

# Introduction aux méthodes statistiques

*26 Février 2008*

**Christian CAPARIN**  
***christian.caparin@wanadoo.fr***

- >> *Introduction*

# BUTS DE LA PRESENTATION

- Faire une présentation non théorique des méthodes statistiques utilisées en pratique
- Partir des problèmes et voir les exemples de solutions apportées

# Champs d'application

- Finance : analyse de risque, prévision de séries financières
- Marketing: fidélité client, détection de fraude, validation de campagnes
- Bioinformatique

# Les caractéristiques du problème des statisticiens

- Un nombre important de variables
  - Parfois des centaines
  - Pas nécessairement de même nature
- Un nombre important d'individus
  - Notamment à cause de l'apparition de l'outil informatique

# Objectif du statisticien

- Réduire le nombre de variables du problème

OU/ET

- Réduire le nombre d'individus

## Deux solutions

- Modèles non supervisés
  - Aucune variable est privilégiée l'une par rapport à l'autre
  - Volonté de résumer toute l'information
- Modèles supervisés
  - Explication d'une (ou plusieurs) variable(s) à l'aide des autres

## Objectif

- Étude d'un méthode non supervisée

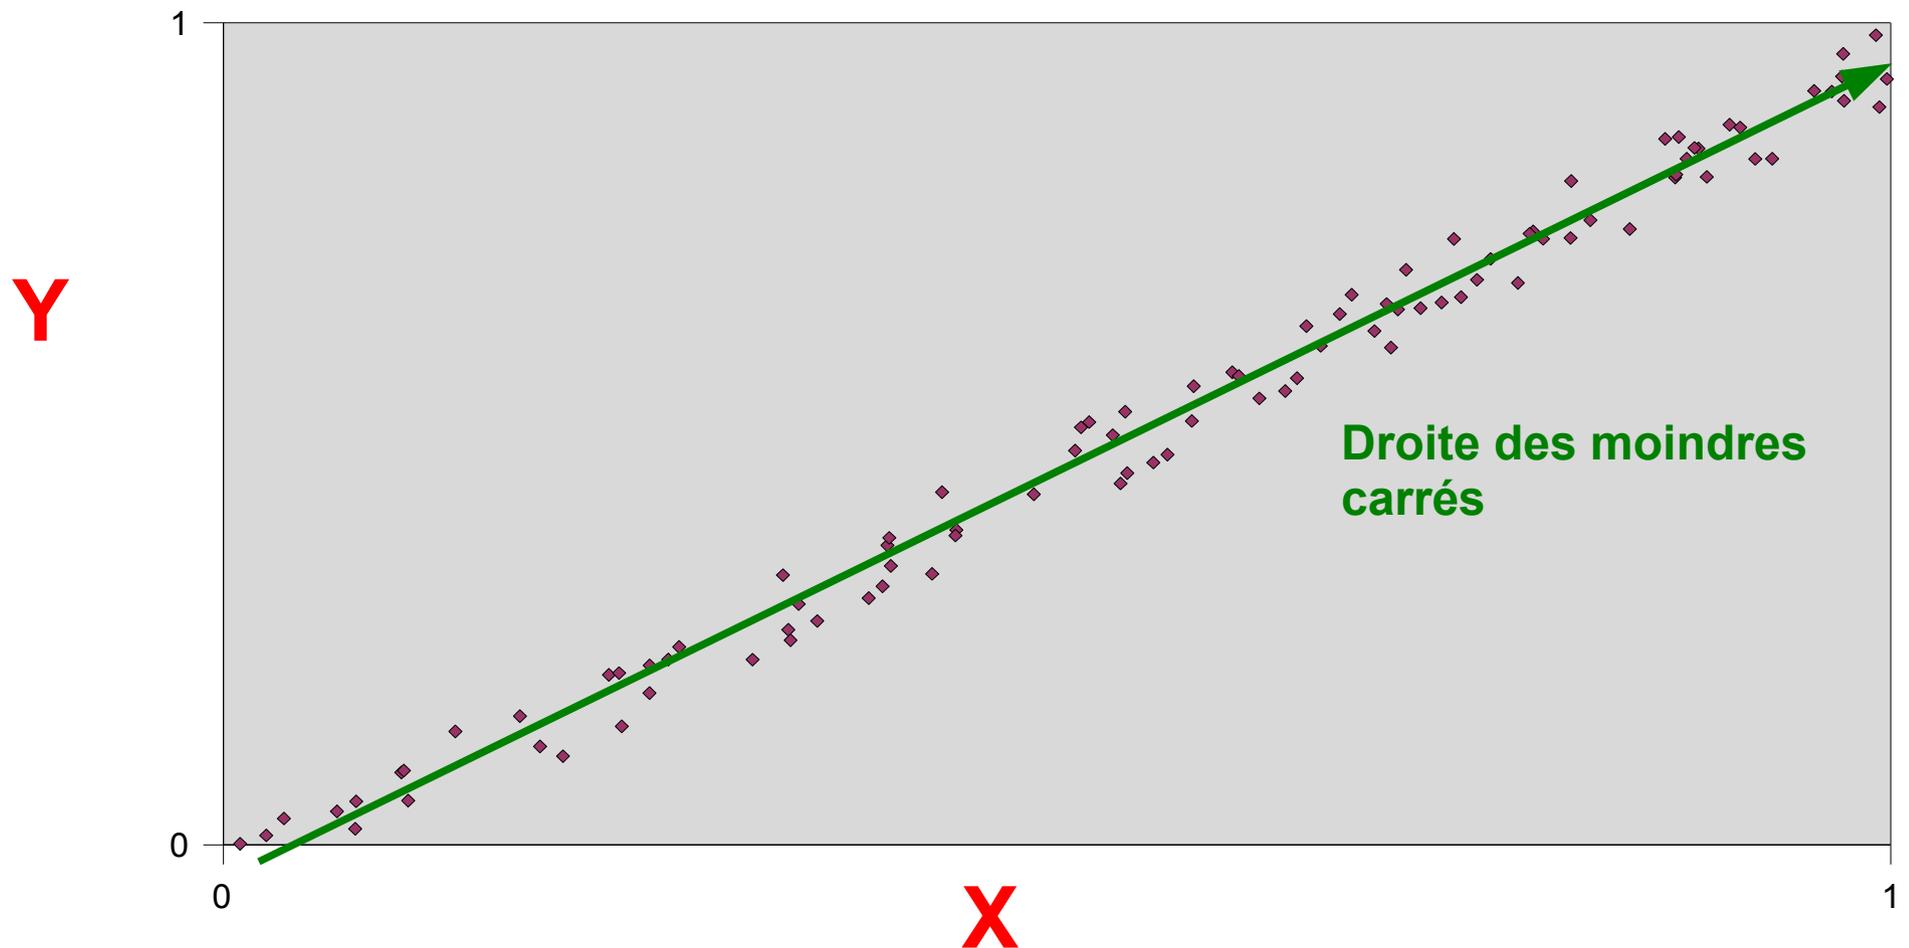
***A.C.P.***

***Analyse en composantes principales***

## Les enjeux

- Constat: **difficulté** pour l'être humain de voir dans des espaces de dimension importante
  - Facilité uniquement pour les espaces de dimension 1 et 2 voire trois
- Objectif: « **résumer** » des données de dimension importante dans des espaces de dimension acceptable

# Un cas simple



# Problématique

- Algorithme proposé
  - Utiliser la droite des moindres carrés pour résumer les données
- Inconvénients
  - Quelle régression choisir? Celle de Y sur X ou celle de X sur Y?

