

# Analyse de données

## Analyse par Composantes Principales

Jamal Atif

jamal.atif@dauphine.fr



Université Paris-Dauphine, Licence MIDO




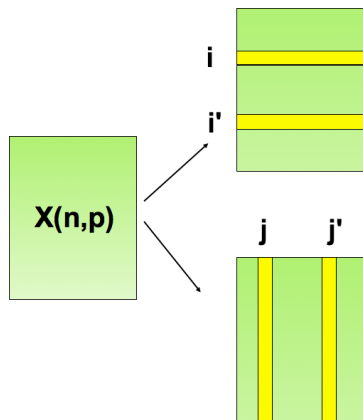
2015-2016

Ce cours est adapté librement des ressources des années précédentes. Remerciements particuliers à PATRICE BERTRAND.



# L'ACP, principe



# Deux espaces de représentation




**ressemblance des individus**



**liaisons entre les variables**

# Critères à optimiser




Nuage en projection le plus étalé possible.




Inertie par rapport au point  $G$  du nuage projeté maximum.

# Données : nuages de points



Chaque individu  $i$  est muni d'un poids  $p_i$

$$\forall i, p_i > 0 \text{ et } \sum_{i=1}^n p_i = 1.$$



## Exemple

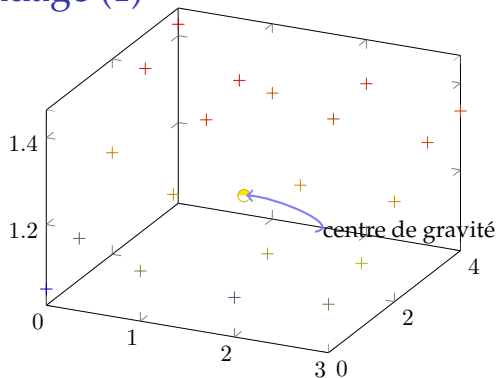

Tableau : notes de 9 élèves (Jean, Aline, Annie, Monique, Didier, André, Pierre, Brigitte, Evelyne) dans 5 matières (Math., Sciences, Français, Latin, Dessin-Musique)

	M	S	F	L	DM
JE	6	6	5	5,5	8
AN	8	8	8	8	9
AN	6	7	11	9,5	11
MO	14,5	14,5	15,5	15	8
DI	14	14	12	12,5	10
AD	11	10	5,5	7	13
PI	5,5	7	14	11,5	10
BR	13	12,5	8,5	9,5	12
EV	9	9,5	12,5	12	18

$$\text{Jean} \mapsto x_1 = \begin{pmatrix} 6 \\ 6 \\ 5 \\ 5,5 \\ 8 \end{pmatrix} \text{ ici}$$

$$\text{Math} \mapsto x_1 = \begin{pmatrix} 6 \\ 8 \\ \vdots \\ 9,5 \end{pmatrix}$$

# Caractéristiques d'un nuage (1)




$$\mathcal{N} = \mathcal{N}_I = \{x_i \mid i = 1, \dots, n\}, p_i \geq 0, \sum_i p_i = 1$$

Centre de gravité

$$g = \sum_{i=1}^n p_i x_i = \begin{pmatrix} \sum_i p_i x_i^1 \\ \vdots \\ \sum_i p_i x_i^p \end{pmatrix} = \begin{pmatrix} \bar{x}^1 \\ \vdots \\ \bar{x}^p \end{pmatrix}$$



## Caractéristiques d'un nuage (2)



## Exemple (2)

$$g = \frac{1}{9} \begin{pmatrix} 6 \\ 6 \\ 5 \\ 5,5 \\ 8 \end{pmatrix} + \frac{1}{9} \begin{pmatrix} 8 \\ 8 \\ 8 \\ 8 \\ 9 \end{pmatrix} + \dots + \frac{1}{9} \begin{pmatrix} 9 \\ 9,5 \\ 12,5 \\ 12 \\ 18 \end{pmatrix}$$

$$g = \begin{pmatrix} 9,67 \\ 9,83 \\ 10,2 \\ 10,1 \\ 11,0 \end{pmatrix} = \begin{pmatrix} g^1 \\ g^2 \\ g^3 \\ g^4 \\ g^5 \end{pmatrix}$$

$g$  correspondant à l'“élève moyen”.

