

# REMISE EN CAUSE DES DIVISIONS DANS UN ALGORITHME DE CLASSIFICATION DESCENDANTE

Marie CHAVENT  
*MAB, Université Bordeaux 1*  
*351 cours de la libération*  
*33405 Bordeaux cedex*

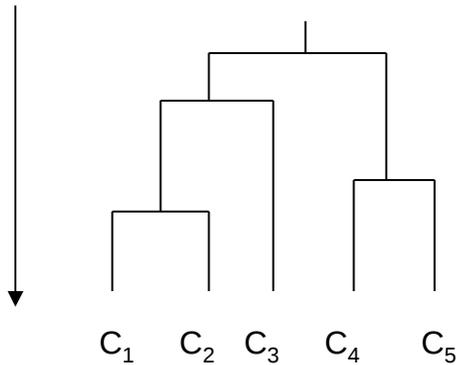
[Chavent@math.u-bordeaux.fr](mailto:Chavent@math.u-bordeaux.fr)

# Méthodes divisives

## Classification :

Approche hiérarchique descendante

Divisions

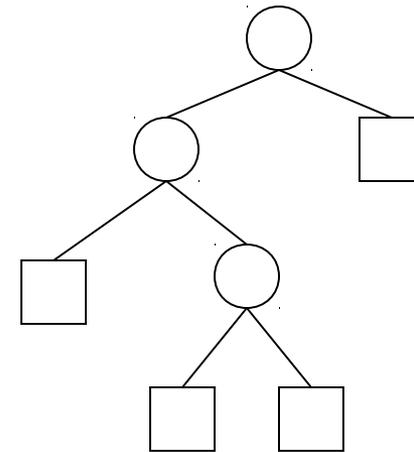


- Comment diviser une classe
- Choix de la classe à diviser

Recherche de classes homogènes et/ou bien séparées sur toutes les variables

## Discrimination :

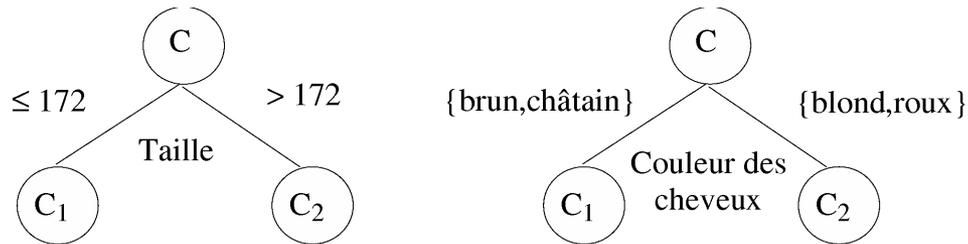
Méthodes de segmentation



Recherche de classes homogènes sur la variable à expliquer

# Classification descendante hiérarchique

## Division monothétique d'une classe



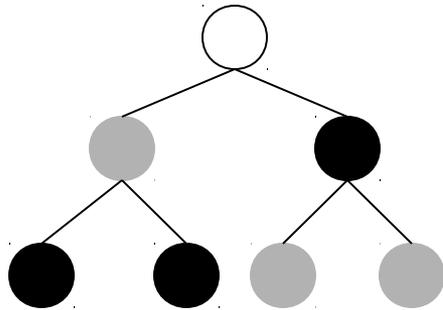
- Division en fonction d'une variable et de sa transformation binaire
- Critère d'évaluation des bi-partitions : inertie intra-classe

Autres approches :

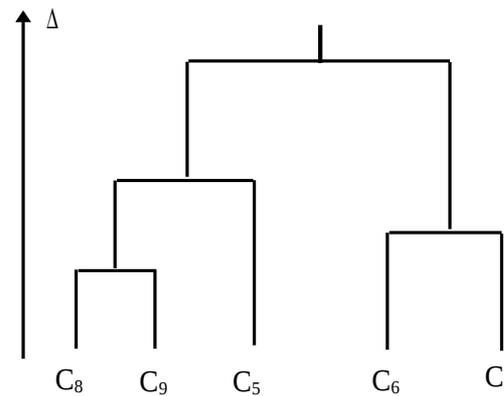
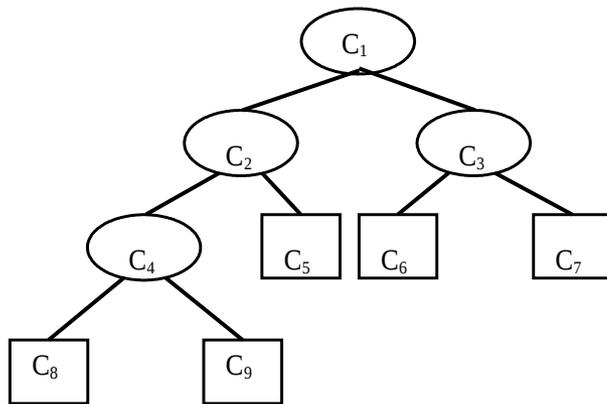
- énumération complète : Edward et Cavalli-Sforza (1965)
- heuristiques : Roux (1985), MacNaughton-Smith (1964)
- optimisation du diamètre : Guénoche, Hansen et Jaumard (1991)

