

# **PRINCIPALES COMPOSANTES ANALYSE en**

1. Cas général de l'ACP

2. ACP bipondée

3. ACP simple (covariances)

4. ACP standard (correlations)

## ACP : Cas général

Protocole multivarié de  $K$  variables sur  $(J, n_J)$  :  $(x_J^k)_{k \in K}$

Remplacer les  $K$  variables par  $L'$ , nouvelles variables

### 1.1 Du protocole multivarié au usage de points

Usage de points  $(M_j, n_j)$  dans un espace affine  $\mathcal{U}$  de dimension  $K$

muni du repère cartésien  $(O, \leftarrow(x_J^k)_{k \in K})$ .

Le profil  $x_J^K = (x_J^k)_{k \in K}$  de  $j$  est représenté, par le point pondéré

$(M_j, n_j) : \underline{OM_j} = \sum_{k \in K} x_J^k g_k$ .

Usage euclidien :  $(M_j M_j)^2 = \sum_{k \in K} \sum_{k' \in K} d_{kk'}^2$  avec  $d_{kk'} = \langle g_k | g_{k'} \rangle$

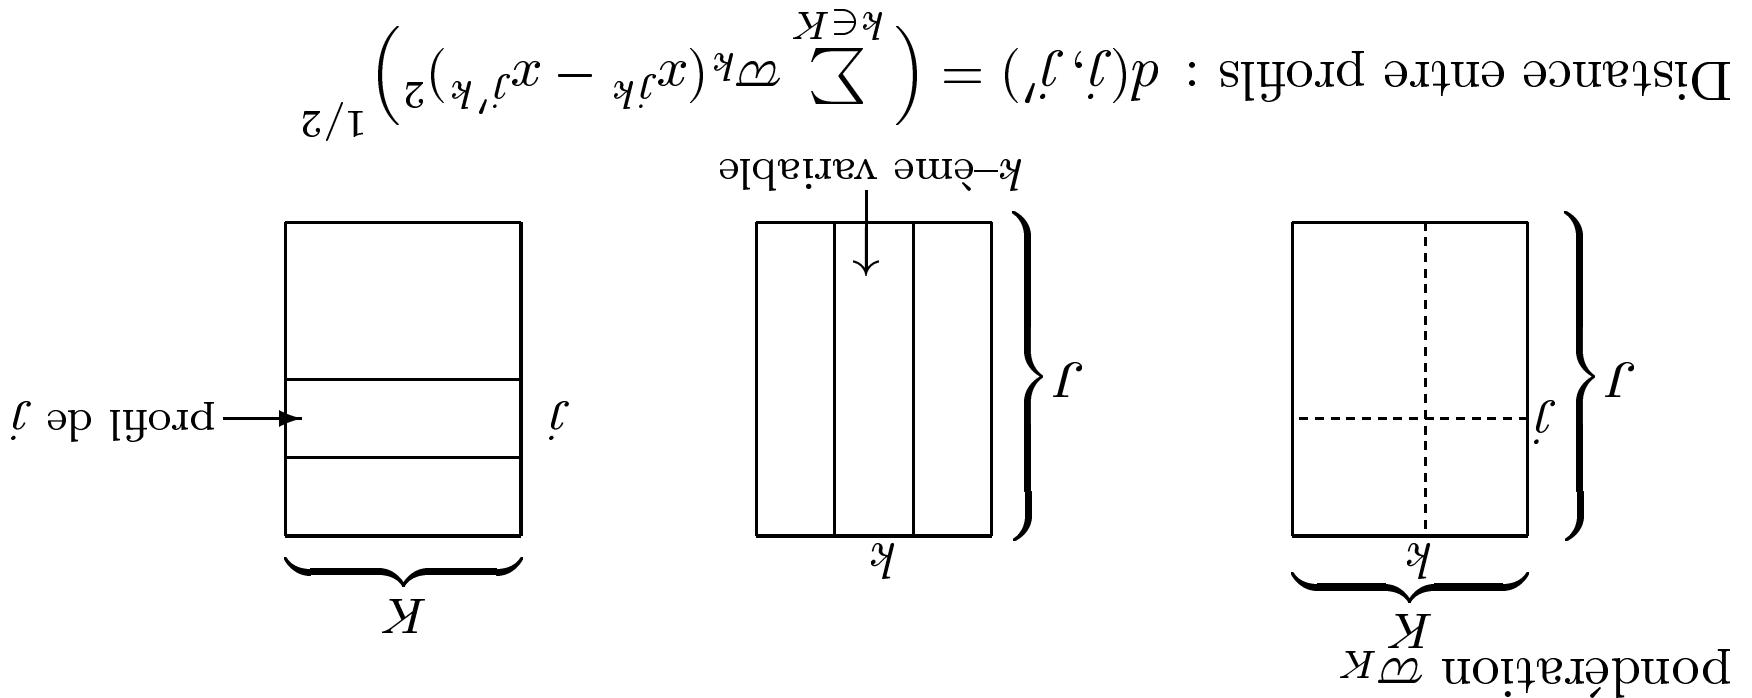
$$\langle g_k | g_{k'} \rangle =$$

EFFECTUER L'analyse en composantes principales du protocole multivariée  $x_{JK}$  c'est déterminer les variables principales du nuage euclidien  $(M_j, n_j)$ , selon les méthodes présentées au chapitre NUAGE.

## 2

### ACP bipondérée

Protocol de notes  $x_{JK}$ , muni de la mesure-efféctifs  $n_J$  et de la



Espace affine  $\underline{\mathcal{U}}$  de dimension  $K$  munie du repère cartésien  $(\mathbf{O}, (\underline{g}_k)_{k \in K})$

$$\text{Point moyen } \bar{\mathbf{G}} = \sum_{k \in K} \underline{g}_k \underline{x}_k = \underline{\mathbf{M}}^f \sum_{j \in I} f_j \mathbf{M}^f_j, \text{ où } \underline{\mathbf{G}} = \sum_{j \in I} f_j \mathbf{G}_j$$