# Métrie

$$d^2(x_1, x_2) = (x_1^1 - x_2^1)^2 + (x_1^2 - x_2^2)^2 + \dots$$

physique : dimensions de même nature

$$d^2(x_1, x_2) = a_1(x_1^1 - x_2^1)^2 + a_2(x_1^2 - x_2^2)^2 + \dots$$

statistique : donner à chaque attribut une importance différente.

$$d^2(x_1, x_2) = (x_1 - x_2)^t M (x_1 - x_2)$$

$$= \sum_{i=1}^p \sum_{j=1}^p m_{ij} (x_1^i - x_2^i) (x_1^j - x_2^j)$$

$$= \|x_1 - x_2\|_M^2$$

où  $M$  est symétrique, définie positive (cas d'axes obliques, i.e. non perpendiculaires).


En pratique :

$$M = I, \quad M = D_{1/s^2} = \begin{pmatrix} 1/s_1^2 & 0 & \dots & 0 \\ 0 & 1/s_2^2 & \dots & 0 \\ \vdots & \dots & \ddots & \vdots \\ 0 & 0 & \dots & 1/s_p^2 \end{pmatrix}$$

## Formulation du critère

On recherche l'espace vectoriel  $V$  de  $\mathbb{R}^p$  de faible dimension tel que par projection, le nuage  $\mathcal{N}_I$  soit le moins déformé possible.

Définition intuitive des différents types d'axes



## Déformation par projection

- ▶  $P_V$  : projecteur orthogonal sur  $V$ . On note  $P_V(x_i) = \tilde{x}_i$
- ▶ Déformation par projection orthogonale sur  $V$

$$D_V = \sum_{i \neq j} p_i p_j [d^2(x_i, x_j) - d^2(\tilde{x}_i - \tilde{x}_j)]$$

⇕

$$D_V = \sum_i p_i (d^2(x_i, g) - d^2(\tilde{x}_i, \tilde{g}))$$

- ▶ Sous-espace principal de dimension  $k$ ,  $V_k$  : sous-espace de  $\mathbb{R}^p$  de dimension  $k$  qui rend la déformation  $D_V$  minimum
- ▶ (Premier) axe principal : sous-espace principal de dimension 1
- ▶ Plan principal : sous-espace principal de dimension 2

# Formulation du critère à l'aide de l'inertie

## Propriété

$$D_V = I_g(\mathcal{N}_I) - I_{\tilde{g}}(\widetilde{\mathcal{N}}_I)$$

où  $I_g(\mathcal{N}_I) = \sum_i p_i d^2(x_i, g)$  est l'inertie du nuage  $\mathcal{N}_I$  par rapport à  $g$  et  $I_{\tilde{g}}(\widetilde{\mathcal{N}}_I)$  et l'inertie du nuage projeté par rapport au projeté de  $g$ .

## Preuve

Nous avons

$$D_V = \sum_i p_i (d^2(x_i, g) - d^2(\tilde{x}_i, \tilde{g}))$$

Remarquons que :  $\sum_i p_i (\tilde{x}_i - \tilde{g}) = \sum_i p_i (\widetilde{x_i - g}) = \sum_i p_i (\widetilde{x_i} - g) = \tilde{0} = 0$ . Donc  $\tilde{g}$  est le barycentre de  $\widetilde{\mathcal{N}}_I$ .

D'où :

$$I_{\tilde{g}}(\widetilde{\mathcal{N}}_I) = \sum_i p_i d^2(\tilde{x}_i, \tilde{g})$$

Donc :

$$I_g(\mathcal{N}_I) = I_{\tilde{g}}(\widetilde{\mathcal{N}}_I) + D_V$$

# Nuage centré

- ▶ L'expression de  $D_V$  ne dépend que des vecteurs  $x_i - g$
- ▶ On note  $y_i = x_i - g$
- ▶ Nuage centré associé à  $\mathcal{N}_I : \{(y_i, p_i) \mid i = 1, \dots, n\}$
- ▶ Les expressions de  $I(\mathcal{N}_I)$  et  $I(\widetilde{\mathcal{N}}_I)$  ne changent pas si l'on centre le nuage
- ▶ Par la suite on considère uniquement le nuage centré

# Décomposition de l'inertie

## Propriété

Si  $V$  est un s.e.v. de  $\mathbb{R}^p$  qui est somme directe de  $V_1$  et  $V_2$ , alors :

$$I(\widetilde{\mathcal{N}}_I^V) = I(\widetilde{\mathcal{N}}_I^{V_1}) + I(\widetilde{\mathcal{N}}_I^{V_2})$$

