

HDclassif : un package R pour la classification non-supervisée de données en grande dimension

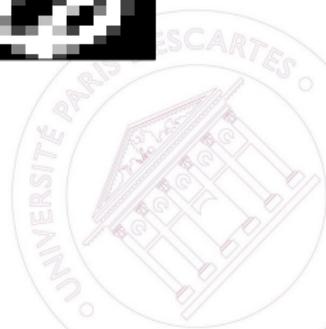
Laurent Bergé

MAP5 (UMR 8145), Université Paris-Descartes & Sorbonne Paris Cité

GREThA (UMR 5113), University of Bordeaux

10 Juin 2016, Journée R, Muséum National D'Histoire Naturelle, Paris

Qu'est-ce que la classification non-supervisée ?



Qu'est-ce que la classification non-supervisée ?



But de la classification non-supervisée

- 1 Catégoriser des observations dans des groupes cohérents
- 2 (optionnel) Avoir le “bon” nombre de groupes



Pourquoi faire de la classification non-supervisée ?

- **Synthétiser** des données complexes et volumineuses
- Partitionner les individus en des classes **homogènes** et **interprétables**



Schématisation du problème

Classification non-supervisée

- **input:** n observations $x_i \in \mathbb{R}^p$
- **output:** la partition $\{z_1, \dots, z_n\}$ (et le nombre de classes K)



Plan

1 Modèle de Mélange Gaussien

2 Modèles HDDC

3 Package HDclassif



Modèle de Mélange Gaussien

Modèle génératif:

Chaque observation i est générée de façon *indépendante* de la façon suivante :

- 1 $z_i \sim \mathcal{M}(\pi_1, \dots, \pi_K)$
- 2 Sachant $z_i = k$:

$$x_i \sim \mathcal{N}(\mu_k, \Sigma_k)$$

Paramètres du modèle

Pour chaque classe $k \in \{1, \dots, K\}$:

- π_k proportion
- μ_k vecteur moyenne
- Σ_k matrice de variance-covariance

Modèle de Mélange Gaussien

Modèle génératif:

Chaque observation i est générée de façon *indépendante* de la façon suivante :

- 1 $z_i \sim \mathcal{M}(\pi_1, \dots, \pi_K)$
- 2 Sachant $z_i = k$:

$$x_i \sim \mathcal{N}(\mu_k, \Sigma_k)$$

Paramètres du modèle

Pour chaque classe $k \in \{1, \dots, K\}$:

- π_k proportion
- μ_k vecteur moyenne
- Σ_k matrice de variance-covariance

Modèle de Mélange Gaussien

Modèle génératif:

Chaque observation i est générée de façon *indépendante* de la façon suivante :

- 1 $z_i \sim \mathcal{M}(\pi_1, \dots, \pi_K)$
- 2 Sachant $z_i = k$:

$$x_i \sim \mathcal{N}(\mu_k, \Sigma_k)$$

Paramètres du modèle

Pour chaque classe $k \in \{1, \dots, K\}$:

- π_k proportion
- μ_k vecteur moyenne
- Σ_k matrice de variance-covariance

Modèle de Mélange Gaussien

Modèle génératif:

Chaque observation i est générée de façon *indépendante* de la façon suivante :

- 1 $z_i \sim \mathcal{M}(\pi_1, \dots, \pi_K)$
- 2 Sachant $z_i = k$:

$$x_i \sim \mathcal{N}(\mu_k, \Sigma_k)$$

Paramètres du modèle

Pour chaque classe $k \in \{1, \dots, K\}$:

- π_k proportion
- μ_k vecteur moyenne
- Σ_k matrice de variance-covariance

Estimateurs

Probabilité d'observer x_i sachant $z_i = k$:

$$\begin{aligned} P(x_i | z_i = k, \mu_k, \Sigma_k) \\ &= f(x_i | \mu_k, \Sigma_k) \\ &= \exp\left((x_i - \mu_k)^t \Sigma_k^{-1} (x_i - \mu_k) + \log(\det \Sigma_k) + C^{te}\right) \end{aligned}$$

Estimateurs

Les estimateurs $\hat{\mu}_k$ et $\hat{\Sigma}_k$ sont les paramètres qui maximisent la vraisemblance.



