

$$\Sigma = \frac{1}{m} X^c X^c \quad \text{matrice carrée d'ordre } p$$

symétrique

$$\Sigma = \begin{pmatrix} \text{var}(x_1^c) & \text{cov}(x_1^c, x_2^c) & \text{cov}(x_1^c, x_3^c) \\ \text{cov}(x_2^c, x_1^c) & \text{var}(x_2^c) & \text{cov}(x_2^c, x_3^c) \\ \text{cov}(x_3^c, x_1^c) & \text{cov}(x_3^c, x_2^c) & \text{var}(x_3^c) \end{pmatrix}$$

trace $\Sigma = \text{var}(A) + \text{var}(B) + \text{var}(C)$

trace $\Sigma = \text{var totale}$

2.2) Matrice des corrélations

$$R = \frac{1}{n} {}^t X^s X^s$$

X^s matrice des données centrées réduites $\dim X^s = (n, p)$

$R = \frac{1}{n} {}^t X^s X^s$ matrice carrée d'ordre p symétrique
(p, p) (n, n)

diagonale de 1

termes compris entre -1 et 1

à quoi ça ressemble? go voir campus (ou Martin)

Analyse en composantes principales (ACP)

I Aperçu général

n individus

p variables quantitatives, de même importance

$$X_1, \dots, X_p$$

Si il y a des corrélations entre les variables $X_1, X_2, \dots, X_p \rightarrow$ redondance

idée générale: Transformer les p variables redondantes X_1, X_2, \dots, X_p en p variables appelées facteurs f_1, f_2, \dots, f_p non redondants (non corrélés)

remarque: les redondances sont inscrites dans Σ et R

1.1) La transformation

$$X_1, X_2, \dots, X_p \rightarrow f_1, f_2, \dots, f_p$$

base \rightarrow autre base

Σ ou $R \rightarrow$ matrice diagonale Λ

Il faut diagonaliser Σ ou R

• On obtient une matrice diagonale Λ
(matrice des valeurs propres)

• On obtient une matrice de changements de base U

\rightarrow On détermine les composantes des individus dans la nouvelle base (les facteurs)

$$F = X^T U \text{ ou } X^C U \quad \text{matrice des composantes principales}$$

F matrice de dimension (n, p) , matrice centrée (Σ en colonne = 0)
mais plus réduite

1.2) l'interprétation

Problème: donner un sens aux facteurs principaux
corrélations entre variables et facteurs

\rightarrow matrice des saturations

$$S = \frac{1}{n} {}^t X^S \cdot F$$

Λ matrice des variances des facteurs

$1^{1/2}$ matrice des écarts-types des facteurs

II l'ACP, pas à pas sur un exemple

ACP, Pourquoi?
- variables quantitatives
- variables de "même importance" (eau huile lait)
quel type?

ACP centrée réduite si:

- variables en unités différentes
- les ordres de grandeur sont trop \neq
- les dispersions sont \neq

Matrice centrée: somme colonne = 0

Diagonaliser une matrice A

① déterminer ses valeurs propres

\Rightarrow résoudre équation $\det(A - \lambda I) = 0$

② En déduire la matrice diagonale Δ semblable

trace $\Delta =$ trace A

③ déterminer la base de vecteurs propres

si un vecteur propre associé à λ , alors $AU = \lambda U$

Propriétés des vecteurs propres:

- vecteurs propres orthogonaux
- choix de vecteurs propres unitaires

Matrice des composantes principales

= matrice des coordonnées des individus par rapport aux nouvelles axes.

qualité de représentation d'un individu par

Matrice des saturations

- = matrice des corrélations entre les variables et les facteurs
- = matrice des coordonnées des variables par rapport aux axes (facteurs)


Prop. de la matrice de saturation; cercle de corrélation

$$S = [D_{ij}]_{\substack{1 \leq i \leq p \\ 1 \leq j \leq p}}$$
$$\sum_{j=1}^p D_{ij}^2 = 2 \quad \text{ou? } \Delta[\dots]$$
$$\sum_{i=1}^p$$

En dim 2, $p=2$ $x^2 + y^2 = 1 \rightarrow$ cercle de centre 0 et de rayon 1
— 3, $p=3$ $x^2 + y^2 + z^2 = 1 \rightarrow$ sphère —

$\sum_{j=1}^p D_{ij}^2 = 1 \rightarrow$ les points-variables dans les axes factoriels sont situés sur une hypersphère de centre 0 et de rayon 1.

Cercle de corrélation



• Les projections des variables sont situées à l'intérieur du cercle de corrélation.

• Les variables "intéressantes" d'un point de vue graphique sont celles dont les projections "proches" du cercle

Analyse des notes de 34 élèves de 2^{nde} générale

questions à se poser: Pourquoi une ACP? → ces variables quantitatives, variables "de m^e importance"

Quel type d'ACP?

↳ ACP centrée réduite car: ~~• unités ≠~~ (pas de ce cas)

statistiques élem. ← ~~• ordres de grandeur ≠~~
~~• dispersion ≠~~

→ Interprétation de la matrice de corrélation

→ Sélection des axes et pages.

3 premiers axes
 qge: 68,6%

→ Interprétation de la matrice de données et sa représentation, les plans de corrélation

à partir du cercle:
 - axe 1: Maths, F_n
 Phy

à partir de matrice:
 Maths F_n
 Phy SVT EPS
 axe 2: EPS
 - 3: \approx SES

interprétation des composantes principales

→ sélection des individus : mode de l'axe, en situation extrême, de bonne qualité

axe 1:

- | | |
|------|-----------------|
| i 31 | i 25 |
| i 12 | i 3 |
| i 11 | i 23 |
| i 13 | i 15 |

