

Chap III -

Analyse en composantes principales (ACP)

I - Aperçu de la méthode

p variables quantitatives X_1, X_2, \dots, X_p
 n individus

idée de l'ACP : extraire de la liste des p variables initiales (+ ou - redondantes), une liste de nouvelles variables (ou facteurs) sans aucune redondance.

a. La transformation.

Redondance = . corrélation
. covariance.

Transformation des variables pour éliminer les variances ou les corrélations.

⇒ on va diagonaliser Σ sur \mathbb{R} .

⇒ . une nouvelle base (base des vecteurs propres) → matrice U

. une nouvelle matrice diagonale Λ (matrice diagonale des valeurs propres).

base initiale = variables initiales.

base de vecteurs propres : facteurs (nouvelles variables).

Remarque 1 : On choisit des vecteurs propres unitaires ou normés, c'est à dire dont la

norme vaut 1.

Remarque 2: les vecteurs propres sont orthogonaux 2 à 2.

On obtient finalement une matrice F appelée matrice des scores factoriels, matrice des coordonnées des individus dans la nouvelle base:

$$F = X^D U \text{ ou } X^C U$$

On a donc :

- X^D ou X^C : matrice d'origine (individus par rapport aux variables)
- R ou Σ : matrice de corrélation ou de variance-covariance
- U : matrice des vecteurs propres normés
→ facteurs
- $F = X^D U$ ou $X^C U$: matrice des individus par rapport aux facteurs.

Remarque: F est centrée mais pas forcément réduite.

Qualité globale d'explication (qge): mesure de la qualité d'information portée par un facteur.

b. d'Interpretation.

Il faut tenter:

- d'interpreter les facteurs (axes)
- d'interpreter la position des individus par rapport aux facteurs.

On va etudier les correlations existantes entre les facteurs et les variables.

→ matrice des correlations entre les variables et les facteurs: matrice des saturations S.

$$S = RU \Lambda^{-1/2} \quad \text{ou} \quad \Lambda^{-1/2} = \begin{bmatrix} \frac{1}{\sqrt{\lambda_1}} & & 0 \\ & \frac{1}{\sqrt{\lambda_2}} & \\ 0 & & \ddots \end{bmatrix}$$

λ_i : v.p. de R

$\sqrt{\lambda_i}$: variance du vecteur propre associé

$\frac{1}{\sqrt{\lambda_i}}$: écart type du vecteur propre associé.

$$R = \frac{1}{m} X^d X^d$$

$$S = \frac{1}{m} X^d U \Lambda^{-1/2} = \frac{1}{m} X^d F \Lambda^{-1/2}$$

II- ACP d'un exemple.

matrice des données A =

$$\begin{bmatrix} 3 & 1,2 & 5 \\ 4 & 2 & 6 \\ 3 & 1,8 & 6 \end{bmatrix}$$

(lait) (eau) (huile)

• Première étape: Déterminer A^c ou A^d .

analyse centrée et réduite.

- Calcul des moyennes :

$$\bar{X} = \frac{10}{3} \quad \bar{Y} = \frac{5}{3} \quad \bar{Z} = \frac{17}{3}$$

- Calcul des écart-types :

$$\sigma_x = \frac{\sqrt{8}}{3} \quad \sigma_y = \frac{2\sqrt{19}}{15\sqrt{3}} \quad \sigma_z = \frac{\sqrt{2}}{3}$$

$$\Rightarrow A^s = \begin{bmatrix} \frac{x_1 - \bar{X}}{\sigma_x} & \frac{y_1 - \bar{Y}}{\sigma_y} & \dots \\ \frac{x_2 - \bar{X}}{\sigma_x} & \dots & \dots \\ \frac{x_3 - \bar{X}}{\sigma_x} & \dots & \dots \end{bmatrix}$$

$$A^s = \begin{bmatrix} -0,707 & -1,373 & -1,414 \\ 1,414 & 0,979 & 0,707 \\ -0,707 & 0,391 & 0,707 \end{bmatrix}$$

Vérification : A^s est centrée.

• Deuxième étape : Déterminer R.

$$R = \frac{1}{n} A^s A^s = \begin{bmatrix} 1 & 0,693 & 0,5 \\ 0,693 & 1 & 0,925 \\ 0,5 & 0,925 & 1 \end{bmatrix}$$

Vérification : R est symétrique "des 1" sur la diagonale.

Troisième étape: Diagonalisation de R.

a) Recherche des op de R.

$$\det(R - \lambda I) = \begin{vmatrix} 1-\lambda & 0,693 & 0,5 \\ 0,693 & 1-\lambda & 0,925 \\ 0,5 & 0,925 & 1-\lambda \end{vmatrix} = \begin{vmatrix} 1-\lambda & 0,693 & 0,5 \\ 0 & -386-\lambda & -0,461+1,386\lambda \\ 0,5 & 0,925 & 1-\lambda \end{vmatrix}$$

$$L_1 - \frac{1-\lambda}{0,5} L_3 \rightarrow L_1$$

$$\det(R - \lambda I) = \begin{vmatrix} 0 & -1,157 + 1,85\lambda & -2\lambda^2 + 4\lambda - 1,5 \\ 0 & -0,282 - \lambda & -0,461 + 1,386\lambda \\ 0,5 & 0,925 & 1-\lambda \end{vmatrix}$$

$$= 0,5 \begin{vmatrix} -1,157 + 1,85\lambda & -2\lambda^2 + 4\lambda - 1,5 \\ -0,282 - \lambda & -0,461 + 1,386\lambda \end{vmatrix}$$

$$= 0,5 (-2\lambda^3 + 6\lambda^2 - 2,828\lambda + 0,11)$$

$$= -\lambda^3 + 3\lambda^2 - 1,414\lambda + 0,055.$$

Veuf: - polynôme de degré 3

- terme dominant $(-1)^3 \lambda^3 = -\lambda^3$

- $\frac{-3}{-1} = \bar{x}$ des op = $t_r(R) = 3$

→ résolution de $\det(R - \lambda_j) = 0$.

résolution approchée

3 op

op: variance des facteurs, correspondant

$$\lambda_1 = 2,43$$

$$\lambda_2 = 0,53$$

$$\lambda_3 = 0,004$$