

Chap 3 : Analyse en composantes principales A.C.P

I / Introduction

En vue d'éliminer la redondance d'information due aux éventuelles liaisons pouvant exister entre les p variables initiales, on se propose de remplacer le tableau X de départ par un tableau Y , où le nombre de variables est plus petit.

$$(X^1, \dots, X^p)_{(n,p)} = X \longrightarrow Y = (Y^1, \dots, Y^q)_{(n,q)} \text{ avec } q < p.$$

Rp : les nouvelles variables sont non corrélées

Généralement, en pratique, les variables initiales ne sont pas toutes de la même grandeur, et comme les nouvelles variables sont des combinaisons linéaires de variables initiales, les variables prenant les petites valeurs seront sans doute négligées devant les variables à grandes valeurs. A.C.P répond à ce problème, en utilisant l'A.F.G. du tableau centré X , et muni chaque individu d'un poids p_i ($\sum_{i=1}^n p_i = 1$)

II / Position du problème

Soit X un tableau contenant n individus et p variables

$$X_{(n,p)} = (x_{ij}^d)_{\substack{1 \leq i \leq n \\ 1 \leq j \leq p}}$$

On note par \tilde{X} le tableau centré, $\tilde{X}_{(n,p)} = (\tilde{x}_{ij}^d)_{\substack{1 \leq i \leq n \\ 1 \leq j \leq p}}$

où $\tilde{x}_{ij}^d = x_{ij}^d - \bar{x}_j^d$

But de l'A.C.P.

L'œil humain ne sachant regarder dans un espace de dimension supérieure à 3, le but de l'A.C.P est de décrire et visualiser le nuage $N(I) = \{ \underline{x}_i / \underline{x}_i \in \mathbb{R}^p \}$ et ce en cherchant un sous-espace vectoriel de dimension q ($q < p$) le plus proche de $N(I)$

Méthode

1) Chercher la droite Δu_1 , le plus proche de $N(I)$ (Δu_1 est un s.e.v. de \mathbb{R}^p de dimension 1, engendré par $\{u_1\}$)

2) Recherche de la droite Δu_2 , orthogonale à Δu_1 , la plus proche de $N(I)$

Proposition: Le plan le plus proche de $N(I)$ est le plan engendré par les vecteurs $\{u_1, u_2\}$.

3) Recherche de la droite Δu_3 , orthogonale à Δu_1 et Δu_2 , la plus proche du nuage.

\vdots
 \Rightarrow Ainsi de suite jusqu'à

q) Recherche de la droite Δu_q , orthogonale à $\Delta u_1, \dots, \Delta u_{q-1}$, la plus proche du nuage.

Déf: Les droites $\Delta u_1, \dots, \Delta u_q$ qui ajustent au mieux le nuage sont dites axes factoriels ou axes principaux.

Proposition: Le s.e.v. de dimension q qui ajuste au mieux les pts du nuage $N(I)$ est le s.e.v. engendré par $\{u_1, \dots, u_q\}$

A.C.P. de tableau $X \Leftrightarrow$ A.F.G. de \tilde{X} ou $\begin{cases} (\mathbb{R}^p, I) \\ (\mathbb{R}^q, D_p) \end{cases}$

$D_p = \begin{pmatrix} p_1 & & 0 \\ & \ddots & \\ 0 & & p_n \end{pmatrix}$ métrique des points.

III/ On se place sur \mathbb{R}^p .

On considère le nuage des n points de \mathbb{R}^p , $N(I) = \{(X_i, p_i)\}_{i=1}^n$.

$N(I)$ nuage des n individus.