# Classification descendante hiérarchique

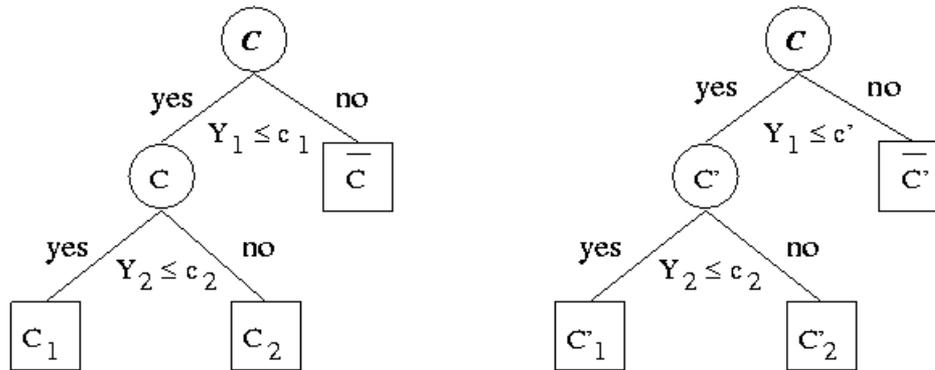
## Choix de la classe à diviser



- choix de la classe qui induit la partition de plus petite inertie intra-classe
- choix de la classe  $C$  qui maximise  $\Delta(C)=I(C)-I(C_1)-I(C_2)$

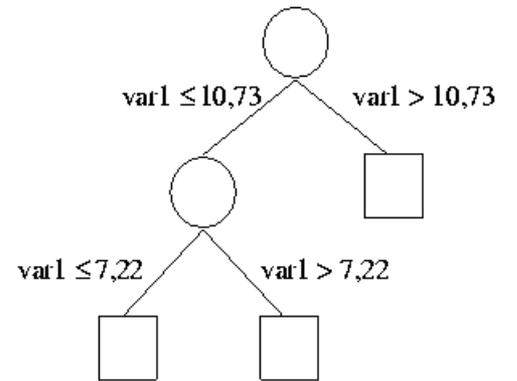
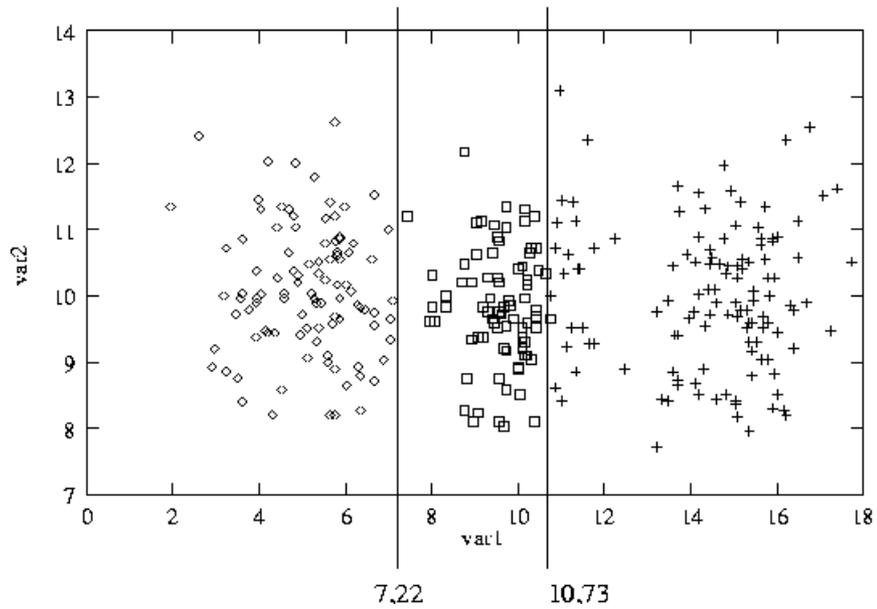