## Deux conséquences

- ▶  $I(\mathcal{N}_I) = I(\widetilde{\mathcal{N}}_I^V) + I(\widetilde{\mathcal{N}}_I^{V^\perp})$
- ▶ Si  $\{u_1, \dots, u_k\}$  est une base orthogonale de  $V$ , alors :

$$I(\widetilde{\mathcal{N}}_I^V) = I(\widetilde{\mathcal{N}}_I^{u_1}) + \dots + I(\widetilde{\mathcal{N}}_I^{u_k})$$



# Recherche des sous-ensembles principaux

- ▶ Problème  $\mathcal{P}_k$  : déterminer un sous-espace principal  $V_k$  de dimension  $k$
- ▶ Propriété : si  $k$  et  $l$  sont des entiers tels que  $0 < k < k + l \leq p$  et si  $V_k$  est solution de  $\mathcal{P}_k$ , alors il existe une solution  $V_{k+l}$  de  $\mathcal{P}_{k+l}$  qui contient  $V_k$ .
- ▶ Conséquences :
  1. On peut choisir les sous-espaces principaux de telle sorte qu'ils soient emboîtés.
  2. Si  $V_{k-1}$  est solution de  $\mathcal{P}_{k-1}$ , on peut chercher  $V$  solution de  $\mathcal{P}$  de la forme :

$$V = V_{k-1} \oplus \Delta u$$
$$I(\tilde{\mathcal{N}}^V) = I(\tilde{\mathcal{N}}_{k-1}^V) + I(\tilde{\mathcal{N}}^{\Delta u})$$

3. Le plan principal contient l'axe principal

# Inertie du nuage le long d'une droite

$$I(\tilde{\mathcal{N}}^u) = \sum_i p_i \|\tilde{y}_i^u\|^2 \text{ avec } \tilde{y}_i^u = \frac{\langle y_i, u \rangle}{\|u\|^2} u$$

Donc :

$$I(\tilde{\mathcal{N}}^u) = \sum_i p_i \frac{\langle y_i, u \rangle^2}{\|u\|^2}$$

Or  $\langle y_i, u \rangle = y_i^t M u = u^t M y_i$ , et on considère

$$\|u\|_M = 1$$

$\implies$

$$I(\tilde{\mathcal{N}}^u) = \sum_i p_i (u^t M y_i) (y_i^t M u)$$

$$= \sum_i p_i (u^t M) y_i y_i^t (M u)$$

$$= (u^t M) \underbrace{\left( \sum_i p_i y_i y_i^t \right)}_{\Sigma} (M u)$$

$$= (u^t M) \Sigma (M u)$$

$$\Sigma_{j,k} = \sum_i p_i y_i^j y_i^k$$

$$= \sum_i p_i (x_i^j - \bar{x}^j) (x_i^k - \bar{x}^k)$$

$$= \text{cov}(x^j, x^k)$$

## Exemple (4)

$$\Sigma = \begin{pmatrix} 11,4 & 9,92 & 2,66 & 4,82 & 0,111 \\ & 8,94 & 4,12 & 5,48 & 0,056 \\ & & 12,1 & 9,29 & 0,389 \\ & & & 7,91 & 0,667 \\ & & & & 8,67 \end{pmatrix}$$

$$\text{Si } v_1 = \begin{pmatrix} 0,515 \\ 0,507 \\ 0,492 \\ 0,485 \\ 0,030 \end{pmatrix} \text{ et } M = Id, \text{ alors}$$

$$I(\tilde{\mathcal{N}}^{v_1}) = v_1^t \Sigma v_1 = 28,5$$

# Écriture matricielle

$$\Sigma = \sum_i p_i y_i y_i^t = Y^t D_p Y, \text{ avec } D_p = \text{diag}(p_i) = \begin{pmatrix} p_1 & & \mathbf{0} \\ & \ddots & \\ \mathbf{0} & & p_n \end{pmatrix}$$

$$\begin{aligned} I(\mathcal{N}_I) &= \sum_i p_i \|y_i\|_M^2 \\ &= \sum_i p_i y_i^t M y_i \\ &= \text{trace} \left( \sum_i p_i y_i^t M y_i \right) \text{ puisque } \text{trace}(a) = a \\ &= \sum_i p_i \text{trace} (y_i^t M y_i) \text{ puisque } \text{trace}(\sum a X_i) = a \sum \text{trace}(X_i) \\ &= \sum_i p_i \text{trace} (y_i y_i^t M) \text{ puisque } \text{trace}(XY) = \text{trace}(YX) \\ &= \text{trace} \left( \sum_i p_i y_i y_i^t M \right) \\ &= \text{trace}(\Sigma M) \end{aligned}$$