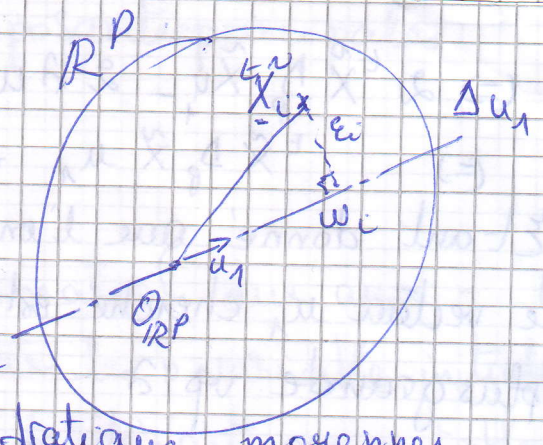
1) Recherche du s.e.v. de dim 1

On note par u_1 le vecteur de la base de ce s.e.v. de dim 1 noté Δu_1 , on suppose que u_1 est normé.

w_i est la projection Δ_p -orthogonale de \tilde{X}_i sur Δ_{u_1}

$$w_i = \langle \tilde{X}_i, u_1 \rangle_{\Delta_p} = \tilde{X}_i \Delta_p u_1$$

E_i erreur due à la projection.



On utilise le critère des M.C qui consiste à minimiser la somme des erreurs quadratique moyennes

Problème d'optimisation.

$$\text{Min}_{\|u_1\|_{\Delta_p}^2 = 1} \sum_{i=1}^n p_i E_i^2$$

$$E_i^2 = \|\tilde{X}_i\|_{\Delta_p}^2 - w_i^2$$

Le pb revient à $\max_{\|u_1\|_{\Delta_p}^2 = 1} \sum_{i=1}^n p_i w_i^2$

$$\Leftrightarrow \max_{\|u_1\|_{\Delta_p}^2 = 1} \|W\|_{\Delta_p}^2 \quad \text{avec } W = \begin{pmatrix} w_1 \\ \vdots \\ w_n \end{pmatrix} \text{ vecteur des } n \text{ projections}$$

$$\text{En effet } \|W\|_{\Delta_p}^2 = {}^t W \Delta_p W = (w_1, \dots, w_n) \begin{pmatrix} p_1 & & 0 \\ & \ddots & \\ 0 & & p_n \end{pmatrix} \begin{pmatrix} w_1 \\ \vdots \\ w_n \end{pmatrix} = (p_1 w_1, \dots, p_n w_n) \begin{pmatrix} w_1 \\ \vdots \\ w_n \end{pmatrix} = \sum_{i=1}^n p_i w_i^2$$

$$\text{Pb } \Leftrightarrow \max_{\|u_1\|_{\Delta_p}^2 = 1} {}^t W \Delta_p W \quad \text{avec } W = \begin{pmatrix} \tilde{X}_1 \Delta_p u_1 \\ \vdots \\ \tilde{X}_n \Delta_p u_1 \end{pmatrix} \Delta_p u_1 = \tilde{X} \Delta_p u_1$$

$$\Leftrightarrow \max_{\|u_1\|_{\Delta_p}^2 = 1} {}^t (\tilde{X} \Delta_p u_1) \Delta_p (\tilde{X} \Delta_p u_1)$$

$$\Leftrightarrow \max_{\|u_1\|_{\Delta_p}^2 = 1} {}^t u_1 \Delta_p \tilde{X} \Delta_p \tilde{X} \Delta_p u_1$$

En définitive, il s'agit de résoudre le problème à 1 contrainte suivant:

$$\begin{cases} \text{Max}_{u_1 \in \mathbb{R}^p} {}^t u_1 \Delta_p \tilde{X} \Delta_p \tilde{X} \Delta_p u_1 \\ {}^t u_1 \cdot u_1 = \|u_1\|_{\Delta_p}^2 = 1 \end{cases} \Leftrightarrow \begin{cases} \text{Max}_{u_1 \in \mathbb{R}^p} {}^t u_1 \tilde{X} \Delta_p \tilde{X} u_1 \\ {}^t u_1 \cdot u_1 = 1 \end{cases}$$

Le pb de multiplicateur de Lagrange donne comme solution

un vecteur u_1 tq

$$\frac{\partial}{\partial u_1} ({}^t u_1 \tilde{X} \Delta_p \tilde{X} u_1 - \lambda ({}^t u_1 \cdot u_1 - 1)) = 0$$

$$\Leftrightarrow \lambda \vec{X} \Delta_p \vec{X} u_1 - \lambda \Delta u_1 = 0$$

$$\Leftrightarrow \vec{X} \Delta_p \vec{X} u_1 = \Delta u_1 \quad u_1 \text{ est alors } \vec{v} \text{ de } \vec{X} \Delta_p \vec{X} \text{ associée à } \lambda$$