## Remise en cause d'une division

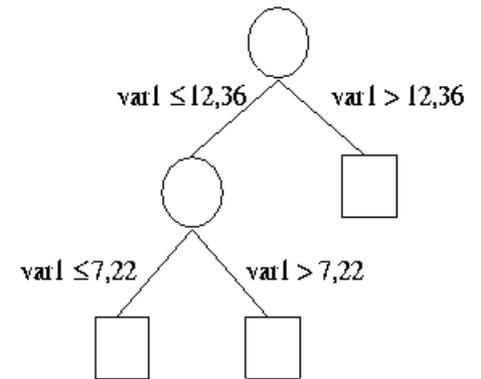
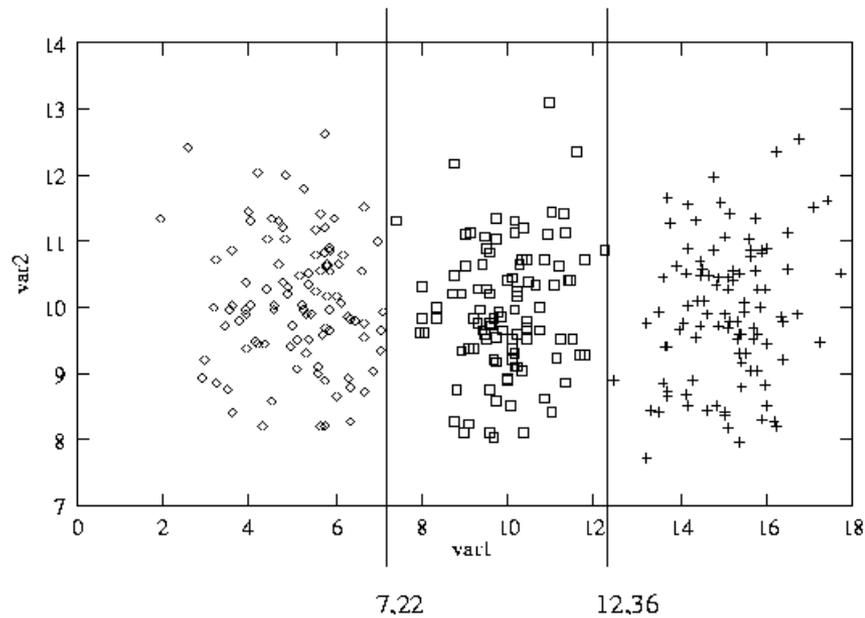


- Pour toutes les transformations binaires de  $Y_1$ , on évalue les partitions en trois classes induites par cette nouvelle variable binaire, la transformation binaire de  $Y_2$  étant fixée.
- On retient la nouvelle transformation binaire de  $Y_1$  qui induit la meilleure partition en trois classes.

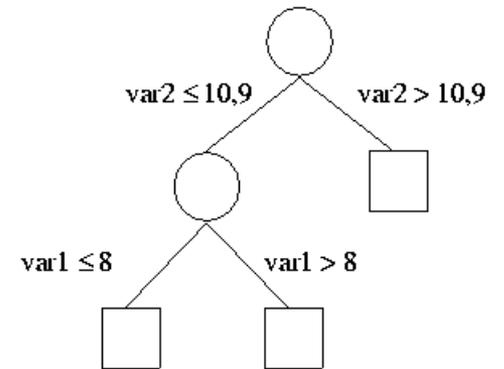
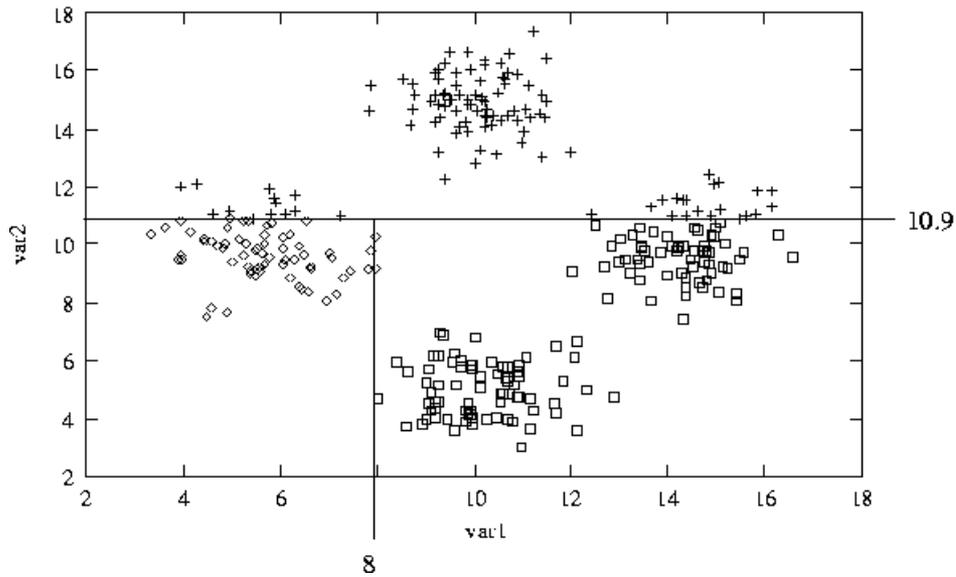
Avant :