# Rappel: Les moindres carrés

- Hypothèse

$$Y = aX + b + \epsilon$$

- Estimation de a et b

$$\min_{a,b} \sum_{i=1}^N (y_i - ax_i - b)^2$$

# Problématique

- Décomposition de la variance

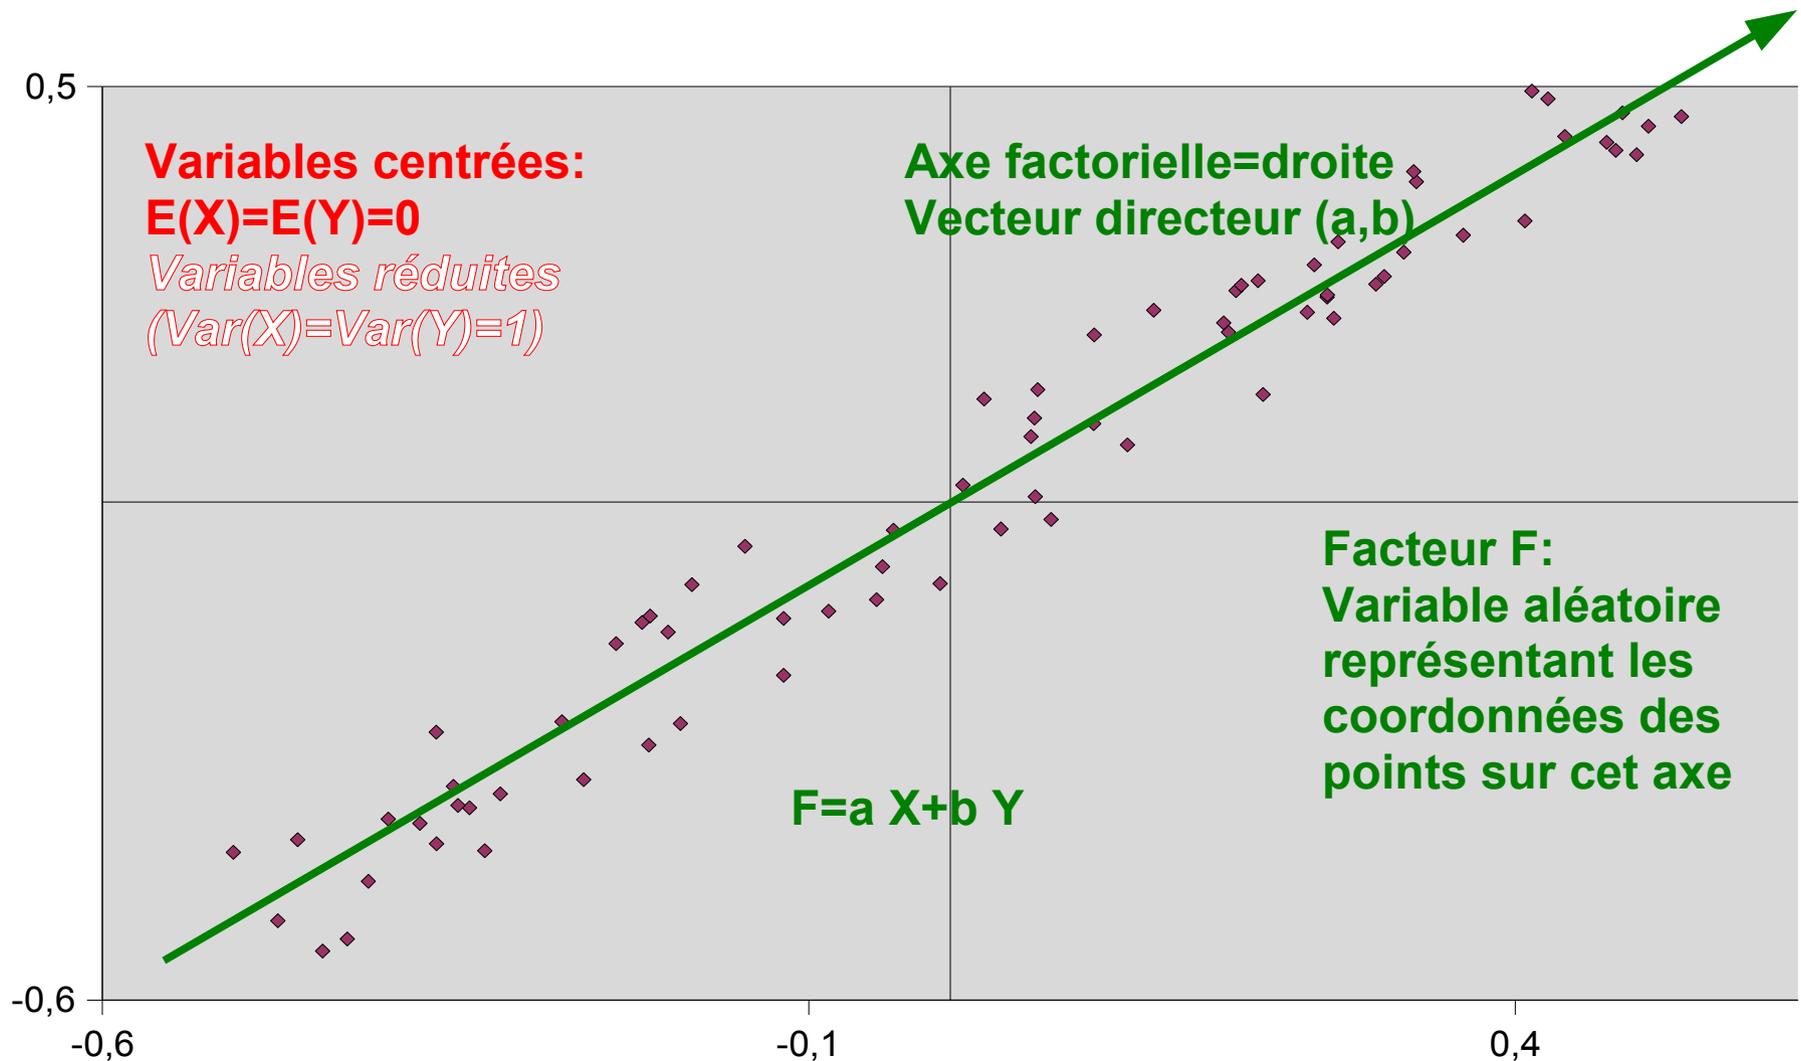
$$VAR(Y) = VAR \underbrace{(aX + b)}_{\text{variance expliquée}} + VAR \underbrace{(Y - aX - b)}_{\text{variance résiduelle}}$$

- Non corrélation entre les résidus et le signal

$$cov(Y - aX - b, aX + b) = 0$$

- >> *Un modèle non supervisé: L'ACP*

# Vocabulaire



# Mathématisation

- Une relation fondamentale

$$VAR((X, Y)) = \underbrace{VAR(F \vec{u})}_{\text{variance expliquée par l'axe}} + \underbrace{VAR((X, Y) - F \vec{u})}_{\text{variance résiduelle}}$$

$$COV(F \vec{u}, (X, Y) - F \vec{u}) = 0$$

Idée d'un nouvel algorithme?

# Mathématisation

- Algorithme pour la **dimension 2**
  - Je choisis l'axe qui donne la plus grande variance expliquée
  - L'autre axe factoriel est l'axe orthogonal au précédent (et qui passe par O)

A-t-on fini?

# Mathématisation

- Problème
  - Si on est en dimension supérieure ou égale à 3, quel sera le deuxième axe factoriel qu'on va choisir?
- Solution
  - Prendre des axes factoriels qui
    - Expliquent le maximum de variance
    - Sont non corrélés aux précédents

# Algorithme

- Données:
  - Une population sur laquelle sont renseignées les variables  $X_1, \dots, X_p$  quantitatives
- Initialisation:
  - Je choisis comme premier axe l'axe qui explique la plus grande variance possible
- Phase itérative
  - Je prends comme axe suivant, l'axe qui explique la plus grande variance possible mais qui en'est pas corrélé avec les axes déjà trouvés.

## Algorithme: Phase d'initialisation

- Je cherche le premier facteur  $F_1$  comme combinaison linéaire des variables initiales
  - $F_1 = \alpha_1 X_1 + \dots + \alpha_p X_p$
  - $(\alpha_1, \dots, \alpha_p)$  vecteur unitaire
- Je choisis les  $\alpha_1, \dots, \alpha_p$  de façon à ce qu'ils maximisent  $\text{var } F_1$ .

