

Ministère de l'enseignement supérieur et de la recherche scientifique
Université de JIJEL
Faculté des Sciences Exactes et Informatique
Département d'Informatique




ACP


Analyse en Composantes Principales

Introduction

- Les méthodes factorielles
 - la projection sur un espace de dimension inférieur,
 - Une visualisation de l'ensemble des liaisons entre variables ,
 - Réduire le nombre de variables, tout en minimisant la perte de l'information.



ON VISUALISE



axes principaux

Introduction

- L'ACP (Hotelling, 1933) a pour objectif de réduire le nombre de données, souvent très élevé, d'un tableau de données :
 - Algébriquement: **matrice**,
 - Géométriquement : **nuage de points**.


Introduction

- L'ACP consiste en l'étude des **projections** des **points** de ce **nuage** sur:
 - **un axe, un plan ou un hyperplan**

(Mathématiquement: des sous-espaces vectoriels).


La représentation graphique

- Lorsqu'il n'y a que **deux dimensions** (exemple: largeur et longueur), il est facile de représenter les données sur un plan :



La représentation graphique

- Avec **trois dimensions** (largeur, hauteur et profondeur par ex.), c'est déjà plus difficile :



La représentation graphique

- Mais au delà de **3 dimensions**, il est impossible de représenter les données sur un plan ou même de les visualiser mentalement.

Projeter la réalité sur un plan




Figure de J.P.Fenelon

- Selon le point de vue, l'information retenue ne sera pas la même.
- L'ACP nous propose un point de vue permettant de voir au mieux les individus d'un tableau.

Résumer les données

- Lorsqu'on projette les données sur un plan, on obtient un graphique déformé de la réalité.
- Le rôle de l'ACP est de trouver des espaces de dimensions plus petites minimisant ces déformations.

Données et leurs caractéristiques

- **Tableau des données**

Chaque tableau contient des lignes qui représentent les individus et des colonnes qui représentent les variables.

Ce tableau rectangulaire (**matrice**) qu'on note par X possède des observations à n individus et p variables.

Il a la forme suivante :

Données et leurs caractéristiques

- Tableau des données

$$X = \begin{bmatrix} x_{11} & \dots & x_{1p} \\ \vdots & & \vdots \\ \vdots & x_{ij} & \vdots \\ \vdots & & \vdots \\ x_{n1} & \dots & x_{np} \end{bmatrix} \in M_R(n, p),$$

où **x_{ij}** est la valeur prise par la **variable j** sur l'**individu i**.

Individu=Élément de R^p

Variable = Élément de R^n

Données et leurs caractéristiques

Individus et variables

- **Individu:** Le i ème individu est un vecteur à p composantes réelles qu'on le note par e_i tel que

$$e_i = (x_{i1}, x_{i2}, \dots, x_{ip}) \in \mathbb{R}^p; \text{ pour } i = 1, n$$

Données et leurs caractéristiques

Individus et variables

- **Variable:** La j eme variable est la liste des n valeurs qu'elle prend sur n individus, on la note par x_j tel que:

$$x_j = (x_{1j}, x_{2j}, \dots, x_{nj})^t \in \mathbb{R}^n; \text{ pour } j = 1, p:$$


Données et leurs caractéristiques

- L'A.C.P: permet d'explorer les liaisons entre variables et les ressemblances entre individus.
- **Résultats:**
 - **Visualisation des individus** (Notion de distances entre individus)
 - **Visualisation des variables** (en fonction de leurs corrélations)


Deux nuages de points

- Le tableau peut être vu comme un ensemble de lignes ou un ensemble de colonnes.

Etude des individus




Etude des variables



Nuage des individus

- A chaque individu noté e_i , on peut associer un point dans R_p = espace des individus.
- A chaque variable du tableau X est associé un axe de R_p .



Principe de l'ACP

- On cherche une représentation des n individus, dans un sous-espace F_k de \mathbb{R}^p de dimension k (k petit 2, 3) ($k < p$)
- Autrement dit, on cherche à définir **k nouvelles variables combinaisons linéaires des p variables initiales** qui feront perdre le **moins d'information** possible.

Principe de l'ACP

- Ces variables seront appelées «*composantes principales* »
- les axes qu'elles déterminent : « *axes principaux* »
- les formes linéaires associées : « *facteurs principaux* »

Perdre le moins d'information possible:

1

F_k devra être « **ajusté** » le mieux possible au nuage des individus: la somme des carrés des **distances** des individus à F_k doit être **minimale**




2

F_k est le sous-espace tel que le nuage **projété** ait une inertie (dispersion) **maximale**.