$$\begin{aligned} & \text{Pour } k \neq k', \text{ on a } \underline{g}_k \top \underline{g}_{k'} = \|\underline{g}_k\| \|\underline{g}_{k'}\| \cos(\angle \underline{g}_k, \underline{g}_{k'}). \\ & (\mathbf{M}^f \mathbf{M}^f)^2 = \sum_k \underline{x}_k^2 - \sum_{k' \neq k} \underline{x}_{k'} \underline{x}_k = \sum_k \underline{x}_k^2 - \sum_{k' \neq k} \underline{g}_{k'} \top \underline{g}_k. \end{aligned}$$

La matrice  $\mathbf{Q}$  des produits scalaires est diagonale, notée  $\mathbf{Q}^K$ , avec

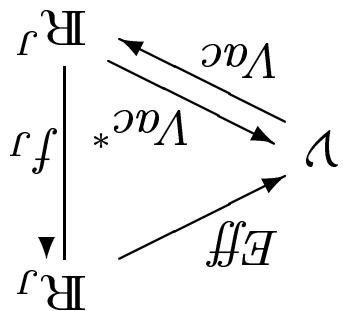
Varianc $e$  du n $uage$  :

$$Cta_k = \omega_k \text{Var} x_{f_k}.$$

Contribution de la variable  $x_{f_k}$  à la variance du n $uage$  :

Nous appellerons I $^*$ ACP d'un tel protocole : ACP pondérée.

## 2.1 Directions et variables principales



$$\begin{aligned}
 Vac &: \underbrace{g_k}_k \leftarrow \langle \underbrace{\mathbf{GM}_j}_{\mathbf{f}} \rangle \sum_{k=1}^K \mathbf{w}_k \mathbf{u}_k \\
 Vac_* &: \underbrace{f_j}_j \leftarrow \langle \underbrace{\mathbf{GM}_j}_{\mathbf{f}} \rangle \sum_{k=1}^K \mathbf{w}_k \mathbf{u}_k \\
 Sum &= Vac_* \circ Vac : \underbrace{g_k}_k \leftarrow \sum_{k=1}^K \mathbf{w}_k \mathbf{u}_k
 \end{aligned}$$

Formules de passage

$$\begin{aligned}
 \text{Variable } a_K &= \underbrace{\sum_{k=1}^K a_k g_k}_k \quad \leftarrow \text{vecteur géométrique } \underbrace{a}_a \\
 \text{Equation aux directions et valeurs propres :} \\
 Sum(a) &= \underbrace{\chi_a}_a \text{ soit } \sum_{k=1}^K u_k a_k = \chi_a
 \end{aligned}$$

avec :  $a_k = a_k \underline{w}_k$

$$\text{Mo}_j y_j = 0 \text{ et } \text{Var} y_j$$

$y_j$  est la coordonnée du point  $M_j$  sur l'axe principal

$$y_j = \sum_{k \in K} a_k x_{jk}^0, \text{ avec } \sum_{k \in K} a_k^2 = 1$$

: Variable principale calibrée (formule de passage)