## Algorithme: Phase itérative

- Données:
  - J'ai déjà trouvé les facteurs  $F_1, F_{k-1}$
- Je cherche le facteur  $F_k$  comme combinaison linéaire des variables initiales
  - $F_k = \beta_1 X_1 + \dots + \beta_p X_p$
- Je choisis les  $\beta_1, \dots, \beta_p$  de façon à ce qu'ils maximisent  $\text{var } F_k$  sous la contrainte:
$$\text{cov}(F_k, F_n) = 0 \text{ pour } 1 \leq n < k$$

## Quelques résultats(I)

- Les vecteurs solutions sont les vecteurs propres de la matrice de covariance des variables.

$$\Sigma = \left( cov(X_i, X_j) \right)_{1 \leq i \leq p, 1 \leq j \leq p}$$

## Quelques résultats(II)

- La somme des variances des  $F_i$  est égale à la variance totale de l'échantillon
  - Souvent, on ne parle qu'en terme de pourcentage de la variance totale

## Quelques résultats(III)

- On peut exprimer  $X_i$  une variable en fonction des facteurs

- $X_i = \alpha_1 F_1 + \dots + \alpha_p F_p$

- On peut exprimer les  $\alpha_k$  facilement

- $\alpha_k = \text{cov}(X_i, F_k) / \text{var}(F_k)$

- >> *Un exemple*

## Un exemple



**Iris Virginica**



**Iris  
Versicolor**



**Iris Setosa**

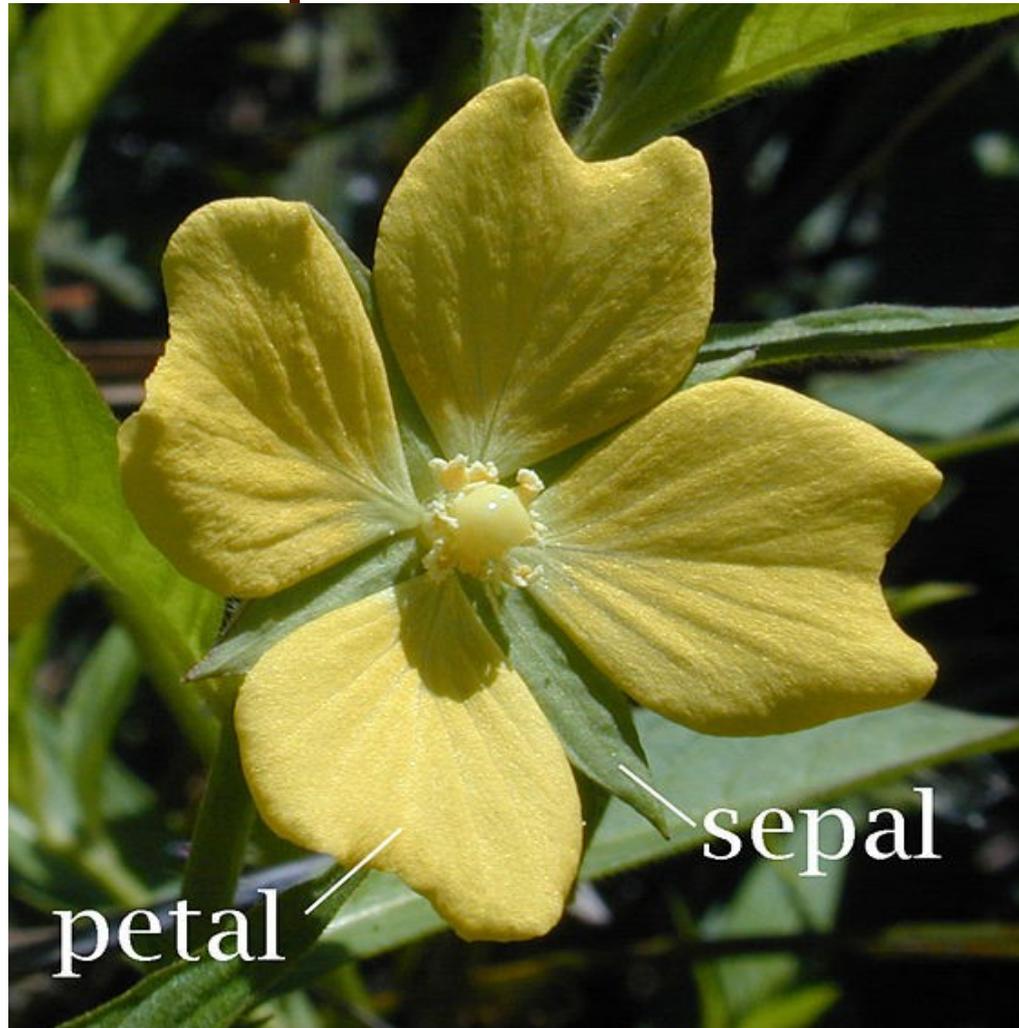
- >> *Un exemple*

## Un exemple

- Échantillon de 150 fleurs de ce type (50 de chaque type)
- Description de chaque fleur avec quatre variables
  - Longueur et largeur du sépale
  - Longueur et largeur de la pétale