Etant donné que l'on cherche à maximiser $\vec{u}_1^T \vec{X} \Delta_p \vec{X} u_1$, le vecteur u_1 cherché est le \vec{v} norme de $\vec{X} \Delta_p \vec{X}$ associée à la plus grande vp λ

Rq. $\vec{X} \Delta_p \vec{X}$ est la matrice de dimension (p, p) des variances-covariance.

2) La recherche du $1^{\text{ère}}$, \dots , $q^{\text{ème}}$ axes principaux

Nous allons généraliser (1)

Soient $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ les p valeurs propres (vp) de V

Soient u_1, \dots, u_p les p vecteurs propres (vp) de V (orthogonaux, associés aux vps $\lambda_1, \dots, \lambda_p$ resp.

1^{er} axe principal est Δu_1

$2^{\text{ème}}$ axe principale est Δu_2

$q^{\text{ème}}$ axe principal est Δu_q

Déf : On appelle pourcentage d'inertie expliquée par l'axe principale Δu_1 la quantité

$$I_1 = \frac{\lambda_1}{\lambda_1 + \dots + \lambda_p}$$

• Plan principal : s.e.f

Le plan principale est le plan le plus proche du nuage NC

$$P = (\Delta u_1, \Delta u_2)$$

Inertie expliquée par le plan $I_{1,2} = \frac{\lambda_1 + \lambda_2}{\lambda_1 + \dots + \lambda_p}$

• Sous espace principal de dim q .

Le s.e.p principal de dimension q , est le s.e.v de \mathbb{R}^p le plus proche du nuage.

$$E_p = (\Delta u_1, \Delta u_2, \dots, \Delta u_q)$$

Le pourcentage d'inertie expliqué par E_p est

$$\frac{\lambda_1 + \dots + \lambda_p}{\lambda_1 + \dots + \lambda_p}$$

Composante principale.

Soient u_1, \dots, u_p les p v.p. normales-orthogonales de V , associées aux p premières v.p. $\lambda_1 \geq \dots \geq \lambda_p$ resp.

La composante $c^l = \tilde{X} u$ est appelée la $l^{\text{ème}}$ composante principale

$$c^l = W^{(l)} \tilde{X} u_l$$

Proposition

- Les composantes principales c^1, \dots, c^p sont centrées
- $\text{Var}(c^l) = \lambda_l$
- $\text{Cov}(c^l, c^{l'}) = 0$

Preuve.

$$\begin{aligned} \bar{c}^l &= \sum_{i=1}^n p_i c_i^l = \sum_{i=1}^n p_i \tilde{X}_i^l u_l = \left(\sum_{i=1}^n p_i \tilde{X}_i^l \right) u_l = \left(\bar{X}_1^l, \dots, \bar{X}_p^l \right) u_l \\ &= (0, \dots, 0) u_l = 0 \end{aligned}$$

$$\begin{aligned} \text{Var}(c^l) &= \text{Var}(W^{(l)}) = {}^t W^{(l)} D_p W^{(l)} \\ &= {}^t (\tilde{X} u_l) D_p (\tilde{X} u_l) = {}^t u_l {}^t \tilde{X} D_p \tilde{X} u_l = {}^t u_l (V u_l) \\ &= {}^t u_l (\lambda_l u_l) = \lambda_l \|u_l\|_{\mathbb{R}^p}^2 = \lambda_l \end{aligned}$$

$$\begin{aligned} \text{Cov}(c^l, c^{l'}) &= \langle c^l, c^{l'} \rangle_{D_p} = {}^t c^l D_p c^{l'} \\ &= {}^t W^{(l)} D_p W^{(l')} \\ &= {}^t (\tilde{X} u_l) D_p (\tilde{X} u_{l'}) = {}^t u_l V u_{l'} = \langle u_l, u_{l'} \rangle_V = 0 \end{aligned}$$


II/ Cas où on se place sur (\mathbb{R}^n, D_p)

Soit le nuage de p points de \mathbb{R}^n $N(\bar{X}) = \{ \tilde{X}^j / \tilde{X}^j \in \mathbb{R}^n, j=1, \dots, n \}$
 de la même manière que dans le cas où on se place sur \mathbb{R}^2
 on cherche le s.e.v. de \mathbb{R}^n de dimension 1 qui ajuste au mieux les p points de \mathbb{R}^n .