Reconstitution d'ordre  $L'$  du tableau des variables centrees :

$$\tilde{x}_{j,k} = \sum_{l=1}^{k \in K} a_{k,l} y_l \quad \text{avec} \quad \sum_{l=1}^{k \in K} a_{k,l}^2 = 1$$

Reconstitution des distances :

$$(GM_j)^2 = \sum_{T=1}^{k \in K} w_k (x_{j,k} - \bar{x}_k)^2 = \sum_{T=1}^{k \in K} (y_j^k)^2$$

Variance du usage :  $\text{Var } M_j = \sum_{T=1}^{k \in K} w_k \text{Var } x_{j,k}$

$$\chi^2 = \sum_T w_k$$

## 2.2 Formules de reconstitution

## 2.3 Espace des variables : caractérisation

### statistique

En termes statistiques, le problème de l'ACP peut être formulé :

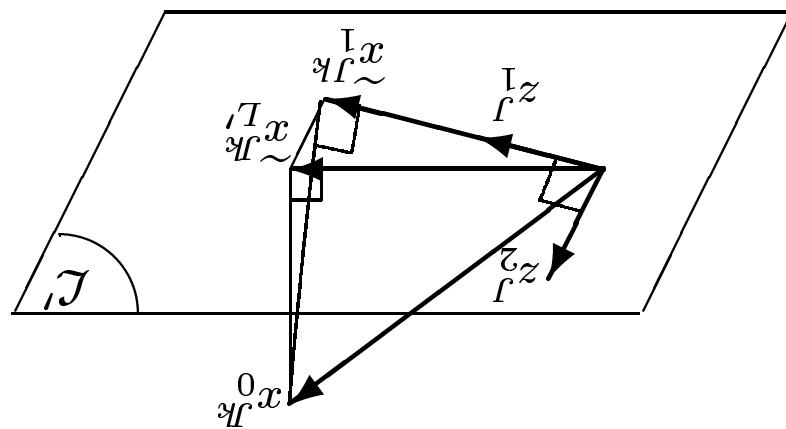
Problème : parmi les variables  $\sum_{k \in K} a_k x_{jk}$ , combinaisons linéaires des variables initiales  $(x_{jk})_{k \in K}$ , chercher celle(s) qui vérifie(nt) :

$\text{Var}\left(\sum_{k \in K} a_k x_{jk}\right) / \left(\sum_{k \in K} a_k^2 / w_k\right)$  maximum.

Chercher  $\text{Var}\left(\sum_{k \in K} a_k x_{jk}\right) / \left(\sum_{k \in K} a_k^2 / w_k\right)$  maximum revient à déterminer la première variable principale, puisque cette statistique est la variance du usage dans la direction  $a$ .

## 2.4 Espace des variables

Régression des variables initiales sur les variables principales.



Le coefficient de régression partielle de  $x_j^0$  est le coefficient de régression simple  $b_k = \text{Cov}(x_j^0 | z_j^1)$ , avec  $\text{Var} x_j^0$

$$\text{Formule de reconstruction : } x_j^0 = b_k z_j^1 + \sum_{l=2}^L b_l z_j^l \text{ avec } b_k = a_k^0 \xi_k$$

Corrélation.

$$\rho_k = \text{Corr}(x_{J^k} | z_f) = q_k / \text{Ety} x_{J^k}$$

$$1 = \sum_{\ell=1}^L (\rho_\ell)^2$$

$\rho_k$  = au cosinus de l'angle entre les variables (vecteurs)  $x_{J^k}$  et  $z_f$

Corrélation multiple  $R$  entre  $x_{J^k}$  et les  $L'$  premières variables

$$\text{Principales : } R^2 = \sum_{\ell=1}^{L'} (q_\ell)^2 / \text{Var} x_{J^k};$$

## 2.4.1 Variable moyenne

Posons  $\underline{w} = \sum_{k \in K} w_k$  et notons  $\underline{x}_j$  la  $\underline{w}_K$ -moyenne des notes de l'individu  $j$ , où la variable des moyennes, ou variable moyenne

$$\underline{x}_j = (\underline{x}_j^k)_{k \in K} \text{ avec : } \underline{x}_j^k = \sum_{i \in K} w_i^k x_{ij}^k / \underline{w}.$$

On a :  $\text{Moy } \underline{x}_j = \sum_{k \in K} w_k \underline{x}_j^k / \underline{w}$ , et  $\text{Var } \underline{x}_j = \sum_{k \in K} w_k^2 \underline{x}_j^k / \underline{w}^2$ .