- >> *Un exemple*

## Une petite définition



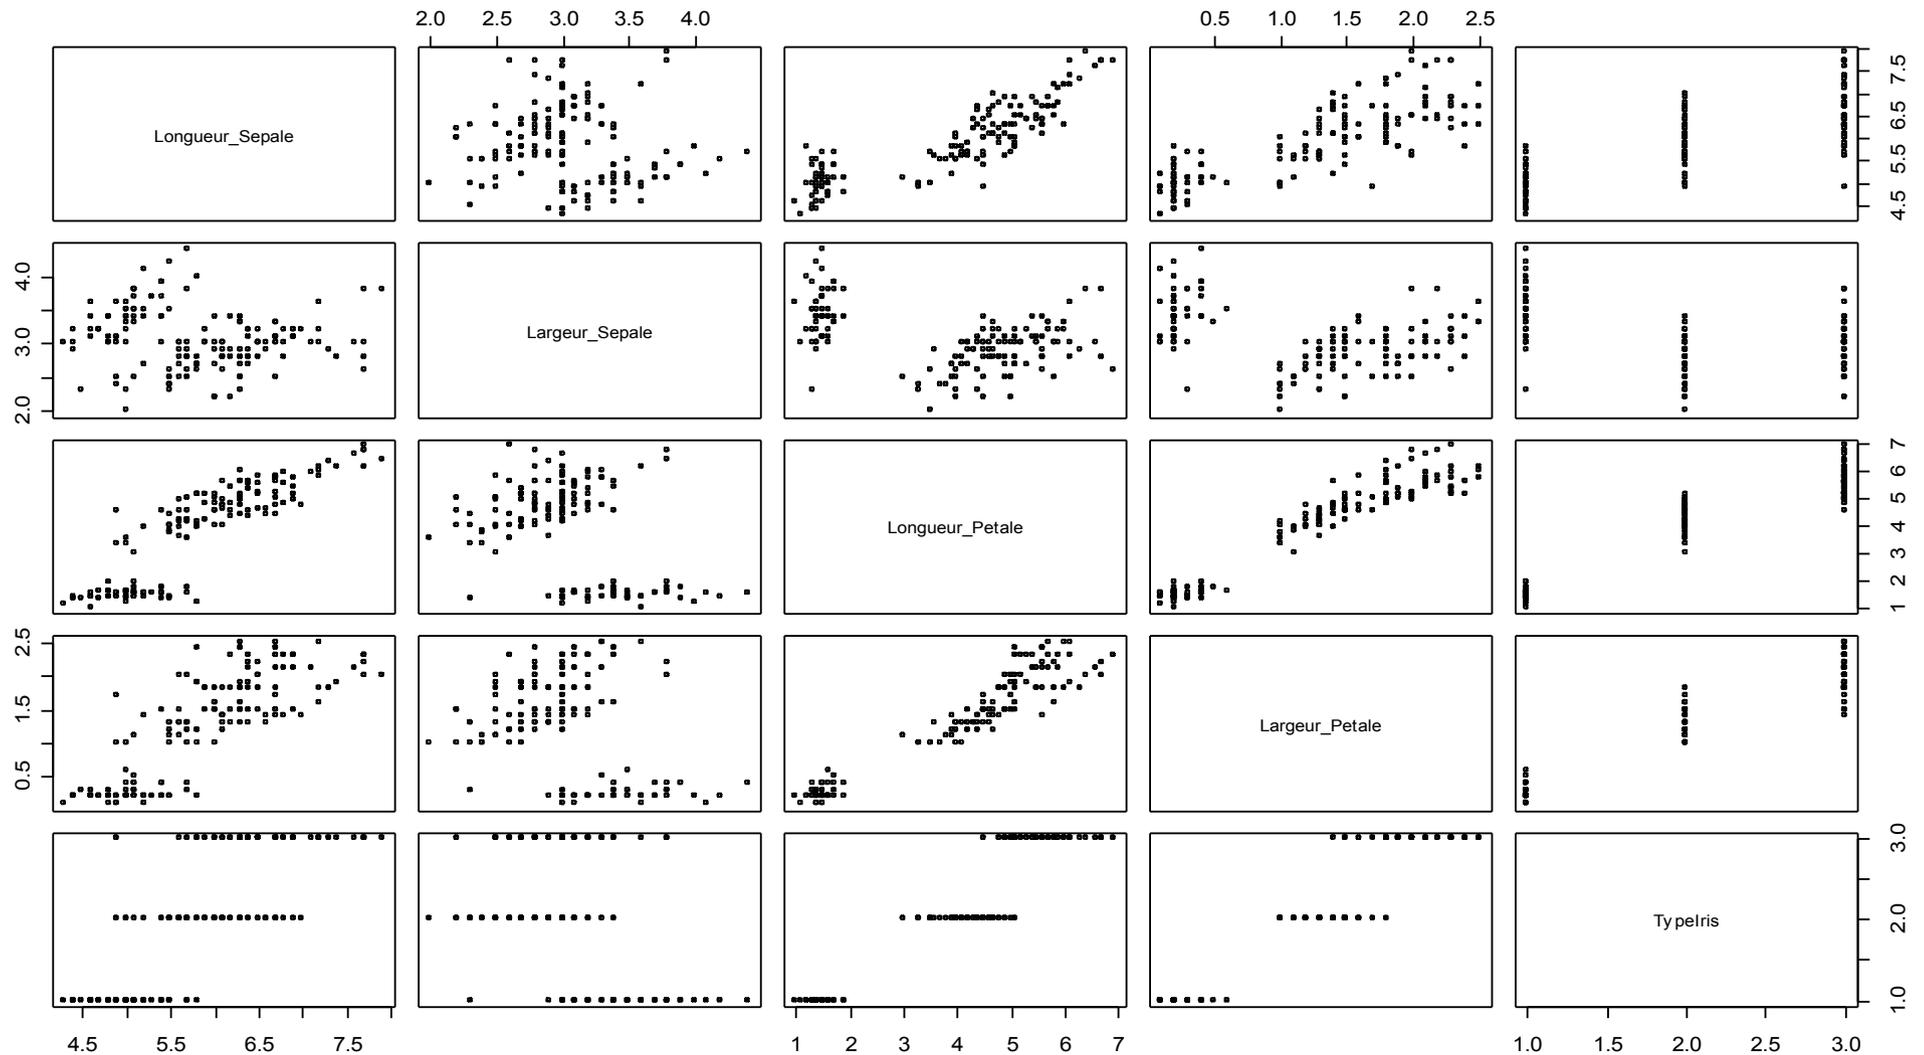
- >> *Un exemple*

# Un exemple

LONGUEUR SEPALE	LARGEUR SEPALE	LONGUEUR PETALE	LARGEUR PETALE	TYPE
5.1	3.5	1.4	0.2	Iris-setosa
4.9	3.0	1.4	0.2	Iris-setosa
4.7	3.2	1.3	0.2	Iris-setosa
4.6	3.1	1.5	0.2	Iris-setosa
5.0	3.6	1.4	0.2	Iris-setosa