(1) et (2) sont basées sur les notions de:

- **Distance**

- **Projection orthogonale**




La distance entre f_i et f_j est inférieure ou égale à celle entre e_i et e_j

LE CHOIX DE LA DISTANCE ENTRE INDIVIDUS

- Dans le plan:

$$d^2 (A, B) = (x_B - x_A)^2 + (y_B - y_A)^2$$



LE CHOIX DE LA DISTANCE ENTRE INDIVIDUS

- Dans l'espace R^p à p dimensions, **on généralise cette notion** : la distance euclidienne entre deux individus s'écrit:

$$e_i = (x_i^1 \ x_i^2 \ \dots \ x_i^p) \quad e_j = (x_j^1 \ x_j^2 \ \dots \ x_j^p)$$
$$d^2 (e_i, e_j) = (x_i^1 - x_j^1)^2 + (x_i^2 - x_j^2)^2 + \dots (x_i^p - x_j^p)^2$$

$$d^2 (e_i, e_j) = \sum_{k=1}^p (x_i^k - x_j^k)^2$$

Inertie totale du nuage de points

- On appelle **inertie** la quantité d'information contenue dans un tableau de données.
- Une **inertie nulle** signifie que tous les individus sont presque identiques.
- Si les j variables sont centrés-réduits, l'**inertie** sera égale à j .

Inertie totale du nuage de points

- On note l'inertie totale du nuage de *points*
lg=mesure de dispersion des points au sein du nuage = somme pondérée des carrés des distances par rapport au centre de gravité *G du nuage*


$$I_g = \sum_{i=1}^n \frac{1}{n} d^2 (e_i, g)$$

ou de façon plus générale

$$I_g = \sum_{i=1}^n p_i d^2 (e_i, g)$$

avec $\sum_{i=1}^n p_i = 1$

Équivalence des deux critères concernant la perte d'information



Soit F un sous-ensemble de \mathbb{R}^p

f_i la projection orthogonale de e_i sur F

$$\|e_i - g\|^2 = \|e_i - f_i\|^2 + \|f_i - g\|^2 \quad \forall i = 1 \dots n$$

Équivalence des deux critères concernant la perte d'information

On va chercher F tel que :

$$\sum_{i=1}^n p_i \|e_i - f_i\|^2 \text{ soit minimal}$$

ce qui revient d'après le théorème de Pythagore à maximiser :

$$\sum_{i=1}^n p_i \|f_i - g\|^2$$

Équivalence des deux critères concernant la perte d'information

$$\|e_i - g\|^2 = \|e_i - f_i\|^2 + \|f_i - g\|^2 \quad \forall i = 1 \dots n$$

Donc : $\sum_{i=1}^n p_i \|e_i - g\|^2 - \sum_{i=1}^n p_i \|e_i - f_i\|^2 = \sum_{i=1}^n p_i \|f_i - g\|^2$

Inertie totale

minimiser cette quantité (carrés des distances entre points individus et leurs projections)




maximiser l'inertie du nuage projeté

Les étapes pour déterminer la composante principale :

- **Centrage et réduction des données**
- **Déterminer les valeurs propres et les vecteurs propres sur la base de la matrice de corrélation entre les variables**
- **Déterminer les axes factoriels**
- **Sélectionner les composantes principales**

Centrage des données

- Le centrage est réalisé de façon **systématique** en ACP
- Translation du centre de gravité du nuage sur l'origine



- Centrer les données ne modifie pas la forme du nuage
⇒ toujours centrer

Réduction des données

Exemple:

Echantillon1

Poids (g)	Diamètre (mm)
100	70
95	65
6.25	6.25

Echantillon2

Poids (g)	Diamètre (cm)
100	7
95	6,5
6.25	0.0065

Dans le premier cas, quand on va chercher le premier axe principale d'inertie, les variables poids et diamètre influencent de manière égale le calcul de l'axe (elles ont toutes deux une variance de 6.25)

Réduction des données

Exemple:

Mais dans le second cas, la variable poids « **pèsera beaucoup plus lourd** » que la variable diamètre dans le calcul, car 6.25 est bien plus grand que 0.0065.

