

K-means et mélanges de gaussiennes

Master parcours SSD - UE Apprentissage Statistique I

Pierre Mahé - bioMérieux & Université de Grenoble-Alpes

Rappels : clustering

Clustering - qualité

But du clustering :

- ▶ déterminer des ensembles de points **proches** ...
- ▶ ... qui soient **distants** les uns des autres

Clustering - qualité

But du clustering :

- ▶ déterminer des ensembles de points proches ...
- ▶ ... qui soient distants les uns des autres

Fonction objective (à minimiser) = dispersion "intra" cluster

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

- ▶ K = nombre de clusters
- ▶ C = clustering : $C(i) = k \Leftrightarrow x_i \in \text{cluster } k$
- ▶ $d(x, y)$ = distance/disimilarité entre x et y

Clustering - qualité

But du clustering :

- ▶ déterminer des ensembles de points **proches** ...
- ▶ ... qui soient **distants** les uns des autres

Fonction objective (à minimiser) = dispersion "intra" cluster

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

- ▶ K = nombre de clusters
- ▶ C = clustering : $C(i) = k \Leftrightarrow x_i \in \text{cluster } k$
- ▶ $d(x, y)$ = distance/disimilarité entre x et y

\Rightarrow problème **combinatoire**, présence de **minima locaux**.

Clustering - qualité

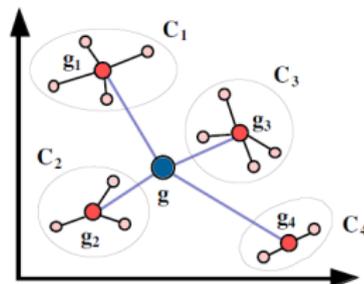
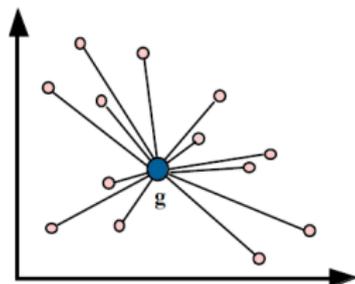
Rappels

k-means

Modèles de
mélange

Conclusion

Références



► dispersion totale = dispersion intra + dispersion inter :

$$\begin{aligned} \sum_{i,j=1}^n d(x_i, x_j) &= \sum_{k=1}^K \sum_{i:C(i)=k} \left(\sum_{j:C(j)=k} d(x_i, x_j) + \sum_{j:C(j) \neq k} d(x_i, x_j) \right) \\ &= \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j) + \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j) \neq k} d(x_i, x_j) \end{aligned}$$

Clustering - qualité

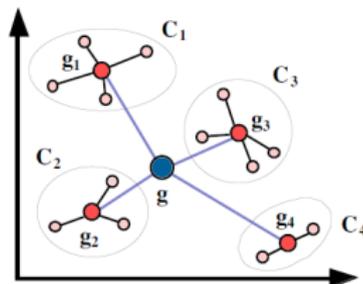
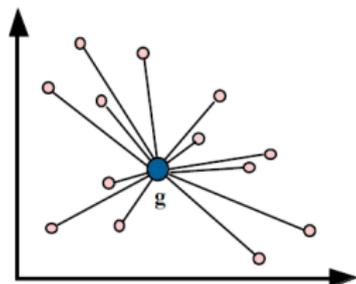
Rappels

k-means

Modèles de
mélange

Conclusion

Références



- ▶ dispersion totale = dispersion intra + dispersion inter :

$$\begin{aligned} \sum_{i,j=1}^n d(x_i, x_j) &= \sum_{k=1}^K \sum_{i:C(i)=k} \left(\sum_{j:C(j)=k} d(x_i, x_j) + \sum_{j:C(j) \neq k} d(x_i, x_j) \right) \\ &= \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j) + \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j) \neq k} d(x_i, x_j) \end{aligned}$$

- ▶ dispersion intra = dispersion totale - dispersion inter

⇒ minimiser intra équivalent à maximiser inter

Clustering et optimisation

Question : minimiser

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

Clustering et optimisation

Question : minimiser

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

Approche directe (gloutonne) :

1. considérer toutes les partitions possibles
2. retenir la meilleure

Rappels

[k-means](#)[Modèles de
mélange](#)[Conclusion](#)[Références](#)

Clustering et optimisation

Question : minimiser

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

Approche directe (gloutonne) :

1. considérer toutes les partitions possibles
2. retenir la meilleure

Problème combinatoire : le nombre de partitions augmente exponentiellement avec n