Règle de Bayes

Si on ne connaît pas z_i :

$$P(z_i = k | x_i, \mu, \Sigma) = \frac{\pi_k f(x_i | \mu_k, \Sigma_k)}{\sum_{k'} \pi_{k'} f(x_i | \mu_{k'}, \Sigma_{k'})}$$
$$\equiv t_{ik}$$

Par définition: $\sum_k t_{ik} = 1$.



Algorithme EM

- 1 Initialisation des z_i
- 2 Calcul des paramètres (π_k , μ_k et Σ_k) sachant z_i
- 3 Boucler jusqu'à convergence:
 - Calcul des t_{ik}
 - Estimation des paramètres (π_k , μ_k et Σ_k) sachant t_{ik}



Algorithme EM

- 1 Initialisation des z_i
- 2 Calcul des paramètres (π_k , μ_k et Σ_k) sachant z_i
- 3 Boucler jusqu'à convergence:
 - Calcul des t_{ik}
 - Estimation des paramètres (π_k , μ_k et Σ_k) sachant t_{ik}



Algorithme EM

- 1 Initialisation des z_i
- 2 Calcul des paramètres (π_k , μ_k et Σ_k) sachant z_i
- 3 Boucler jusqu'à convergence:
 - 1 Calcul des t_{ik}
 - 2 Estimation des paramètres (π_k , μ_k et Σ_k) sachant t_{ik}



Algorithme EM

- 1 Initialisation des z_i
- 2 Calcul des paramètres (π_k , μ_k et Σ_k) sachant z_i
- 3 Boucler jusqu'à convergence:
 - 1 Calcul des t_{ik}
 - 2 Estimation des paramètres (π_k , μ_k et Σ_k) sachant t_{ik}



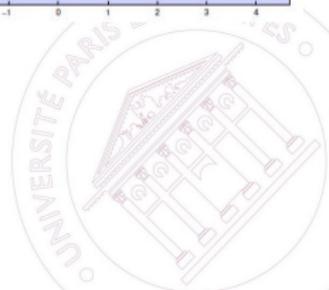
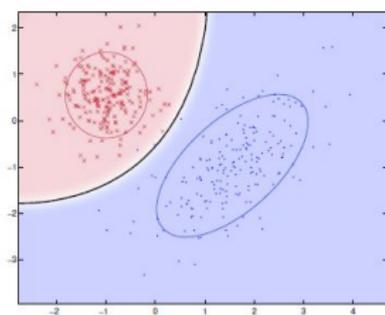
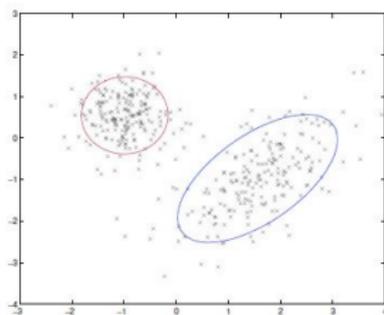
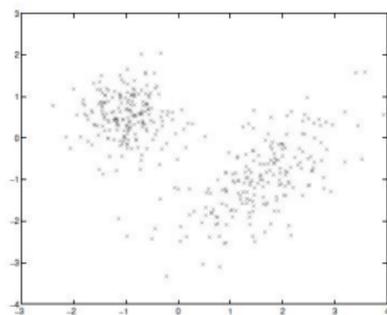
Algorithme EM

- 1 Initialisation des z_i
- 2 Calcul des paramètres (π_k , μ_k et Σ_k) sachant z_i
- 3 Boucler jusqu'à convergence:
 - 1 Calcul des t_{ik}
 - 2 Estimation des paramètres (π_k , μ_k et Σ_k) sachant t_{ik}