C'est problématique, car le premier et le second cas représentent exactement les mêmes pommes

→ Réduire les données

Réduction des données

- Plus la variable a un **écart-type élevé, plus elle apporte de l'inertie en projection et plus elle «attire les axes».**
- Or, l'écart type dépend directement de l'unité de mesure...
- Pour éviter d'accorder une plus grande importance aux variables exprimées arbitrairement avec de plus grandes valeurs, **on réduit les variables**

Réduction des données

- Transformer nos variables de telle manière que leur **moyenne soit égale à 0 (centrage)** et que leur **variance soit égale à 1 (la réduction)**
- Après avoir centré les données, si on les divise par leur écart type, alors on obtient des valeurs dont **la variance vaut 1**

Réduction des données

- Lorsque les variables sont exprimées dans des unités de mesure différentes, → réduction systématique des données.
- En cas d'unités de mesure identiques ?
- Réduction : consiste à accorder une même importance à chaque variable
- Non réduction : accorde plus d'importance aux variables de forte dispersion

Centrage et réduction des données

- Matrice Centrée Réduite est obtenue par la formule suivante :

$$x_{ij} = \frac{x_{ij} - \bar{X}}{\sigma_i}$$


- La **moyenne** est un outil de calcul permet de résumer une liste de valeurs numériques en un seul nombre réel sans tenir compte de l'ordre de la liste.

$$\bar{X} = \frac{1}{n} \sum x_i$$

Centrage et réduction des données

- On appelle le point moyen ou centre de gravité le vecteur G des moyennes arithmétiques de chaque variable:

$$G = (\bar{x}_1, \bar{x}_2, \bar{x}_3, \dots, \bar{x}_q)$$



- Lorsqu'on analyse des variables centrées, ce point moyen G sera le centre du repère considéré:

$$G \equiv O$$

Centrage et réduction des données

- L'**écart type** est un outil de calcul permet de mesurer la **dispersion des valeurs** d'un **échantillon**. C'est la racine carrée de la variance :

$$\sigma = \sqrt{\text{variance}}$$

- Avec la variance est la moyenne des carrées des écarts à la moyenne :

$$V = \frac{1}{n} \sum (x_i - \bar{X})^2$$

x_i : les valeurs de la variable

\bar{X} : la moyenne de la variable

Centrage et réduction des données

- Réduire ou normer donne la même dispersion, une même importance, à chaque variable (dans l'espace, elles ont même longueur:1)

→On dit que l'on réalise une **ACP normée**

- Ne pas réduire ou ne pas normer laisse à chaque variable son écart-type initial ce qui conduit à accorder à chaque variable une importance proportionnelle à son écart-type.

→On dit que l'on réalise une **ACP non normée (simple)**

Recherche des axes factoriels

- La recherche d'axes portant **le maximum d'inertie** équivaut à la construction de nouvelles variables (auxquelles sont associés ces axes) **de variance maximale**.

Recherche des axes factoriels

- En d'autres termes, on effectue un changement de repère dans R_p de façon à se placer dans un nouveau système de représentation où le premier axe apporte le plus possible de l'inertie totale du nuage, le deuxième axe le plus possible de l'inertie non prise en compte par le premier axe, et ainsi de suite.

Recherche des axes factoriels

- Cette réorganisation s'appuie sur la **diagonalisation de la matrice de variances-covariances (matrice de corrélations pour des données centrées-réduites)**.
- Les **axes principaux** sont ceux maximisant la **variance projetée**: ce sont les **vecteurs propres normés** associés aux plus **grandes valeurs propres** de la matrice de **covariance/corrélation**.

Recherche des axes factoriels

- les **vecteurs propres normés à 1** (axes de direction ou axes factoriels)
- les **valeurs propres** (inerties associées aux axes)

Recherche des axes factoriels

- Le premier axe est celui associé à la plus grande valeur propre . On le note u_1
- Le deuxième axe est celui associé à la deuxième valeur propre . On le note u_2
- ...

Matrice des variances covariances

- La Matrice des variances covariances permet de mesure la liaison linéaire qui peut exister entre un couple de variables statistiques

Var X1	Cov(X1,X2)	Cov(X1,X3)
Cov(X2,X1)	Var X2	Cov(X2,X3)
Cov(X3,X1)	Cov(X3,X2)	Var X3

- Si $\text{Cov}(X2,X1) = 0 \rightarrow$ les variables X1 et X2 sont indépendantes
- Si $\text{Cov}(X2,X1) \neq 0 \rightarrow$ les variables X1 et X2 sont dépendantes (existe une relation linéaire entre les variables)

Matrice des variances covariances

- Obtenue par la formule suivante :

$$V = 1/n * {}^t Mc * Mc$$

- Mc : Matrice centrée
- ${}^t Mc$: Matrice centrée transposée

Matrice des corrélations

- Matrice des corrélations entre variables permet d'analyser les relations bilatérales entre les variables :
- Obtenu par la formule suivante :

$$\Gamma = 1/n * {}^t \mathbf{Mcr} * \mathbf{Mcr}$$

\mathbf{Mcr} : Matrice centrée réduite

${}^t \mathbf{Mcr}$: Matrice centrée réduite transposée

Calculer les valeurs propres

- Déterminer le polynôme caractéristique :

Det $|X - \lambda I|$

- Calculer les **valeurs propres** λ
- Déterminer **les vecteurs propres** orthogonaux associés aux valeurs propres

Caractères des composantes principales

- Il n'y a pas de redondance d'information entre **deux composantes principales**.
- Les composantes principales sont **centrées**.
- La **variance** d'une **composante principale** est **égale** à l'**inertie** portée par l'**axe principal** qui lui est associé.

