

Analyses en composantes principales.

* OBJECTIF:

passer de $X \in \mathbb{R}^{n \times p}$ à $C \in \mathbb{R}^{n \times q}$ avec
 $q < p$

TEL QUE C SOIT AUSSI PROCHÉ
QUE POSSIBLE DE X




Chaque ligne ligne de X, noté α_i
est un vecteur de \mathbb{R}^p qui décrit un individu

EN PRATIQUE, ON MINIMISE

$$J = \sum_{i=1}^n \|\alpha_i - U c_i\|^2 \text{ où } c_i \text{ est}$$

la projection de α_i sur
un s.e.v de base U_1, \dots, U_q
avec $U = [U_1 \dots U_q]$

Exemple dans \mathbb{R}^2




$$X = \begin{bmatrix} \alpha_1^\top \\ \alpha_2^\top \\ \alpha_3^\top \end{bmatrix}$$

$$X = \begin{bmatrix} \alpha_1, \alpha_2 \\ \alpha_2, \alpha_3 \\ \alpha_3, \alpha_1 \end{bmatrix}$$

Considérons le centre de gravité du nuage X

$$\bar{\mu} = \bar{\alpha} = \frac{1}{3} (\alpha_1 + \alpha_2 + \alpha_3)$$



$$N = \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

Notons $\sum_{i=1}^n \|x_i - \bar{x}\|^2$
 inerti

ET CONSIDERONS LA PROJECTION ORTHO.


de $X = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$ sur $E = \text{vect}(u_1, \dots, u_q)$

AVEC $\forall k \quad \|u_k\|^2 = 1$ ①

$\forall m \neq l \quad u_m \perp u_l$ ②

$$U = \begin{bmatrix} u_1 & \dots & u_q \end{bmatrix}$$

$$U^T U = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{pmatrix} = I_p, \text{ identity}$$



$$p(x_i) = U(U^T U)^{-1} U^T x_i$$

$$c_i = U^T x_i$$

$$c_i^T = x_i^T U = \sum_{p=1}^P c_i^p$$

$$\begin{bmatrix} c_1^T \\ c_2^T \\ \vdots \\ c_n^T \end{bmatrix} = C = X U$$


LES DONNÉES X SONT CENTRÉES
ET RÉDUITES


$$X_{ij} \leftarrow \frac{X_{ij} - \bar{X}_j}{\hat{\sigma}_j}$$

AVEC


$$\bar{X}_j = \frac{1}{n} \sum_{i=1}^n X_{ij}$$

$$\hat{\sigma}_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2}$$





DONNÉES LENTRÉES
REDUITES



$$\text{Si } \bar{\alpha} = 0 \text{ ALORS } \|\alpha_i - \bar{\alpha}\|^2 = \|\alpha_i\|^2$$

$$I_T = \sum_{i=1}^n \|\alpha_i - \bar{\alpha}\|_2^2$$

$$= \sum_{i=1}^n \left\| \underbrace{\alpha_i}_{\sum_{j=1}^p \alpha_{ij}^2} \right\|_2^2 = \sum_{i=1}^n \sum_{j=1}^p \alpha_{ij}^2$$

$$= \sum_{i=1}^n \left\| \alpha_i - p(\alpha_i) + p(\alpha_i) \right\|^2$$

$$\sum_i \langle \underbrace{\alpha_i - p(\alpha_i)}_{\star}, \underbrace{p(\alpha_i)}_{\star} \rangle$$


$$= \sum_i \| \alpha_i - p(\alpha_i) \|^2 + \| p(\alpha_i) \|^2 + 2 \underbrace{\langle \alpha_i - p(\alpha_i), p(\alpha_i) \rangle}_{\star}$$

$I_T = I_F + I_E$	0
-------------------	---

NOTRE PROBLÈME:

MINIMISER I_E^{-1} ou

MAXIMISE I_E (DEMANDE)



$$\begin{aligned} I_E &= \sum_{i=1}^n \|p(\alpha_i)\|^2 \\ &= \sum_{i=1}^n \|Uc_i\|^2 \\ &= \sum_{i=1}^n \|UU^\top \alpha_i\|^2 \\ &= \sum_{i=1}^n \langle UU^\top \alpha_i, UU^\top \alpha_i \rangle \\ &= \sum_{i=1}^n \underbrace{\alpha_i^\top UU^\top UU^\top}_{I} \alpha_i \end{aligned}$$

$$= \sum_{i=1}^n \alpha_i^T U U^T \alpha_i$$



$$X = \begin{bmatrix} \alpha_1^T \\ \vdots \\ \alpha_n^T \end{bmatrix} \underset{P}{\overset{n}{\sim}} \xrightarrow{\text{ACP}} C = \begin{bmatrix} c_1^T \\ \vdots \\ c_q^T \end{bmatrix} \underset{q}{\overset{n}{\sim}}$$

$$q < p$$