# Écriture matricielle

$$I(\mathcal{N}_I) = \text{trace}(\Sigma M)$$

D'où :

$$\text{trace}(\Sigma M) = u^t M V M u + I(\widetilde{\mathcal{N}}_I^{u^\perp})$$

$\widetilde{\mathcal{N}}_I^{u^\perp}$  s'interprète comme l'inertie par rapport à  $\Delta u$ . On note  $I_{\Delta u}(\mathcal{N}_I) = I(\widetilde{\mathcal{N}}_I^{u^\perp})$ .

$$\underbrace{I_{\Delta u}(\mathcal{N}_I)}_{\text{"déformation } D_V"} = \underbrace{\text{trace}(\Sigma M)}_{I_T: \text{ inertie totale}} - u^t M V M u$$

Minimiser  $D_V$  revient à maximiser  $u^t M V M u$ .

# 1er axe factoriel

►  $I_{\Delta u} = \text{trace}(\Sigma M) - u^t M \Sigma M u$

## Problème

$$\hat{u} = \arg \max_u u^t M \Sigma M u$$
$$\text{s.c. } u^t M u = 1$$

## Solution

Ecriture sous forme de lagrangien :

$$L(u) = u^t M \Sigma M u - \lambda(u^t M u - 1)$$

où  $\lambda$  est un multiplicateur de Lagrange.

Le maximum est atteint lorsque la dérivée s'annule

$$\frac{\partial L(u)}{\partial u} = 2M \Sigma M u - 2\lambda M u = 0$$
$$\implies \Sigma M u = \lambda u$$

Le maximum est donc atteint si  $\lambda$  est la plus grande valeur propre de  $VM$ .

## $k^e$ axe factoriel

Pour tout  $k \leq p$

- ▶ Le  $k^e$  axe factoriel est orienté par le vecteur propre normé  $u_k$  de  $\Sigma M$  associé à la  $k^e$  plus grande valeur propre  $\lambda_k$ .
- ▶  $I_{\Delta u_k^\perp} = \lambda_k = I(\widetilde{\mathcal{N}}_I^{\Delta u_k})$
- ▶  $I_T = \sum_{k=1}^p \lambda_k = \text{trace}(\Sigma M)$
- ▶ La projection du nuage sur  $E_k = \Delta u_1 \oplus \dots \oplus \Delta u_k$  est optimale : c'est celle qui donne la meilleure idée du nuage dans un espace de dimension  $k$ .
- ▶ Pourcentage d'inertie expliquée :

$$\tau_k = \frac{\lambda_1 + \dots + \lambda_k}{I_T}$$

## Exemple (3)

Choix utilisateur : ici 3 axes factoriels

	1	2	3
Val P.	28.253	12.075	8.6157
$\tau$	57.7	24.7	17.6
$\tau$ cum.	57.7	82.4	99.94

	$u_1$	$u_2$	$u_3$
M	.515	-.567	-.0514
S	.507	-.372	-.0145
F	.492	.650	.108
L	.485	.323	-.0226
DM	.0306	.113	-.992

TABLE : Vecteurs axiaux factoriels



# Composantes principales

- ▶ L'abscisse de la projection de l'individu  $i$  sur  $\Delta u_k$  est :

$$c_k^i = \langle y_i, u_k \rangle_M = y_i^t M u_k$$

- ▶  $c_k^i$  représente la coordonnée de  $y_i$  sur le  $k^e$  axe factoriel.
- ▶  $c_k$  :  $k^e$  composante principale

$$\begin{array}{l} c_1 = \begin{pmatrix} c_1^1 \\ \vdots \\ c_1^n \end{pmatrix} = Y M u_1 = Y b_1 \in \mathbb{R}^n \\ \vdots \\ c_p = \begin{pmatrix} c_p^1 \\ \vdots \\ c_p^n \end{pmatrix} = Y M u_p = Y b_p \in \mathbb{R}^n \end{array}$$