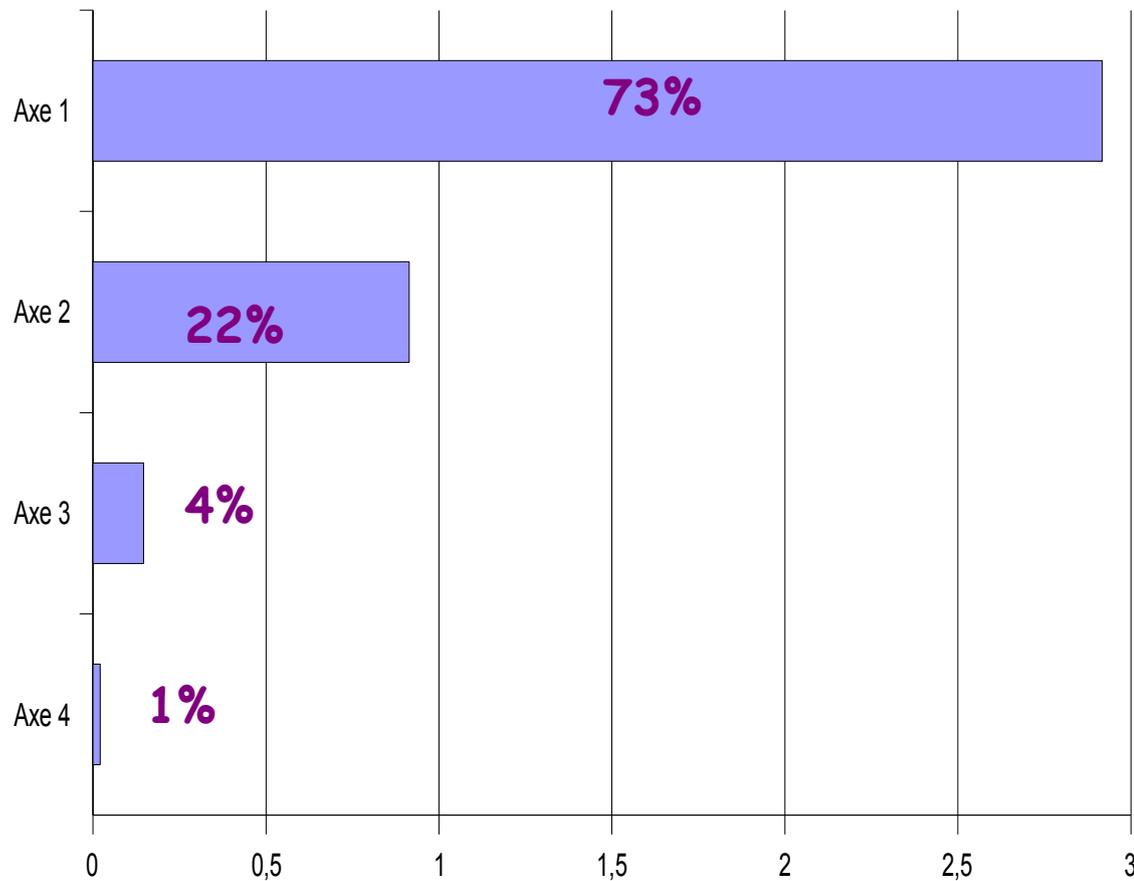
- >> *Un exemple*

# Les graphiques usuels



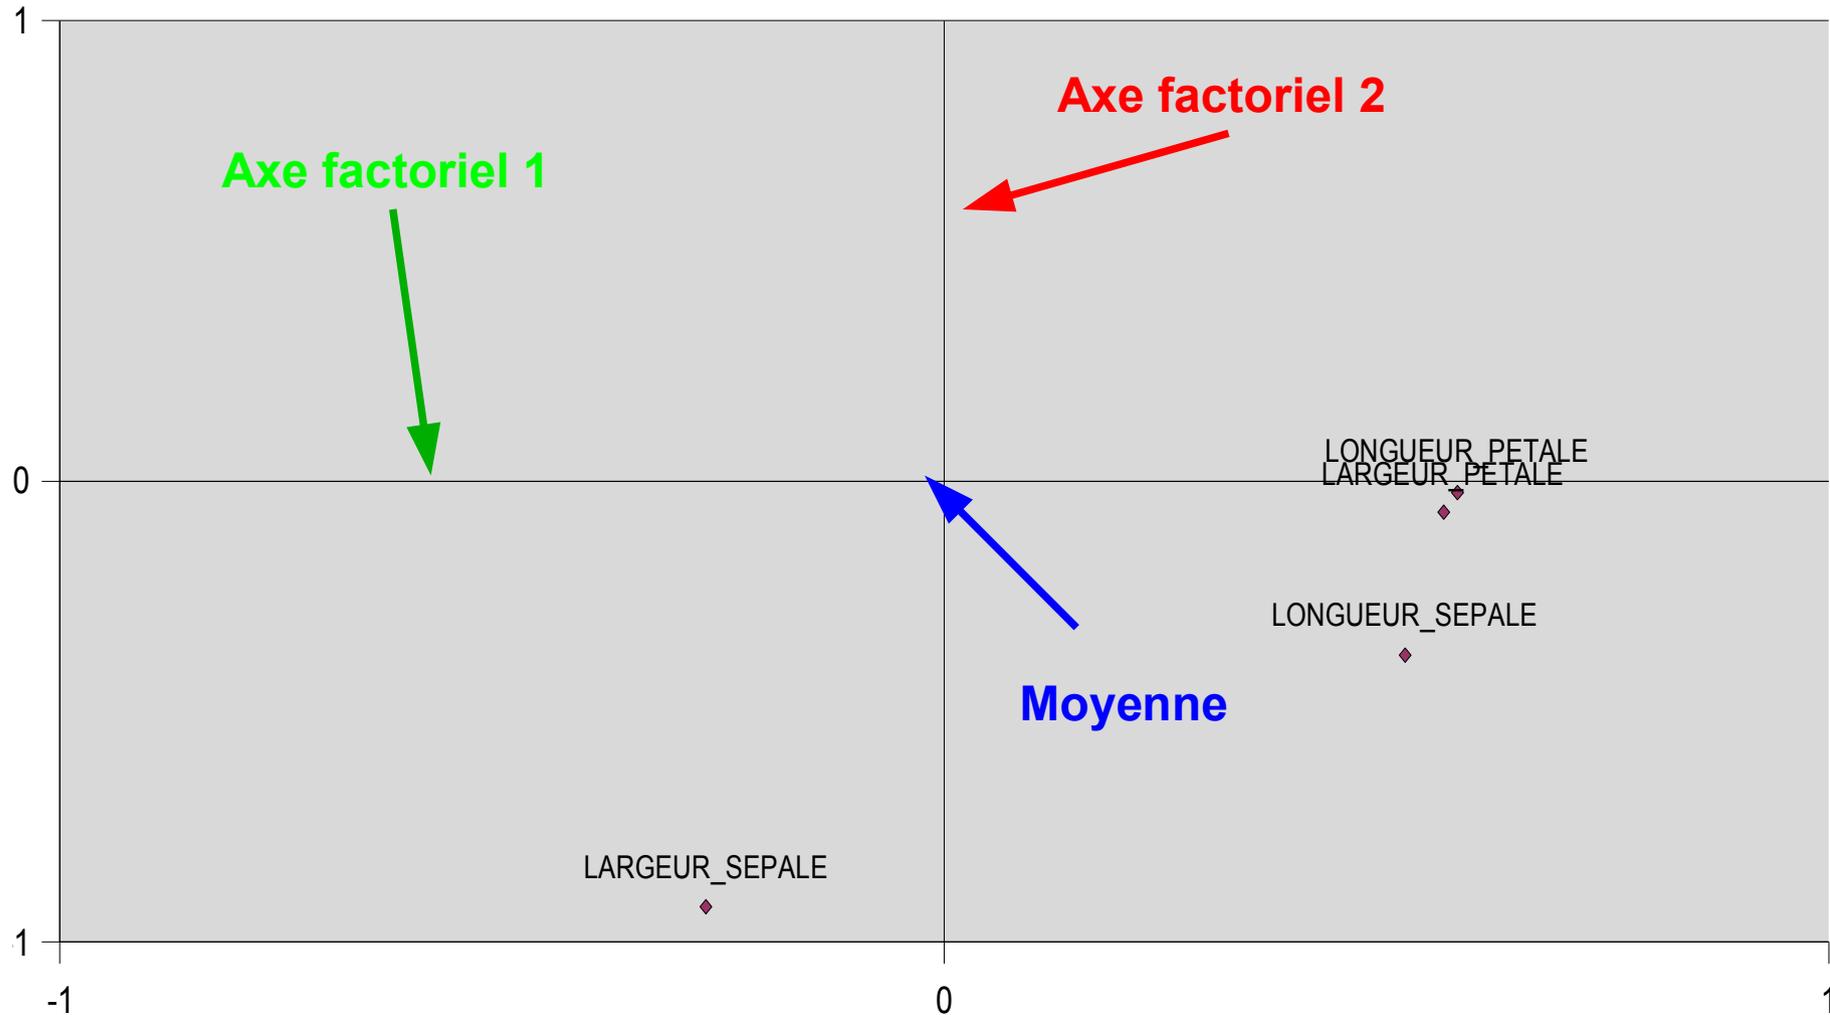
- >> *Un exemple*

# Variance de chaque axe



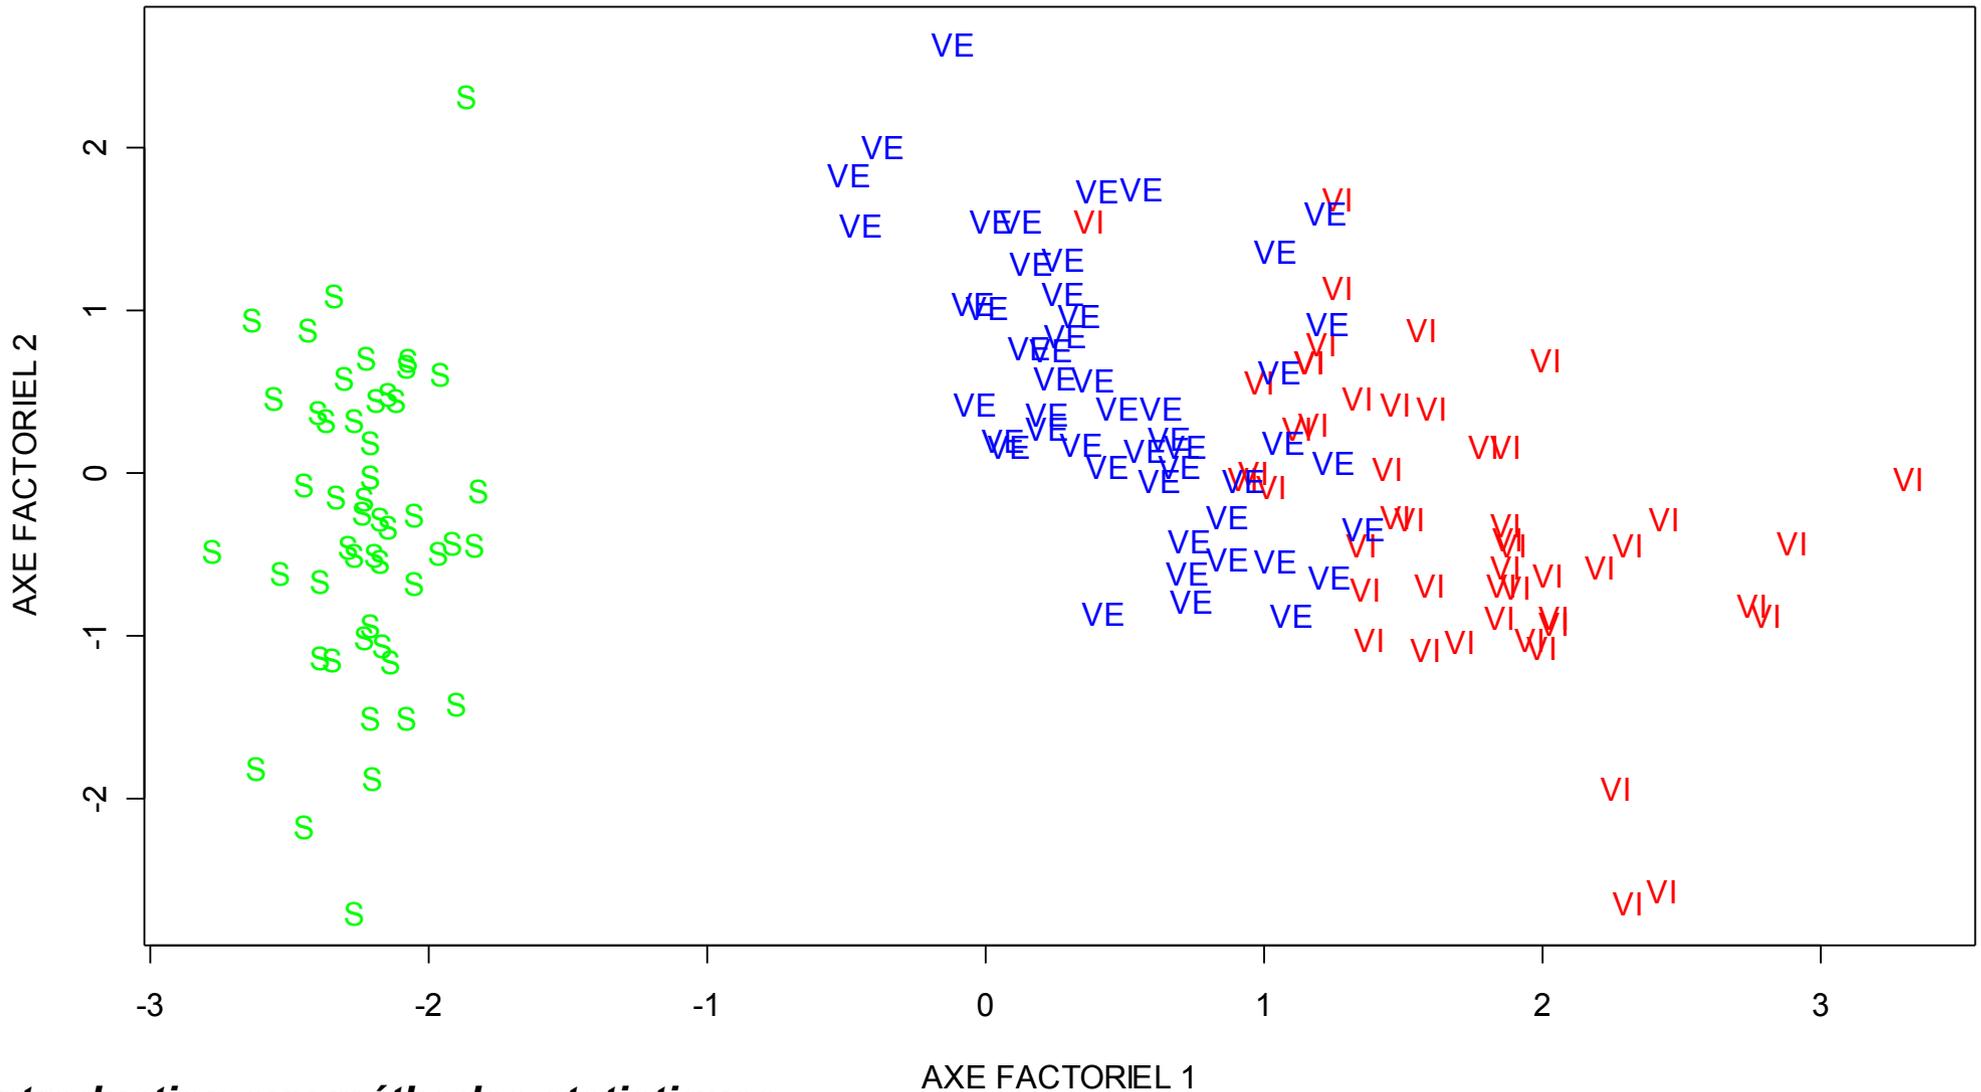
- >> *Un modèle non supervisé: L'ACP*

# Projection des variables



- >> *Un exemple*