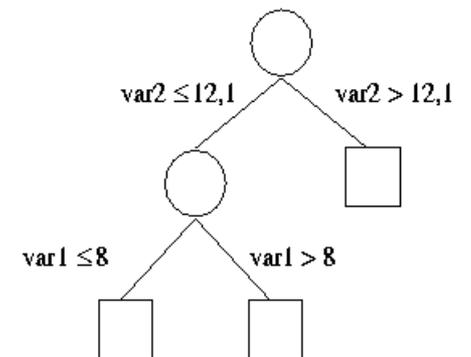
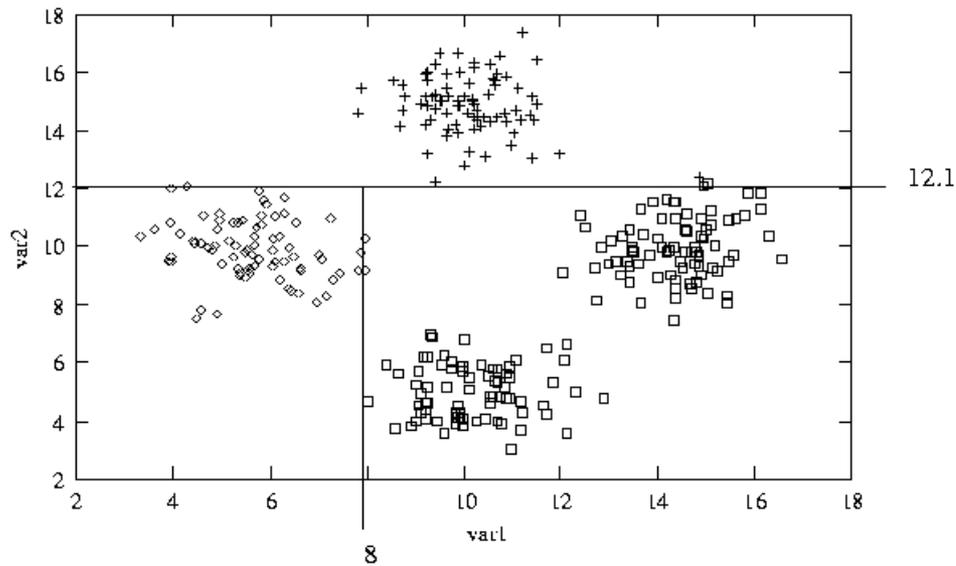
Après :



Avant :



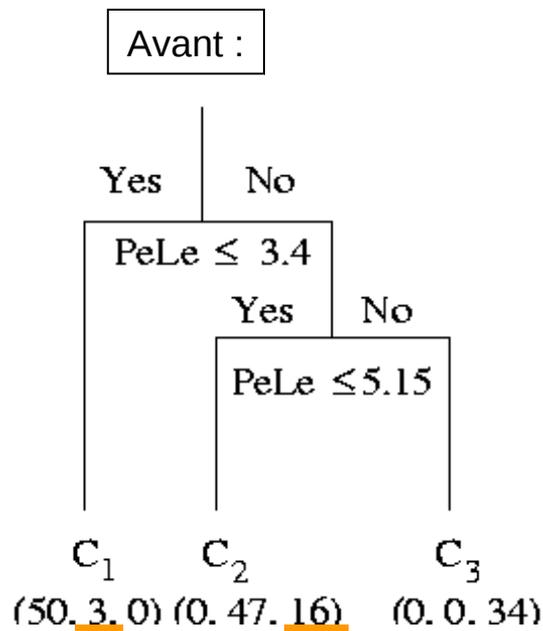
Après :



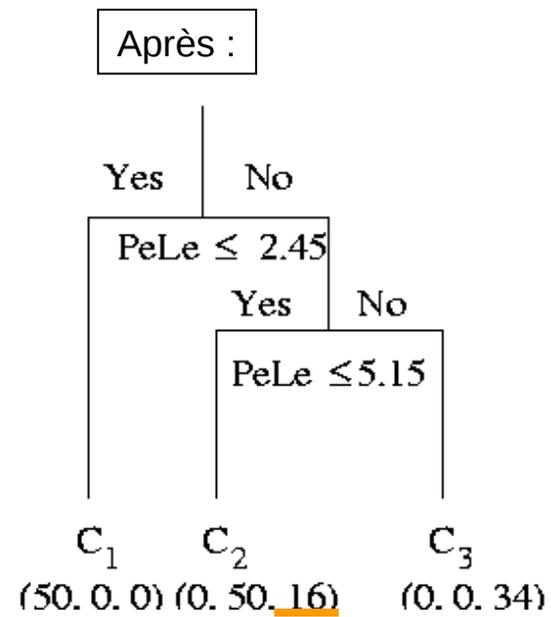
# Les Iris de Fisher

	PeLe	PeWi	SeLe	SeWi	Variété
1					Setoa
⋮					⋮
51					Versicolor
⋮					⋮
101					Virginia
⋮					⋮
150					