Caractères des composantes principales

- Soit u_1 est le vecteur propre associé à la première grande valeur propre λ_1 . Soit donc Δ_{u_1} ce premier axe principal.
- Si on veut chercher un deuxième axe Δ_{u_2} , où u_2 est son vecteur unitaire orthogonal à u_1 (c-à-d $\langle u_1, u_2 \rangle = 0$)

Caractères des composantes principales

- C-à-d le vecteur unitaire u_2 de la droite Δ_{u_2} est le vecteur propre associé à la deuxième plus grande valeur propre λ_2 , il est orthogonal à u_1 .
- Ainsi de suite on cherche le troisième axe et jusqu'au q ième axe, $q < p$

Choix du nombre de facteur à retenir

Le critère qui permet de choisir le nombre d'axes principaux à retenir utilisé est celui de pourcentage inertie totale expliquée:

Caractères des composantes principales

- Soient $\Delta_{u1} \Delta_{u2} \dots \Delta_{uq}$ les q premiers axes principaux de vecteurs unitaires $u1, u2, \dots, uq$.
- On appelle pourcentage d'inertie expliquée par l'axe Δ_{uj} la quantité suivante définie par :

$$\frac{\lambda_j}{I_N(O)} = \frac{\lambda_j}{\text{Tr}(V)} \quad j=1..q$$

Représentation des individus

- L'inertie est donc aussi égale à la somme des variances des variables étudiées.

$$I_g = \sum_{i=1}^p s_i^2$$

$$I_g = \text{Tr}(\mathbf{V})$$

- **Remarque:** dans le cas où les variables sont centrées réduites, la variance de chaque variable vaut 1.
- **L'inertie totale est alors égale à p (nombre de variables).**

Représentation des individus

- Supposons que nous avons retenu q axes principaux, $q \leq p$. Alors on doit effectuer la projection des individus $x_i \in \mathbb{R}^p$ dans l-hyper plan H formés par les q axes principaux.
- La valeur de la projection de x_i sur l'axe Δ_{ul} notée $c(i,l)$ est donnée par

$$c(i,l) = x_i * u_l$$

Représentation des individus

- La **jème** composante principale fournit les coordonnées des n individus sur le **jème axe principal**.

$$\underline{c}^j = \begin{pmatrix} c_1^j \\ c_2^j \\ \vdots \\ c_n^j \end{pmatrix}$$

- Si on désire une **représentation plane** des **individus**, la meilleure sera celle réalisée grâce aux **deux premières composantes principales**.

Représentation d'individus supplémentaires


- On désire savoir où placer sur un graphique un nouveau individu x_k dont on connaît ses coordonnées dans \mathbb{R}^p

$$x_k = \begin{bmatrix} x_k^1 \\ x_k^2 \\ \vdots \\ x_k^p \end{bmatrix} \in \mathbb{R}^p$$

Pour cela on calcule les coordonnées de x_k dans le système des axes principaux, c-à-d on calcule les valeurs ${}^t x_k a_1, {}^t x_k a_2, \dots, {}^t x_k a_p$ où les a_l sont les facteurs principaux, $l \in \{1, \dots, p\}$, $a_l = \text{Mul}$

Représentation des variables supplémentaires

- Les proximités entre les composantes principales et les variables initiales sont mesurées par les covariances, et sur tout **les corrélations**.
- $R(cj, xi)$ est le **coefficient de corrélation linéaire entre cj et xi**




Cercle des corrélations

Représentation des variables supplémentaires

- Le cercle des corrélations est la projection du nuage des variables sur le plan des composantes principales.

corrélation =cosinus




- Les variables bien représentées sont celles qui sont proches du cercle, celles qui sont proches de l'origine sont mal représentées.

La qualité de la représentation des individus

Pour avoir une idée sur la qualité de la représentation de chacun de n individus dans le sous espace constitué par les axes principaux, on calcul les \cos^2 des angles compris entre l'individu x_i et leurs projections dans les différents sous espaces.

La qualité de la représentation des individus



- Nous dirons qu'un individu est mieux représenté lorsque le **\cos^2** est proche de 1.
(La valeur 1 nous l'obtenons si l'on retenait p axes)