# Projection des individus



- >> *Un exemple*

## Le premier axe

- Faibles largeur ,  
longueur de pétales et  
longueur de sépale



**SETOSA**

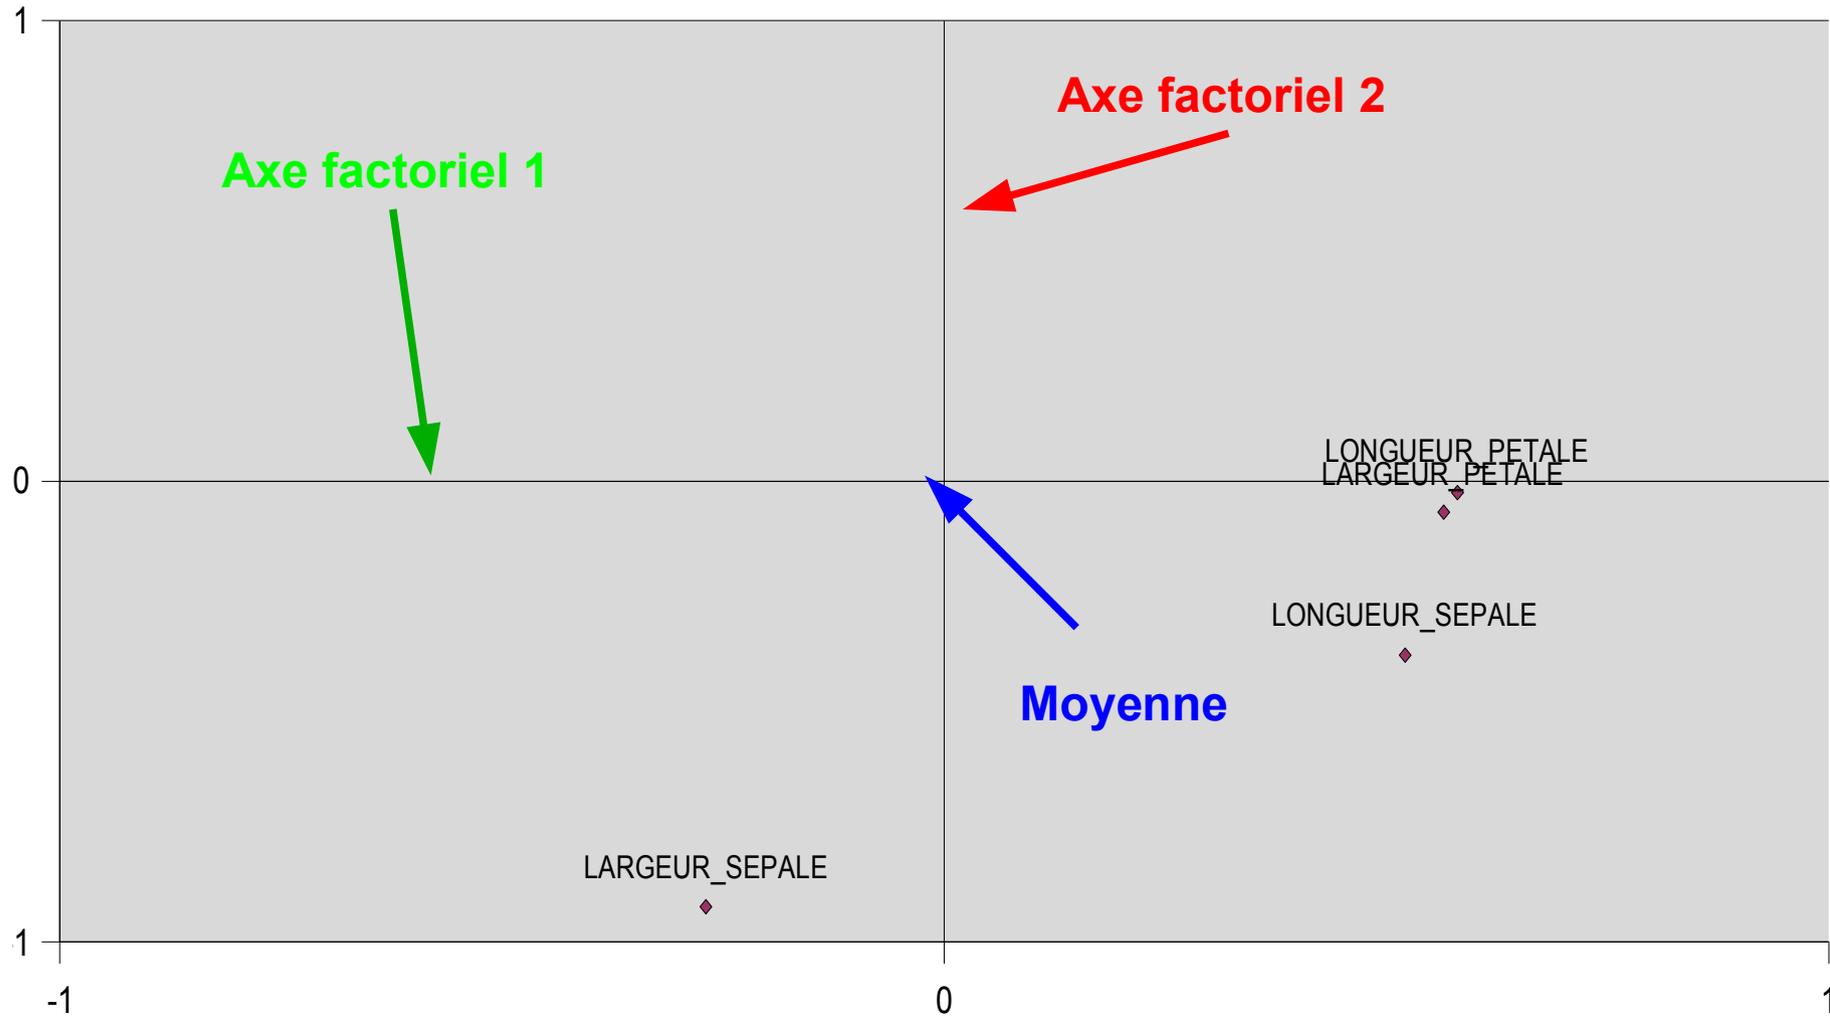
- Fortes largeur ,  
longueur de pétales et  
forte longueur de pétale