La variable moyenne (centre) est principale si et seulement si  $\text{Cov}(x_{jk} | \underline{x}_j)$  ne dépend pas de  $k$ .

La variable principale calibrée est alors  $y_j^0 = \sqrt{\underline{w}} \underline{x}_j^0$ , associée à la

variable propre  $\chi = \sqrt{\text{Var } \underline{x}_j}$ .

Si  $x_j^0$  est variable principale associée à  $\chi_j \neq \chi$  est l'effet d'un contraste sur variable principale associée à la valeur propre  $\chi$ , toute  $K$  applique aux  $K$  variables initiales.

$$\begin{array}{c}
 \boxed{\mathbf{I}} = \boxed{\mathbf{V}} \boxed{\mathcal{U}} \boxed{\mathbf{A}} \\
 \boxed{\mathcal{V}} \boxed{\mathbf{A}} = \boxed{\mathbf{A}} \boxed{\mathcal{U}} \boxed{\Lambda} \\
 \sum_{k \in K} w_k (\omega_k, a_k)^2 = 1 \quad \text{avec} \quad \sum_{k' \in K} v_{k'} (\omega_{k'}, a_{k'}) = \lambda a_k
 \end{array}$$

Équation aux directions et valeurs propres :

*principales*

**2.5 Formulaire :** diagrammes résumés des formules

$$A' \begin{pmatrix} V \\ \diagdown \end{pmatrix} A = A$$

$$\sum_{k=1}^K w_k a_k = v$$

$$\begin{pmatrix} E \\ \diagdown \end{pmatrix} A = B$$

$$w_k \zeta = q$$

$$A' \begin{pmatrix} X \\ \end{pmatrix} = \begin{pmatrix} 0 \\ X \end{pmatrix}$$

$$A \begin{pmatrix} U \\ \diagdown \end{pmatrix} \begin{pmatrix} 0 \\ X \end{pmatrix} = Y$$