On note par s le vecteur normé de la base de ce s.e.v. de dim 1
 \mathcal{O}^j est la projection D_p -orthogonale de \tilde{X}^j sur Δs

$$\mathcal{O}^j = \langle \tilde{X}^j, s \rangle_{D_p} = {}^t \tilde{X}^j D_p s.$$

Et erreur de projection



En utilisant le critère M.C qui consiste à minimiser la somme des erreurs quadratique

$$pb \Rightarrow \min \sum_{j=1}^p (\varepsilon_j)^2$$

$$(\varepsilon_j)^2 = \|\tilde{X} \tilde{X}_p^T - \tilde{X}_p \tilde{X}_p^T\|_F^2 \quad (\text{pythagore})$$

$$pb \Rightarrow \max \sum_{j=1}^p (\tilde{X}_j)^2$$

$$\Leftrightarrow \max_{\|\Delta\|_{D_p}^2=1} \sum_{j=1}^p \tilde{X}_j^T \Delta \quad \text{on pose } \mathcal{V} = \begin{pmatrix} \tilde{X}_1 \\ \vdots \\ \tilde{X}_p \end{pmatrix} = \begin{pmatrix} \tilde{X}_{D_p}^T \Delta \\ \vdots \\ \tilde{X}_{D_p}^T \Delta \end{pmatrix} = \tilde{X}_{D_p}^T \Delta$$

$$\Leftrightarrow \max_{\|\Delta\|_{D_p}^2=1} \mathcal{V}^T \mathcal{V} \quad \mathcal{V}^T \mathcal{V} = (\tilde{X}_1^T, \dots, \tilde{X}_p^T) \begin{pmatrix} \tilde{X}_1 \\ \vdots \\ \tilde{X}_p \end{pmatrix} = \sum_{j=1}^p (\tilde{X}_j)^2$$

$$\Leftrightarrow \max_{\|\Delta\|_{D_p}^2=1} \mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} \Leftrightarrow \max_{\|\Delta\|_{D_p}^2=1} \mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V}$$

le problème d'optimisation à une contrainte revient à résoudre

$$\begin{cases} \max_{\Delta \in \mathbb{R}^n} \mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} \\ \|\Delta\|_{D_p}^2 = \mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} = 1 \end{cases}$$

le Lagrangien

$$L(\Delta) = \mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} - \lambda (\mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} - 1)$$

$$\frac{\partial L(\Delta)}{\partial \Delta} = 0 \Leftrightarrow 2 \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} - 2 \lambda \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} = 0$$

$$\Leftrightarrow \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V} = \lambda \mathcal{V}$$

Δ est un vecteur propre de la matrice $\tilde{X}_{D_p}^T \tilde{X}_{D_p}$ associée à la vp λ

Comme le pb d'optimisation consiste à maximiser $\mathcal{V}^T \tilde{X}_{D_p}^T \tilde{X}_{D_p} \mathcal{V}$

ce qui revient à, le s.e.v de dim 1 le plus proche de $N(\mathcal{V})$

est le s.e.v engendré par le vp normé Δ_1 de $\tilde{X}_{D_p}^T \tilde{X}_{D_p}$ associé à la plus grande vp λ_1 .

Δ_1 1^{er} axe factor principal

les q premiers axes principaux sont les s.e.v de dim 1

$\Delta_1, \dots, \Delta_q$, engendré par les vp normés $\Delta_1, \dots, \Delta_q$ de $\tilde{X}_{D_p}^T \tilde{X}_{D_p}$

associés aux q plus grande vp $\lambda_1 \geq \dots \geq \lambda_q$.