1. Distance euclidienne  $d_M$  avec  $M=I$



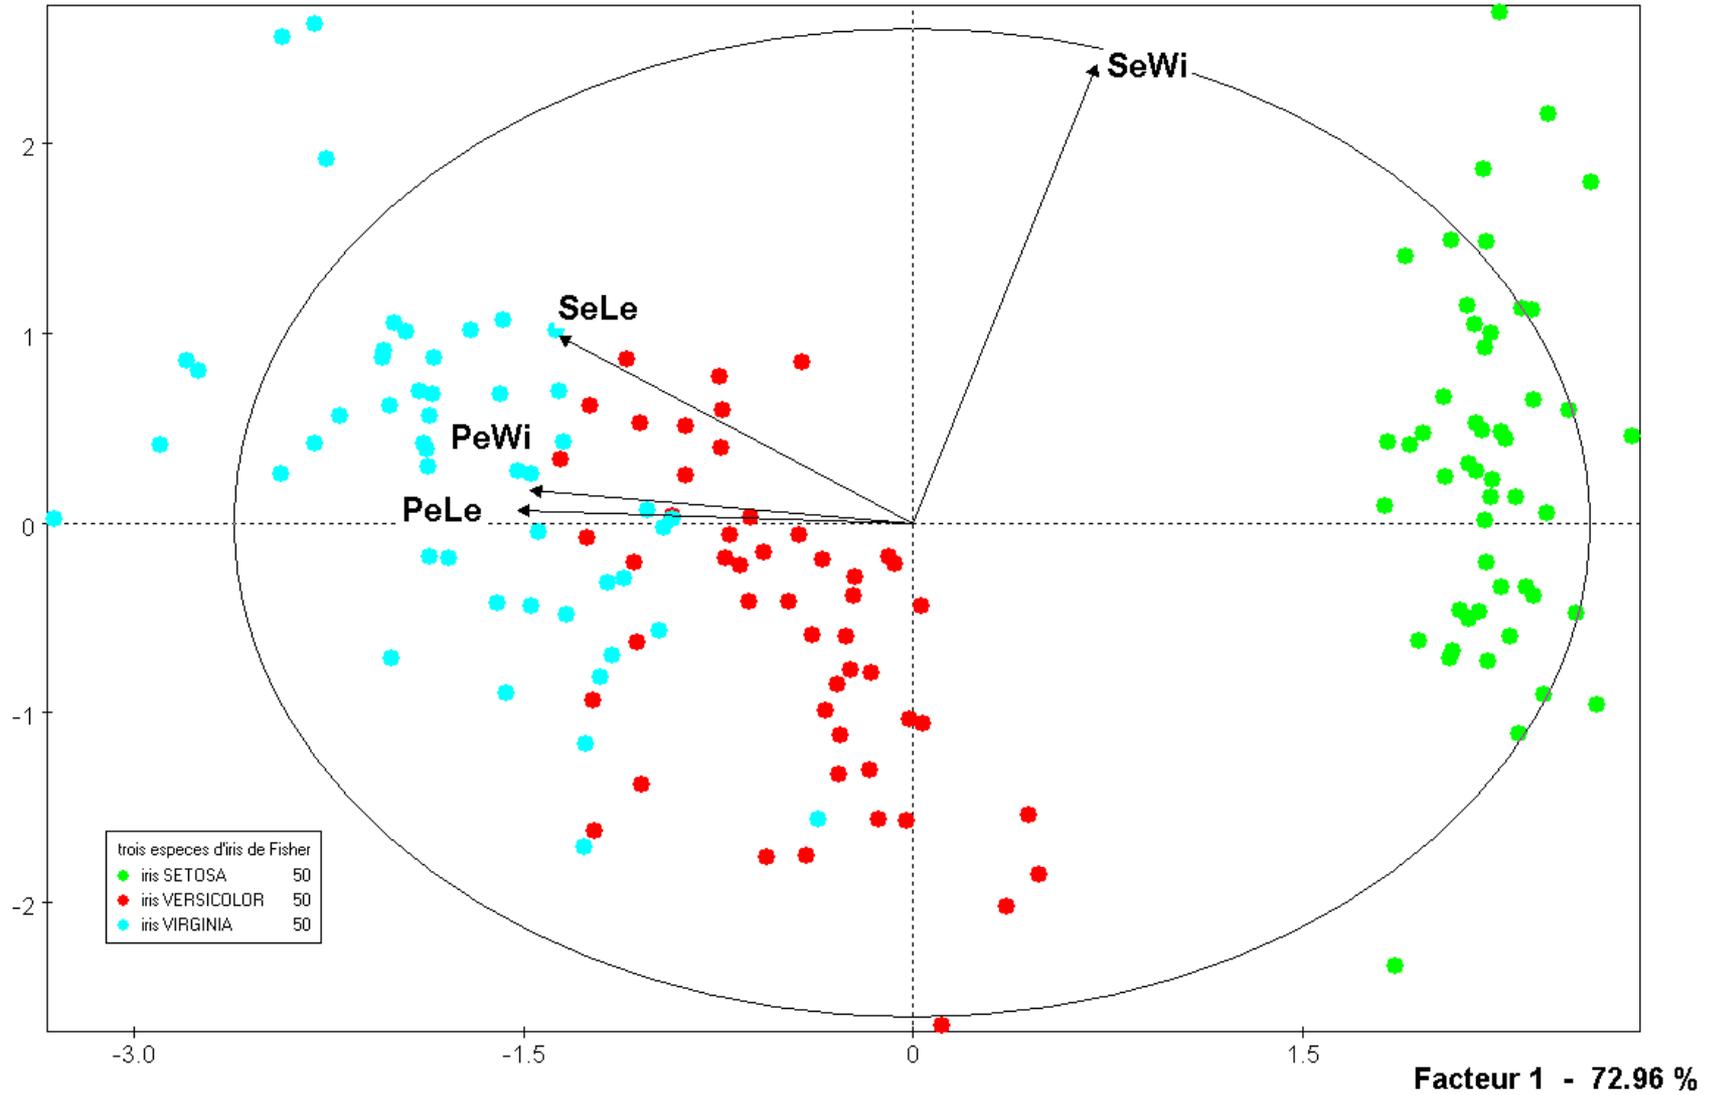
➡ 19 iris mal classés



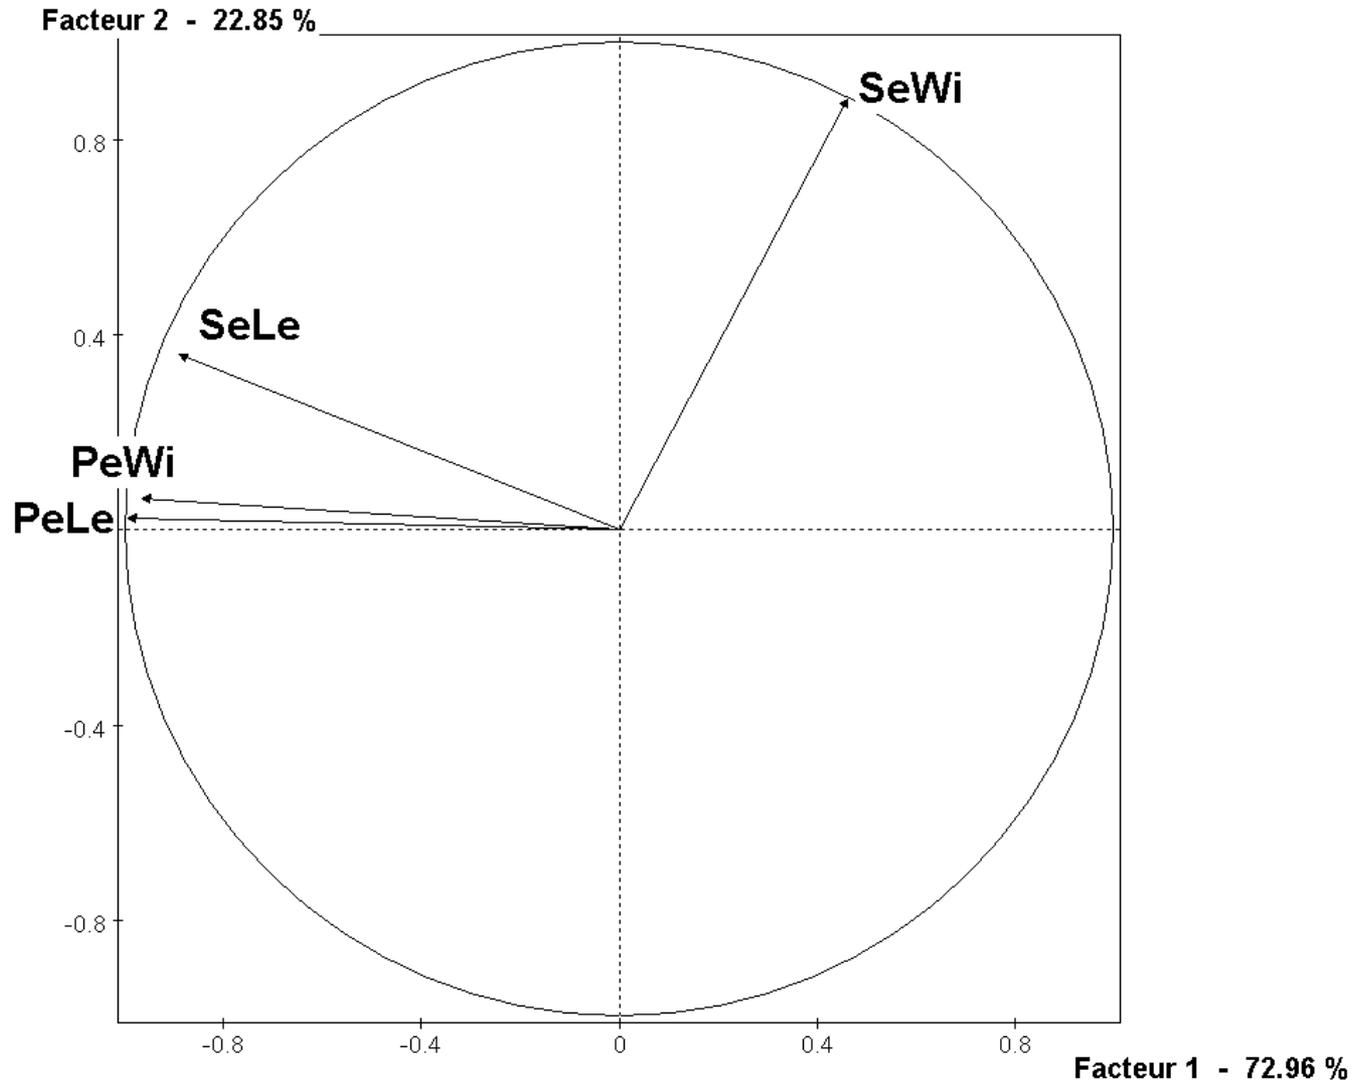
➡ 16 iris mal classés

# ACP sur les 4 variables continues

Facteur 2 - 22.85 %

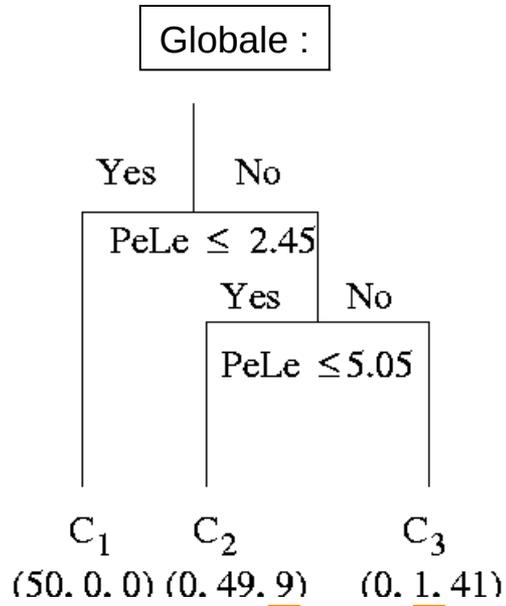