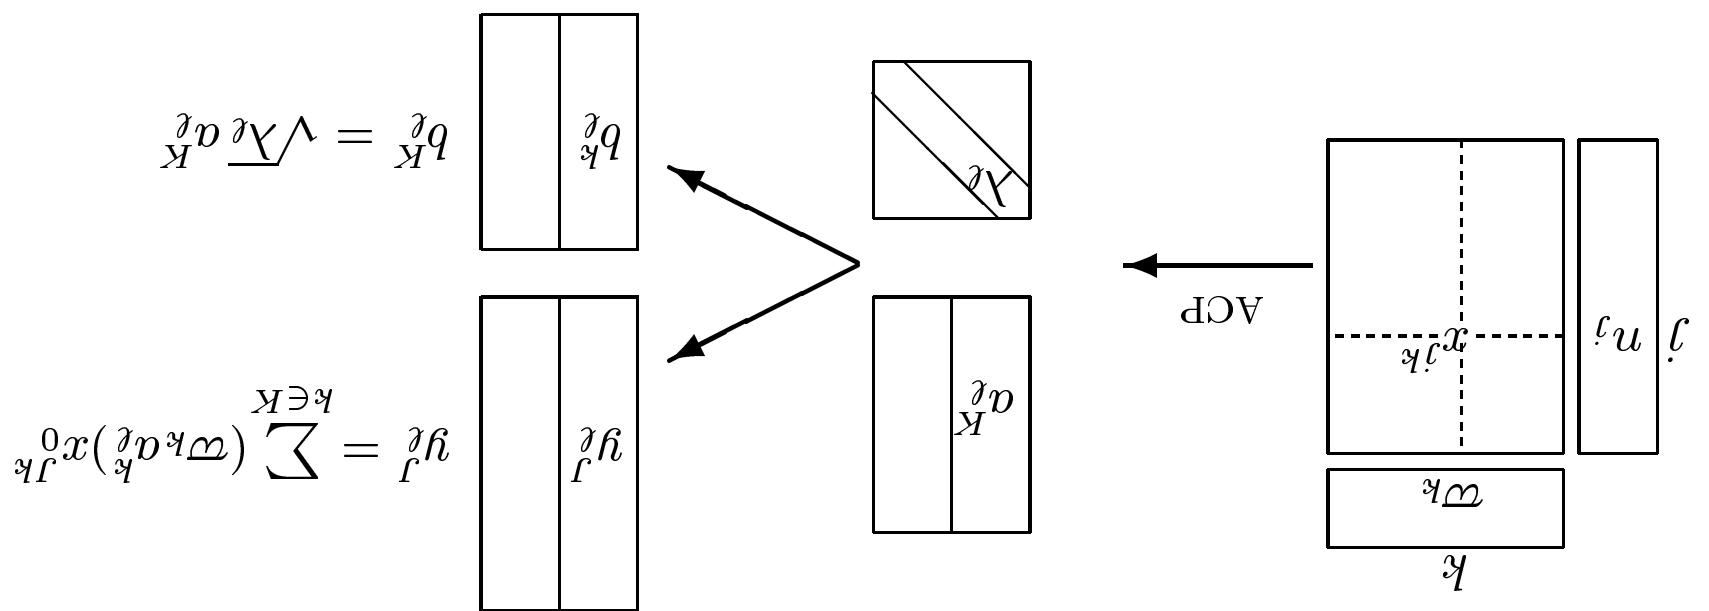
$$y_f = \sum_{k=1}^K x_f^0 (w_k a_k)$$

Formules de reconstruction

Coordonnées principales

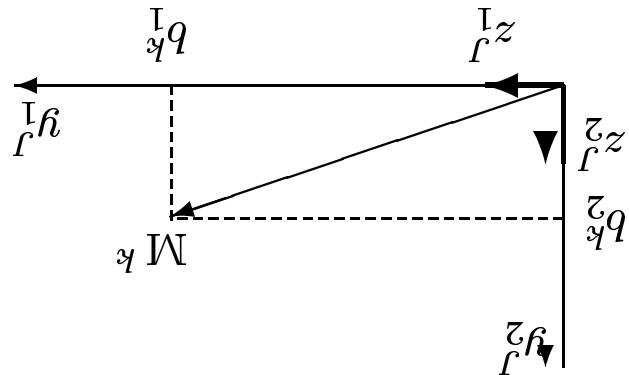
- premières variables principales réduites.
- coefficients de régression ( $b_k$ ) des  $K$ /variables initiales sur les axes principaux retenus pour l'interprétation;
- coordonnées ( $y_j$ ) des  $J$ /points du nuage sur les  $L$ , ( $L \geq T$ )
- vecteurs et valeurs propres  $\lambda$ :

## 2.6 Principaux résultats



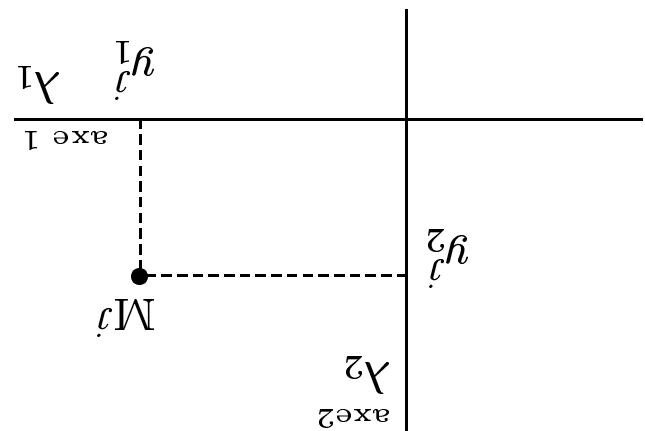
## 2.7 Représentations graphiques

Espace des variables principales initiales variables regressions des  $K$  principales 1, 2, 3, etc. Coordonnées :  $(b_k^1, b_k^2)$  par rapport à  $(z_f^1, z_f^2)$ .



Espace des variables

Espace d'observables, projection du nuage des individus sur les premiers axes 1, 2, etc., ou dans les plans principaux 1-2, 1-3, 2-3, etc.  $M^j$  est représenté par le point d'abscisse  $y^1_j$  et d'ordonnée  $y^2_j$ , etc.



## Procédure de calcul.

- On calcule la matrice  $\mathbf{S}$  de terme général  $s_{kk'} = \sqrt{\omega_k \omega_{k'}} u_{kk'}$ .
- On diagonalise  $\mathbf{S}$ , d'où :  $(\lambda_k, (c_{kk'})_{k \in K})_{k=1, \dots, T}$ , avec  $\sum_{k \in K} c_{kk}^2 = 1$ .

- Pour  $j = 1, \dots, T$  et  $j \in J$ , on calcule :
- $y_j^l = \sum_{k \in K} \sqrt{\omega_k} c_{kk} x_{jk}^0$ .

• Un programme d'ACP pondéré, réalisé avec P. Bonnet, est disponible auprès des auteurs.