## Exemple (6)

	$c_1$	$c_2$	$c_3$
JE	-8.7	-1.7	2.5
AL	-3.9	-.7	1.8
AN	-3.2	3.4	.3
MO	9.7	.2	3.3
DI	6.3	-2.1	.9
AD	-2.9	-4.6	-2.6
PI	-1	6.2	1.6
BR	1.9	-4	-1.4
EV	1.7	3.4	-6.6

## Exemple (7)

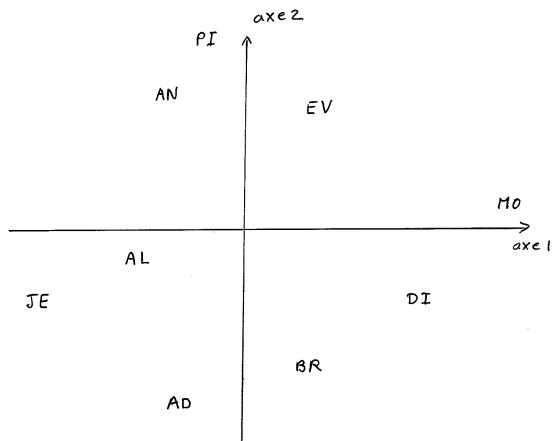


FIGURE : Plan factoriel  $1 \times 2$

## Exemple (8)




FIGURE : Plan factoriel  $1 \times 3$

# Représentation des variables

- ▶ Les  $r$  composantes principales, une fois normées, forment une base  $D_p$ -orthonormée du support du nuage formé par les  $p$  points  $\{x^1, \dots, x^p\} \subset \mathbb{R}^n$  :

$$\left\{ \frac{c_k}{\sqrt{\lambda_k}} \mid k = 1, \dots, n \right\}$$

- ▶ La  $k^e$  coordonnée de la variable  $y^j$  dans cette base est :

$$\begin{aligned} d_j^k &= (y^j)^t D_p \frac{c_k}{\sqrt{\lambda_k}} = \text{cov}(y^j, \frac{c_k}{\sqrt{\lambda_k}}) \\ d^k &= Y^t D_p \frac{c_k}{\sqrt{\lambda_k}} = \underbrace{Y^t D_p Y M}_{\Sigma} u_k / \sqrt{\lambda_k} \\ & \qquad \qquad \qquad \underbrace{\qquad \qquad \qquad}_{\Sigma M u_k = \lambda_k u_k} \\ \implies d^k &= \sqrt{\lambda_k} u_k \end{aligned}$$

## Exemple (9)




FIGURE : Plan principal  $1 \times 2$ , représentation simultanée (axe1 x axe2)

## Exemple (10)




FIGURE : Plan principal 1  $\times$  3, représentation simultanée (axe1 x axe3)

# Aide à l'interprétation

## Représentation des individus

- ▶ Qualité de la représentation par  $E_k$  :

$$\frac{\lambda_1 + \dots + \lambda_k}{I_T}$$

- ▶ Qualité de la représentation de  $x_i$  sur  $\Delta u_k$

$$COR_k(i) = \frac{(c_k^i)^2}{\|y_i\|_M^2} = \cos^2(y_i, u_k)$$

- ▶ Contribution de  $x_i$  à l'inertie de l'axe  $\Delta u_k$

$$CTR_k(i) = \frac{p_i (c_k^i)^2}{\lambda_k}$$

- ▶ Contribution de  $x_i$  à l'inertie totale

$$INR(i) = \frac{p_i \|y_i\|_M^2}{I_T}$$



# Aide à l'interprétation

## Représentation des variables

- ▶ Qualité de la représentation de  $x$  sur  $\Delta(\frac{c_k}{\sqrt{\lambda_k}}$

$$COR_k(j) = \frac{(d_j^k)^2}{\|x^j\|^2} = \cos^2(x^j, c_k) = \rho_{j,k}^2$$

- ▶ Contribution de  $x^j$  à l'inertie de l'axe  $k^e$  axe

$$CTR_k(j) = \frac{m_j(d_j^k)^2}{\lambda_k} = m_j(u_k^j)^2$$

- ▶ Contribution de  $x_i$  à l'inertie totale

$$INR(J) = \frac{m_j\|x^j\|^2}{I_T}$$