# ACP : cercle des corrélations

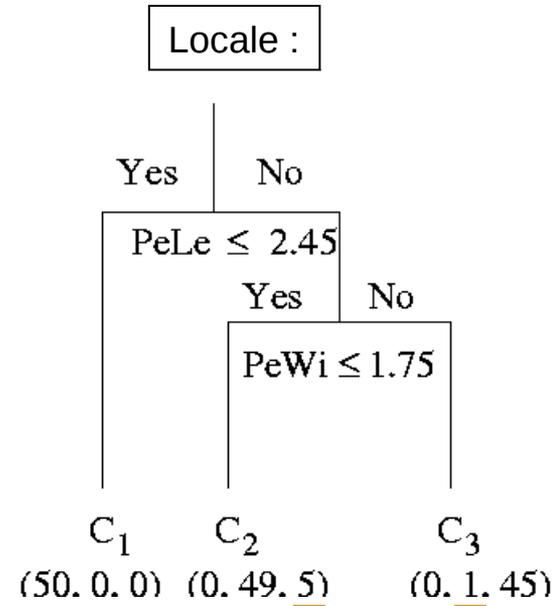


# Les Iris de Fisher

2. Distance euclidienne  $d_M$  normalisée par l'inverse de l'écart maximum,  $M = D_{1/U_i^2}$



➡ 10 iris mal classés

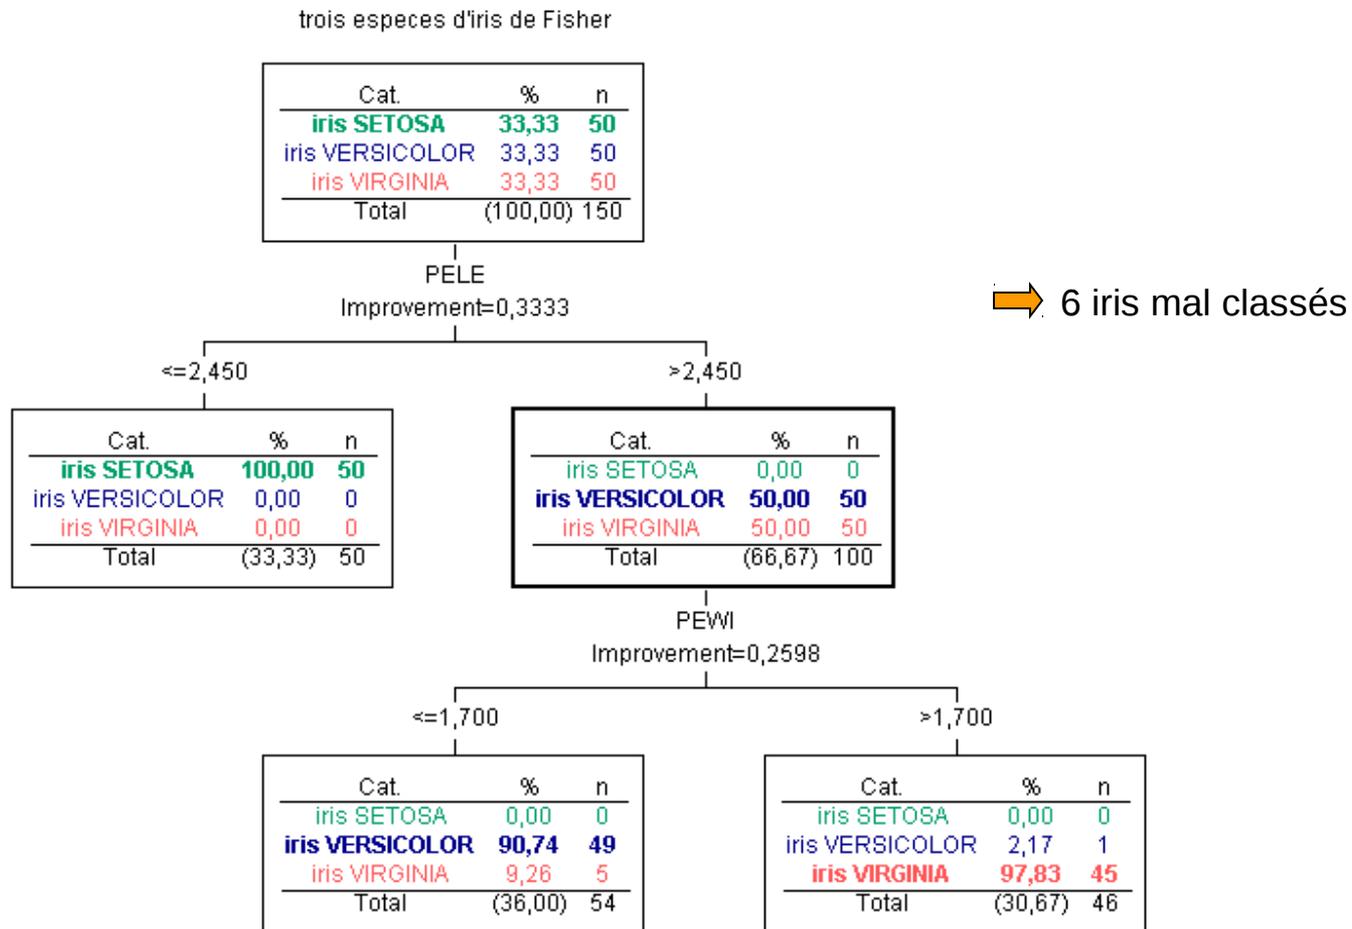


➡ 6 iris mal classés

Segmentation non supervisée ➡ 4%

	Setosa	Versicolor	Virginia
C <sub>1</sub>	50	0	0
C <sub>2</sub>	0	49	5
C <sub>3</sub>	0	1	45

# Classification And Regression Tree (CART, Breiman, Friedman Olshen and Stone, 1984)



Segmentation supervisée ⇒ 4%

## Conclusion et perspectives

- Les Iris de Fisher : segmentation non supervisée et supervisée
- Règles d'affectation permettent
  - ⇒ Interprétation monothétique des classes
  - ⇒ Réviser les coupures
  - ⇒ Échantillonner et affecter
- Données symboliques
- Divisions non binaires, affectation floues, validation, règles d'arrêt et élagage...