**Formulations matricielles.**  $\mathbf{c}_\ell = K$ -colonne  $(c_{k\ell})_{k \in K}$ ,

$\mathbf{C}$  : matrice  $K \times L$ , des  $K$ -colonnes  $(\mathbf{c}_\ell)_{\ell=1, \dots, L}$ ;

$\mathbf{y}_j$  la  $J$ -colonne des coordonnées principales  $(y_{j\ell})_{\ell \in J}$ ;

$\mathbf{b}_k$  la  $K$ -colonne des coefficients de régression  $(b_{k\ell})_{k \in K}$  ;

$\mathbf{U}_{1/2}^K$  la matrice diagonale  $(\sqrt{w_k})_{k \in K}$ ; on a :

$$\mathbf{1}. \quad \mathbf{S} = \mathbf{U}_{1/2}^K \mathbf{V} \mathbf{U}_{1/2}^K.$$

$$2. \quad \mathbf{S}\mathbf{C} = \mathbf{C}\mathbf{A} \text{ avec } \mathbf{C}'\mathbf{C} = \mathbf{I}.$$

$$3. \quad \text{Pour } \ell = 1, \dots, L : \mathbf{y}_\ell = \mathbf{X}^0 \mathbf{U}_{1/2}^K \mathbf{c}_\ell.$$

$$4. \quad \text{Pour } \ell = 1, \dots, L : \mathbf{q}_\ell = \sqrt{\lambda_\ell} \mathbf{U}_{1/2}^K \mathbf{c}_\ell.$$

### 3

## ACP simple ou des covariances

Toutes les variables sont affectées de poids  $w_k$  égaux à 1 ( $J$ )

$$(M_j^j M_{j'}^{j'})_2 = \sum_{k \in K} (x_{jk} - x_{j'k})^2 \quad (\text{métrique euclidienne})$$

élémentaire). La base  $(\underline{y}_k)_{k \in K}$  est orthonomé ( $\mathbf{Q} = \mathbf{I}^K$ ).

Équation aux directions et valeurs propres :

$$(\text{Var } M_j = \sum_{k \in K} \text{Var } x_{jk})$$

Variance du nage = somme des variances des variables initiales

Dans l'ACP simple, directions principales et valeurs propres  
s'obtiennent par diagonalisation de la matrice  $\mathbf{V}$  des covariances et  
covariances entre les variables initiales : l'ACP simple est l'analyse

des covariances.

$$\boxed{A'} \quad \boxed{Y} = \boxed{{}^0X}$$

$$y_f = \sum_{k=1}^K a_k x_f^k$$

Formules de reconstruction

$$\boxed{A} \quad \boxed{{}^0X} = \boxed{Y}$$

$$y_f = \sum_{k \in K} a_k x_f^k$$

Coordonnées principales

$$\boxed{I} = \boxed{A} \quad \boxed{A'}$$

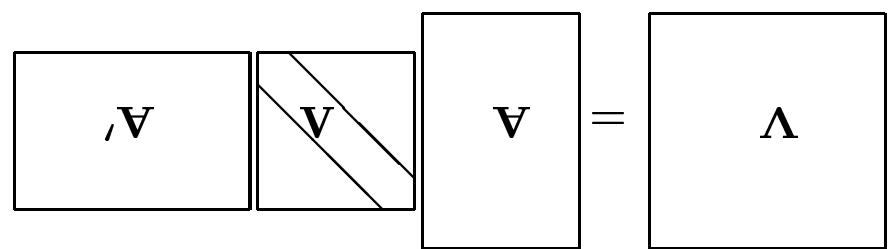
$$1 = \sum_{k \in K} (a_k)^2$$

$$\boxed{V} \quad \boxed{A} = \boxed{A} \quad \boxed{A'}$$

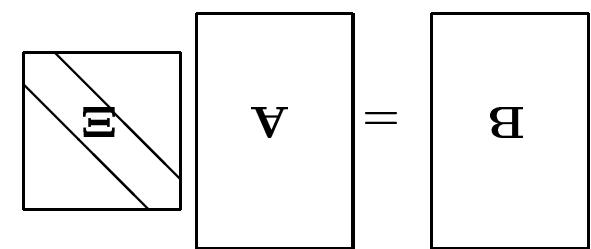
$$\sum_{k \in K} v_{k'} a_{k'} = \lambda a_k$$

Équation aux directions et valeurs propres :

### 3.1 Formulaire de l'ACP simple



$$\sum_{T=1}^{\infty} \alpha^T A' = A$$



$$E = B$$

- On calcule la matrice  $\Sigma$  des covariances.
- On diagonalise  $\Sigma$ , d'où  $(\alpha_k, (a_k)_{k \in K})_{k=1, \dots, T}$  avec  $\sum_{k \in K} (a_k)^2 = 1$ .
- Pour  $j = 1, 2, \dots, T$ , on calcule  $y_j = \sum_{k \in K} a_k x_k^j$ .
- Pour  $\ell = 1, 2, \dots, T$ , on calcule  $b_\ell = \bigwedge_{k \in K} a_k$ .