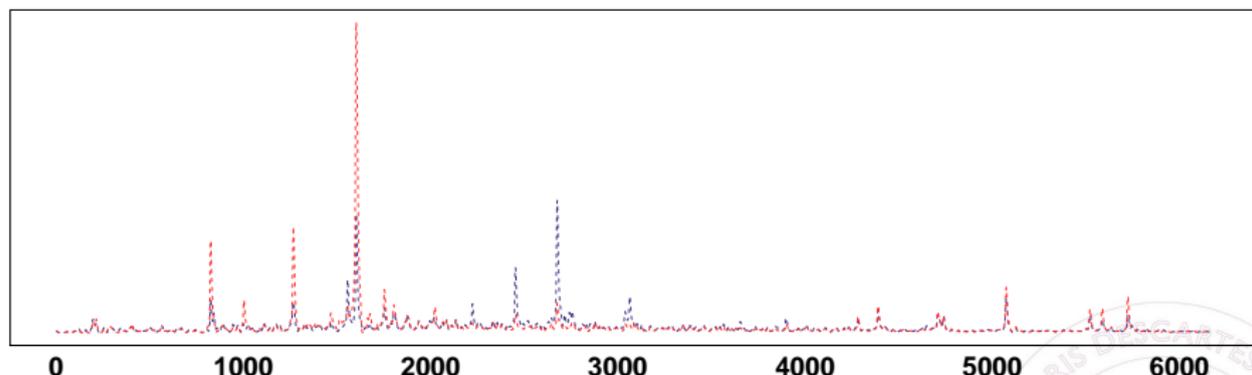
Illustration Modèle de Mélange Gaussien

Classification non-supervisée :



Difficultés du monde réel

- Les données réelles sont souvent en grande dimension (p est très grand)
- Le nombre d'observation est souvent faible ($n \ll p$)

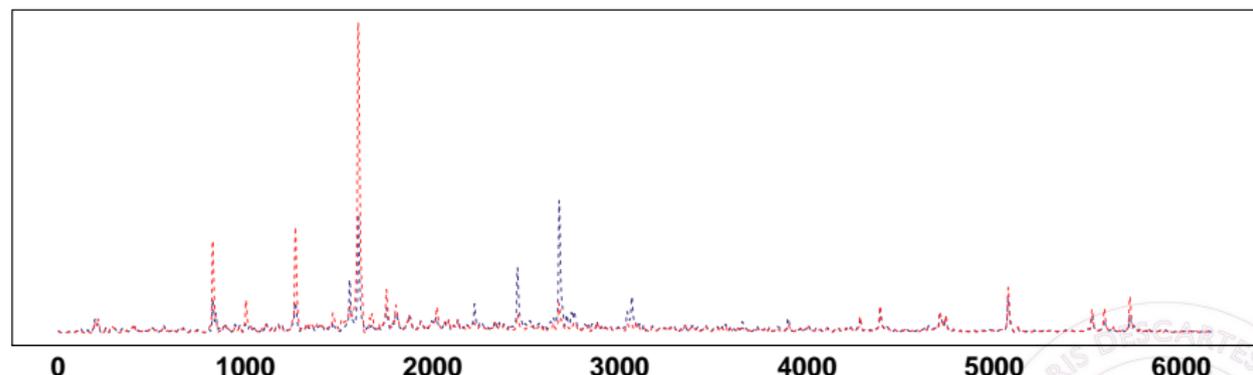


Problèmes

- Quand p est grand \Rightarrow nombre de paramètres explose, complexité p^2
- Quand $n < p \Rightarrow$ modèle pas estimable (dû à l'estimation de Σ_k)

Difficultés du monde réel

- Les données réelles sont souvent en grande dimension (p est très grand)
- Le nombre d'observation est souvent faible ($n \ll p$)



Problèmes

- Quand p est grand \Rightarrow nombre de paramètres explose, complexité p^2
- Quand $n < p \Rightarrow$ modèle pas estimable (dû à l'estimation de Σ_k)

Plan

- 1 Modèle de Mélange Gaussien
- 2 Modèles HDDC
- 3 Package HDclassif



Décomposition spectrale

- Décomposition spectrale de Σ_k :

$$\Sigma_k = Q_k \Delta_k Q_k^t,$$

avec:

- Q_k la matrice des **vecteurs propres** de Σ_k et $Q_k^{-1} = Q_k^t$
- Δ_k la matrice diagonale des **valeurs propres** de Σ_k :

$$\Delta_k = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{pmatrix},$$

$$\lambda_1 > \lambda_2 > \dots > \lambda_p.$$



Décomposition spectrale

- Décomposition spectrale de Σ_k :

$$\Sigma_k = Q_k \Delta_k Q_k^t,$$

avec:

- Q_k la matrice des **vecteurs propres** de Σ_k et $Q_k^{-1} = Q_k^t$
- Δ_k la matrice diagonale des **valeurs propres** de Σ_k :

$$\Delta_k = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{pmatrix},$$

$$\lambda_1 > \lambda_2 > \dots > \lambda_p.$$



Décomposition spectrale

- Décomposition spectrale de Σ_k :

$$\Sigma_k = Q_k \Delta_k Q_k^t,$$

avec:

- Q_k la matrice des **vecteurs propres** de Σ_k et $Q_k^{-1} = Q_k^t$
- Δ_k la matrice diagonale des **valeurs propres** de Σ_k :

$$\Delta_k = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{pmatrix},$$

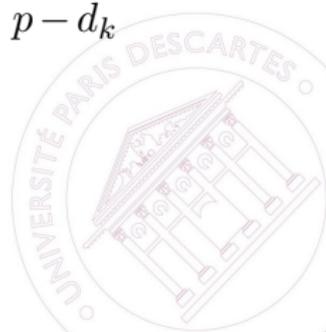
$$\lambda_1 > \lambda_2 > \dots > \lambda_p.$$



Re-paramétrisation du modèle de mélange

Hypothèse sur Δ_k :

$$\Delta_k = \left(\begin{array}{ccccccc} a_{k1} & 0 & & & & & 0 \\ 0 & \ddots & 0 & & & & \\ & 0 & a_{kd_k} & & & & \\ & & & b_k & 0 & & \\ & & & 0 & \ddots & 0 & \\ 0 & & & & 0 & & b_k \end{array} \right) \left. \begin{array}{l} \\ \\ \\ \\ \\ \end{array} \right\} \begin{array}{l} d_k \\ \\ \\ p - d_k \end{array}$$



Paramètres du modèle

Pour chaque classe k :

- π_k , proportion
- μ_k , vecteur moyenne
- d_k , nombre de **dimensions intrinsèques** de la classe k
- a_{kj} , $j^{\text{ème}}$ valeur propre de Σ_k ($j \in \{1, \dots, d_k\}$)
- b_k , «bruit» de la classe
- \tilde{Q}_k : seulement d_k **premiers vecteurs propres**



Le modèle $[a_{kj}b_kQ_kd_k]$ et ses sous-modèles

Le modèle général peut être régularisé:

- Au sein de la classe:

- ▶ $a_{k1} = \dots = a_{kd_k} = a_k$

- Entre les classes:

- ▶ $d_1 = \dots = d_K = d$

- ▶ $Q_1 = \dots = Q_K = Q$

- ▶ $b_1 = \dots = b_K = b$

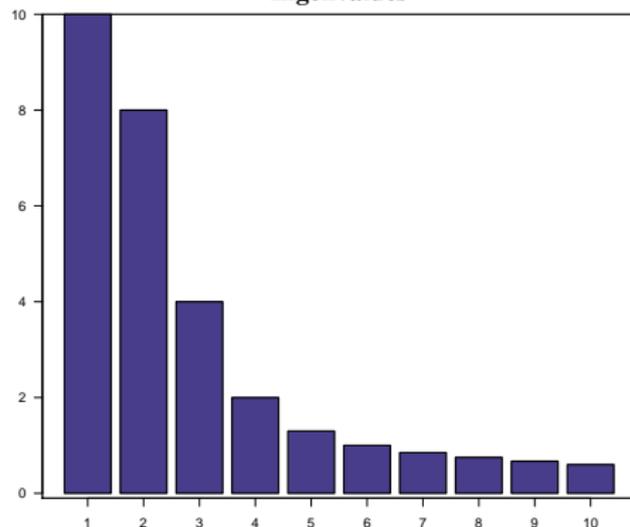
- ▶ $a_{11} = \dots = a_{K1} = a_1$

⇒ 14 modèles

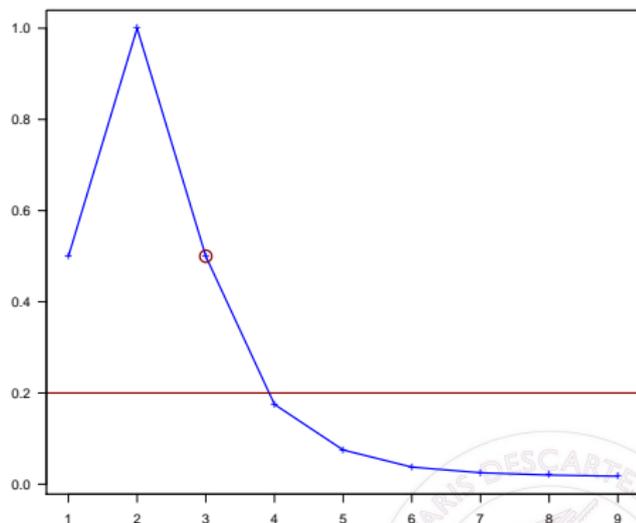


Estimation de d_k

Eigenvalues

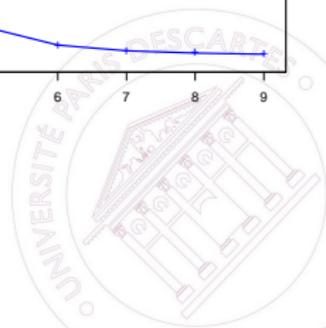


Cattel's scree-test



⇒ on peut faire varier le seuil

- d_k peut être sélectionné par le BIC



Estimation du nombre de groupes K

C'est un problème difficile. Néanmoins différents critères existent:

- BIC (Bayesian Information Criterion)
- ICL (Information Classification Likelihood)
- Heuristique de pente



Plan

- 1 Modèle de Mélange Gaussien
- 2 Modèles HDDC
- 3 Package HDclassif



Package HDclassif: inputs

La fonction `hhdc` prends en entrée:

- `model`: Le nom d'un des 14 modèles. Par défaut "AkjBkQkDk". Peut être un vecteur.
- `K`: Le **nombre de classes**. Peut être un vecteur.
- `threshold`: Le **seuil pour le scree-test** de Cattell. Peut être un vecteur.
- `criterion`: Le critère de sélection (BIC, ICL ou slope).
- `algo`: L'**algorithme** à utiliser (EM, SEM ou CEM).
- `init`: Le type d'**initialisation** (random, kmeans, ...).
- `mc.cores`: Nombre de coeurs à utiliser pour le **calcul en parallèle**.



Package HDclassif: autres fonctions

- La fonction `predict` calcule la probabilité d'appartenance d'une observation à chacune des classes en fonction de paramètres estimés par `hddc`.
- La fonction `plot` montre la sélection des dimensions intrinsèques.



Package HDclassif: output

La fonction `hddc` donne en sortie:

- `prms`: L'ensemble des paramètres estimés (π_k , μ_k , d_k , a_{kj} , b_k et \tilde{Q}_k).
- `Loglik`, `BIC`, `ICL`, `slope`: La valeur de ces critères pour le modèle.
- `all_results`: Tous les modèles qui ont été estimés.
- `class`: La classe associée à chaque observation.
- `posterior`: La matrice $n \times K$ des t_{ik} .



Exemple en direct

Avec tous les risques inhérents !



Conclusion

HDclassif:

- Permet la classification non-supervisée (et supervisée) de façon **efficace en grande dimension**
- Est particulièrement efficace quand $n \ll p$
- Est flexible (variété de modèles régularisés)
- Permet une sélection de modèle parallélisable
- Tout commentaire est bienvenu 😊



Merci !

Merci de votre attention !