**VIRGINICA**

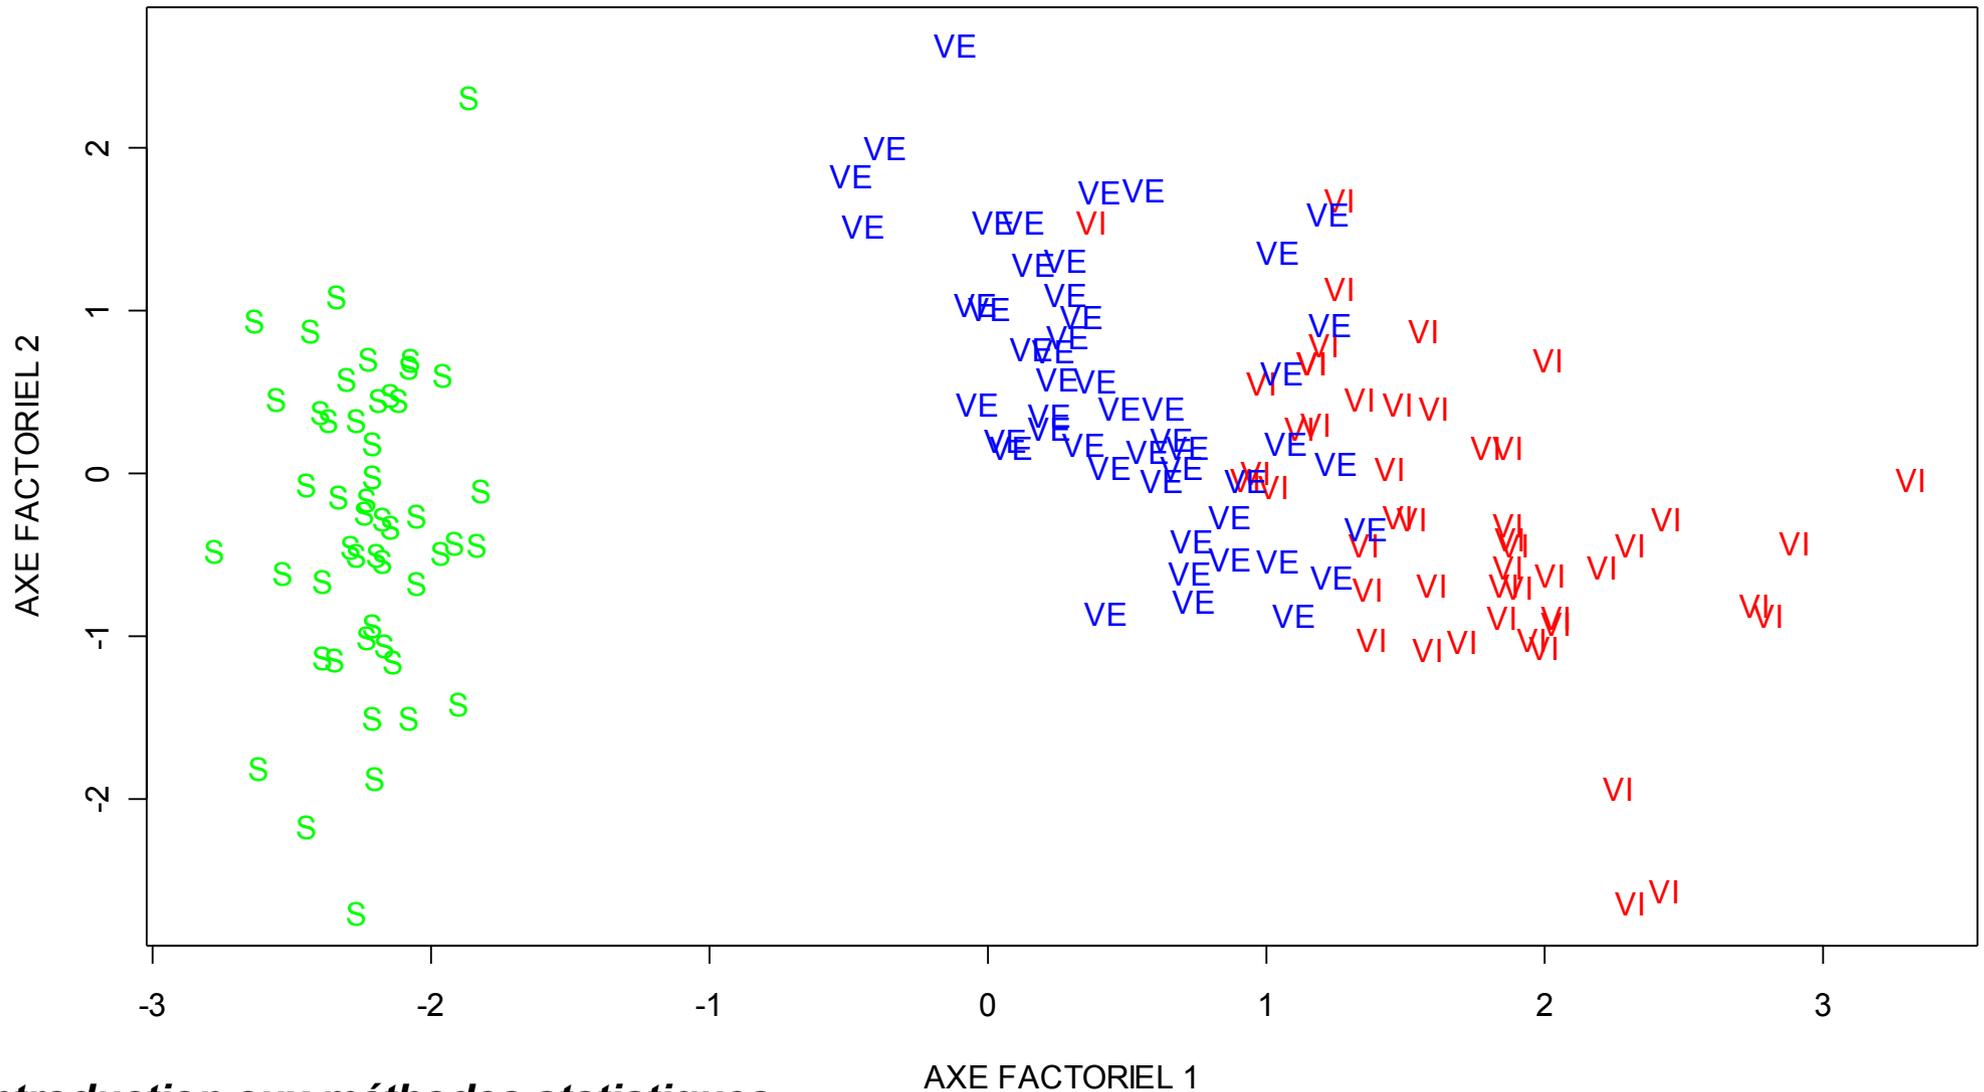
- >> *Un exemple*

# Projection des variables



- >> *Un exemple*

# Projection des individus



- >> *Un exemple*

## Le second axe

- Forte largeur de sépale



**SETOSA**

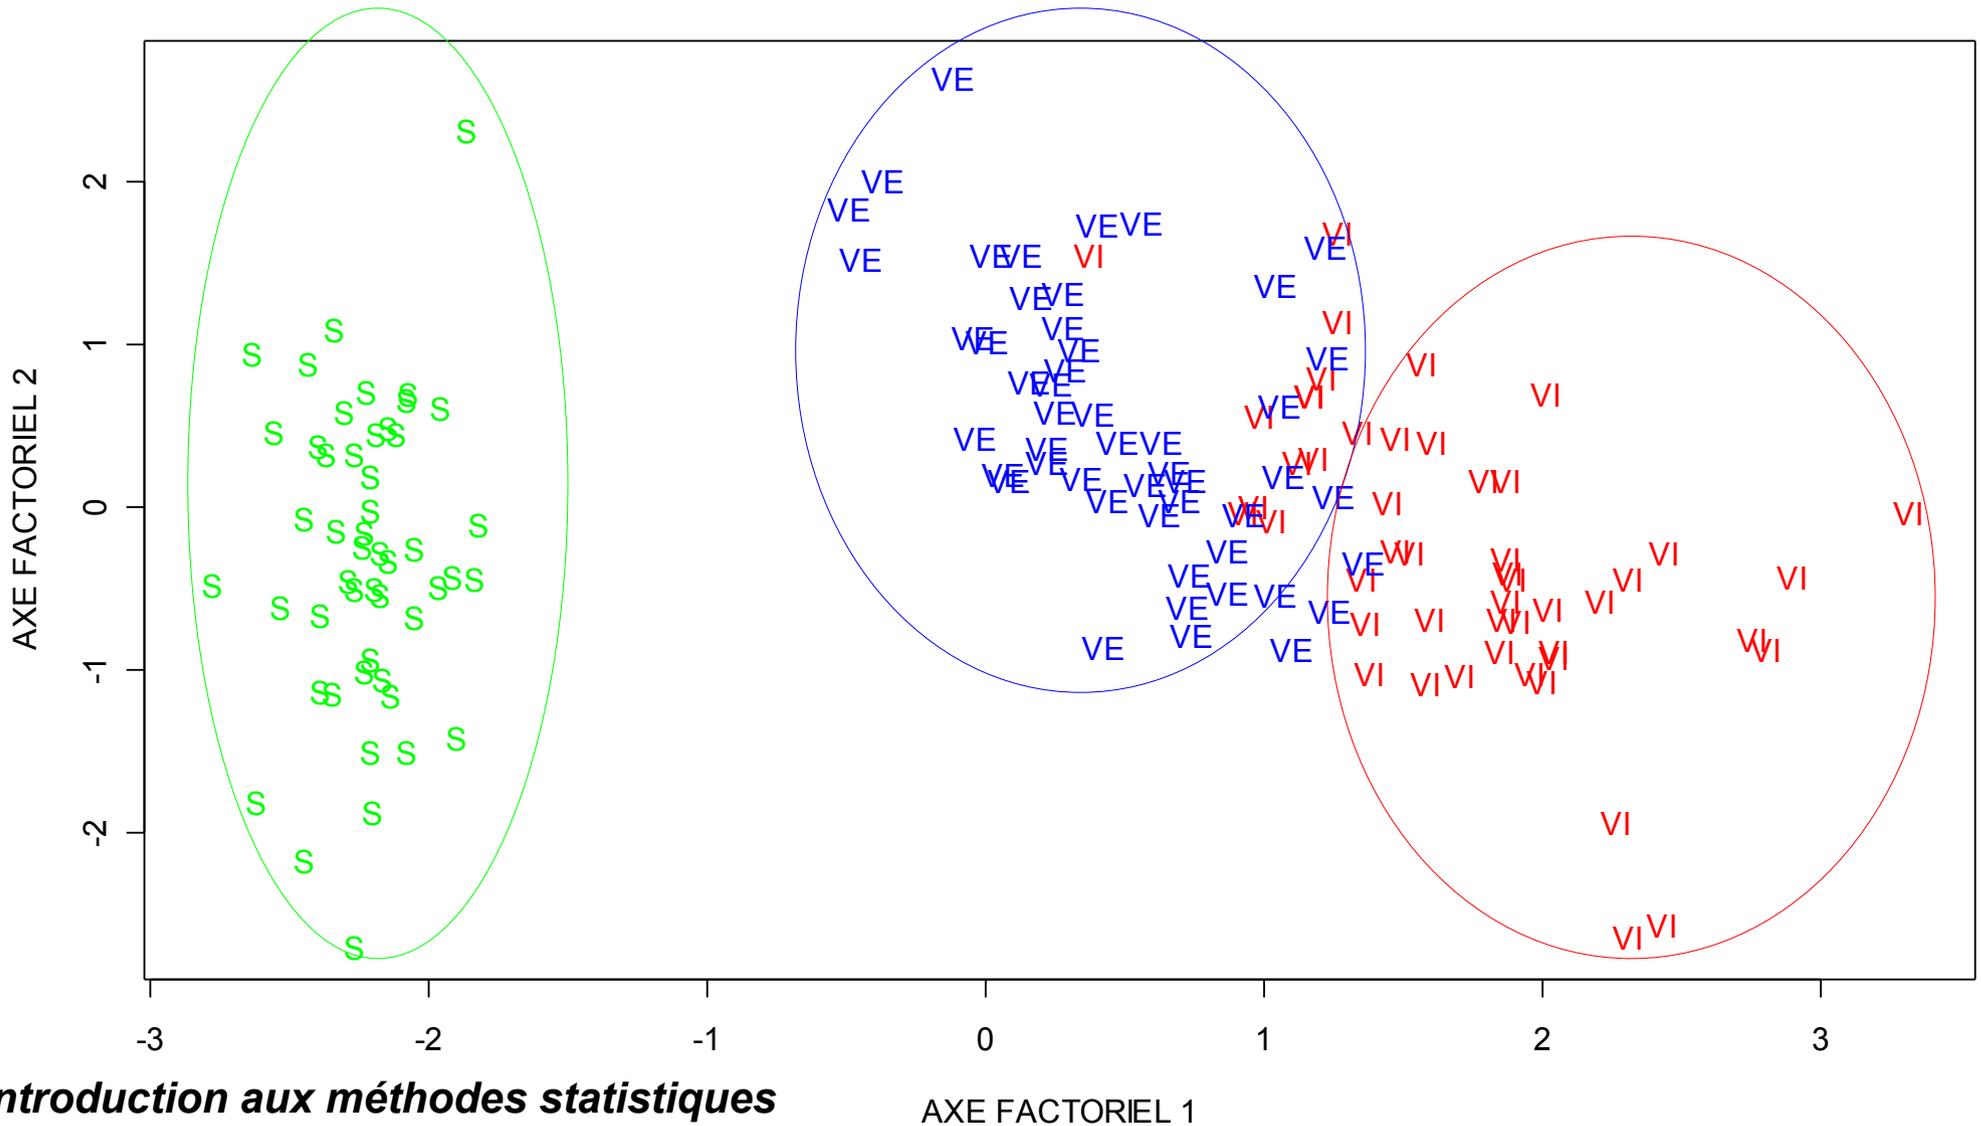
- Faible largeur de sépale



**VERSICOLOR**

- >> *Un exemple*

# Le rapport



## Petit bilan

- Possibilité de réduire de façon intéressante le nombre de variables
- Possibilité de faire des typologies uniquement à partir des graphiques

L'ACP est une technique utilisée dans beaucoup de domaines.....

## Réduction de variables

- Objectif: économiser du temps machine
  - Exemple: réduction de variables pour un logiciel de simulation de risque
- Objectif: Améliorer les précisions du modèle
  - Cas de la régression

## Résumé/Classification

- Résumé d'un échantillon
  - Des axes d'opposition dans une population
- Classification des individus dans une population
  - Trouver des groupes dans une population
  - Expliquer des groupes prédéterminés par une ACP généralisée.