## 3.2 Procédure de calcul

## 4 ACP standard ou des corrélations

Variables hétérogènes : ramener à une même échelle par une procédure de solidarisation  
L'ACP standard revient donc d'une part à solidariser par réduction des échelles des variables, d'autre part à donner à ces variables des poids égaux à 1 ; les variables ont donc la même contribution à la variance du nuage.

Dans l'ACP standard, directions principales et valeurs propres s'obtiennent par diagonalisation de la matrice des corrélations entre les variables initiales : l'ACP standard est l'analyse des corrélations.

$$B_L^2 = \sum_{L'} (r_{L'})^2 = \sum_{L'} \left( \sum_{k=1}^K (q_k^{L'})^2 \right).$$

$x_{T_k}$  et les  $L'$  premières variables principales est donc par

- Le coefficient de corrélation multiple  $B_L$ , entre la variable initiale

$(q_k^L)^2 = \chi(a_k^L)^2 = \text{Ctr}_k^L$  (contribution relative de l'axe  $L$  à la variable  $k$ ).

On a  $(a_k^L)^2 = \text{Ctr}_k^L$  (contribution relative de la variable  $k$  à l'axe  $L$ ) ; et

$$\forall L : \sum_{k=1}^K (a_k^L)^2 = 1 \text{ et } \forall k : \sum_L (a_k^L)^2 = 1 = \sum_{L'} \left( \sum_{k=1}^K (q_k^{L'})^2 \right)$$

Les coefficients  $a_k^L$  vérifient donc la double propriété :

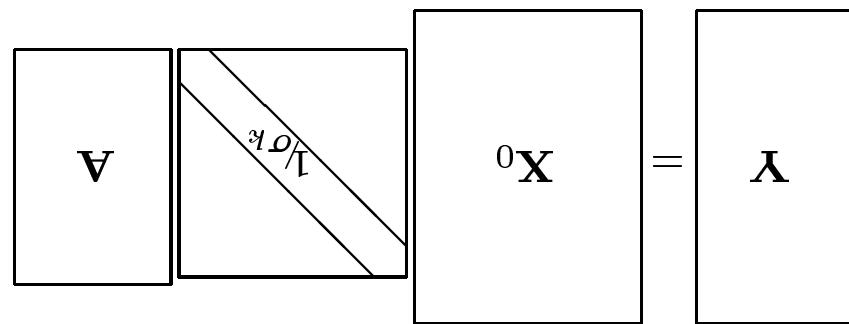
corrélation entre variables initiales et variables principales :  $q_k^L = r_k^L$ .

- Les coefficients de régression  $b_k^L = \xi_k a_k^L$  sont les coefficients de

variables :

- La variance du usage = somme des valeurs propres = nombre de

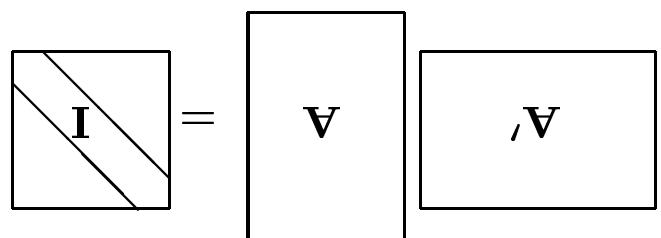
## 4.1 Propriétés de l'ACP standard



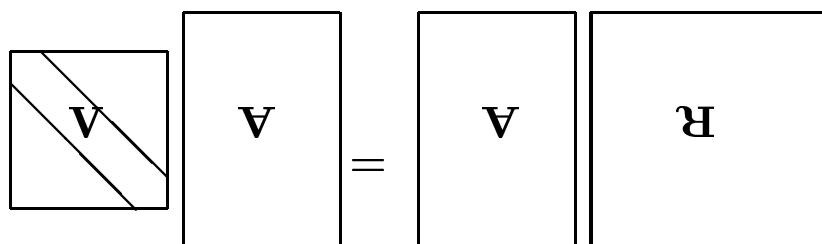
$$\sum_{k \in K} a_k x_k = y_f$$

Coordonnées principales

Formules de reconstruction



$$\sum_{k \in K} (a_k)^2 = 1$$

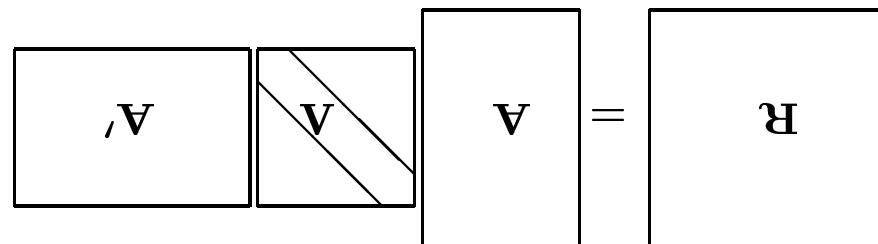


$$\sum_{k \in K} r_k a_k = y_a$$

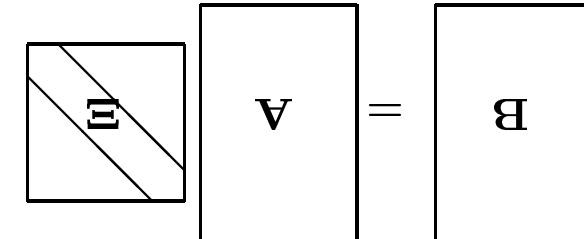
Équation aux directions et valeurs propres :

avec

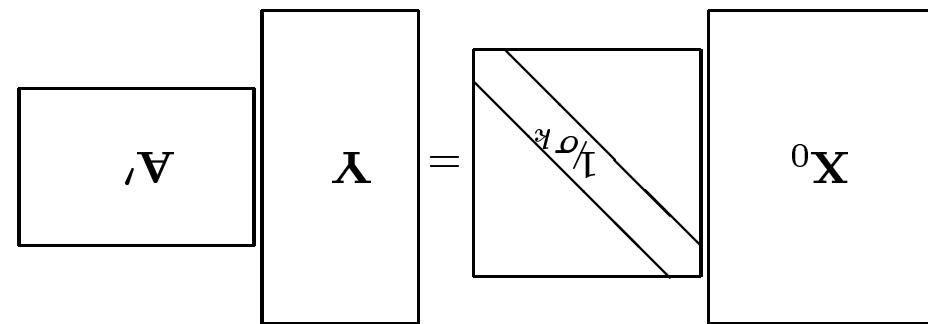
## 4.2 Formulaire de l'ACP standard



$$\sum_{T=1}^T b_k b_k = \sum_{T=1}^T \lambda a_k a_k = r_k$$



$$\lambda a_k a_k = r_k = b_k$$



$$\sum_{T=1}^T a_k a_k = \frac{\omega}{x}$$

### 4.3 Procédure de calcul

1. On calcule la matrice  $\mathbf{B}$  des corrélations.
2. On diagonalise  $\mathbf{B}$ , d'où  $(\lambda_k, (a_{k\ell})_{\ell=1,\dots,L}^K)$  avec  $\sum_{k \in K} (a_{k\ell})^2 = 1$ .
3. Pour  $j = 1, \dots, L$ , on calcule :  $y_j = \sum_{k \in K} a_{k\ell} x_{jk}^0 / \sigma_k$ .
4. Pour  $\ell = 1, \dots, L$ , on calcule :  $b_\ell = \sqrt{\lambda_\ell} a_\ell$ .

- **Facteur de taille** : sur le cercle des corrélations, les variables sont toutes situées d'un même côté.
- Corrélation de la variable moyenne avec la variable principale importante = facteur de taille
- **Facteur de taille** : sur le cercle des corrélations, les variables sont toutes situées d'un même côté.
- impartante de la variante du usage.
- s'assure ensuite que les  $L_j$  axes retenus prennent en compte une partie importante de la moyenne du usage.
- On retient au moins tous les axes dont la contribution est supérieure à une contribution moyenne (e.g. à  $\text{Var } M_j/k$ , ou  $\text{Var } M_j/L$ ) ; on assure ensuite que les  $L_j$  axes retenus prennent en compte une partie importante de la moyenne du usage.
- Contributions des axes
  - Contributions des individus, contributions des variables.

## 5.1 Analyse globale du usage

# 5 Méthodologie et interprétation