- ▶ e.g., 10 observations / 4 clusters : 34105 partitions possibles
- ▶ formellement :

$$\frac{1}{K!} \sum_{k=1}^K (-1)^{K-k} C_k^K k^n$$

Clustering et optimisation

Stratégie : approximer le critère à optimiser

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

Clustering et optimisation

Stratégie : approximer le critère à optimiser

$$W(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

Algorithme k-means :

- ▶ s'appuie sur la **distance Euclidienne** : $d(x_i, x_j) = \|x_i - x_j\|^2$
- ▶ considère le critère :

$$W_{SS}(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \|x_i - \mu_k\|^2, \quad \text{où } \mu_k = \frac{1}{n_k} \sum_{i:C(i)=k} x_i.$$

⇒ **Objectif** : minimiser la distance aux **centres des clusters**

- ▶ $\{\mu_k\}_{k=1, \dots, K}$ = **centroïdes**

Algorithme k -means et optimisation

Avec la **distance Euclidienne** on a (au sein du cluster k) :

$$\sum_{i:C(i)=k} \|x_i - \mu_k\|^2 = \frac{1}{2} \times \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} \|x_i - x_j\|^2$$

Rappels

[k-means](#)

[Modèles de mélange](#)

[Conclusion](#)

[Références](#)

Algorithme k -means et optimisation

Avec la **distance Euclidienne** on a (au sein du cluster k) :

$$\sum_{i:C(i)=k} \|x_i - \mu_k\|^2 = \frac{1}{2} \times \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} \|x_i - x_j\|^2$$

Le critère considéré par k -means est donc :

$$\begin{aligned} W_{SS}(C) &= \sum_{k=1}^K \frac{1}{2} \times \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} \|x_i - x_j\|^2 \\ &= \frac{1}{2} \sum_{k=1}^K \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j) \end{aligned}$$

Rappels

[k-means](#)[Modèles de mélange](#)[Conclusion](#)[Références](#)

Algorithme k -means et optimisation

Avec la **distance Euclidienne** on a (au sein du cluster k) :

$$\sum_{i:C(i)=k} \|x_i - \mu_k\|^2 = \frac{1}{2} \times \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} \|x_i - x_j\|^2$$

Le critère considéré par k -means est donc :

$$\begin{aligned} W_{SS}(C) &= \sum_{k=1}^K \frac{1}{2} \times \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} \|x_i - x_j\|^2 \\ &= \frac{1}{2} \sum_{k=1}^K \frac{1}{n_k} \sum_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j) \end{aligned}$$

$\Rightarrow W_{SS}(C) =$ (total) **within sum of squares**

Rappels

[k-means](#)[Modèles de mélange](#)[Conclusion](#)[Références](#)

Algorithme *k*-means

k-means : objectif

Objectif : pour un nombre de clusters K fixé, minimiser

$$W_{SS}(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \|x_i - \mu_k\|^2,$$

où $\mu_k = \frac{1}{n_k} \sum_{i:C(i)=k} x_i.$

k-means : objectif

Objectif : pour un nombre de clusters K fixé, minimiser

$$W_{SS}(C) = \sum_{k=1}^K \sum_{i:C(i)=k} \|x_i - \mu_k\|^2,$$

où $\mu_k = \frac{1}{n_k} \sum_{i:C(i)=k} x_i$.

Terminologie : $W_{SS}(C) = \sum_{k=1}^K W_{SS}^k(C)$

- ▶ $W_{SS}(C)$ = (total) **within sum of squares**
- ▶ $W_{SS}^k(C)$ = **within sum of squares** du cluster k

Algorithme k -means

1. **Initialisation** : affecter les points aléatoirement aux clusters
2. **Itérer** la procédure suivante :
 - 2.1 calculer les **centroïdes** des clusters :

$$\mu_k^{(t)} = \frac{1}{n_k} \sum_{i: C(i)^{(t)}=k} x_i$$

- 2.2 affecter chaque point au cluster dont le centroïde est le plus proche :

$$C(i)^{(t+1)} = \arg \min_{k=1, \dots, K} \|x_i - \mu_k^{(t)}\|$$

Algorithme k -means

1. **Initialisation** : affecter les points aléatoirement aux clusters
2. **Itérer** la procédure suivante :
 - 2.1 calculer les **centroïdes** des clusters :

$$\mu_k^{(t)} = \frac{1}{n_k} \sum_{i: C(i)^{(t)}=k} x_i$$

- 2.2 affecter chaque point au cluster dont le centroïde est le plus proche :

$$C(i)^{(t+1)} = \arg \min_{k=1, \dots, K} \|x_i - \mu_k^{(t)}\|$$

Critère d'arrêt :

- ▶ **convergence** : les affectations ne changent plus
 - ▶ i.e., $C(i)^{(t+1)} = C(i)^{(t)}$, $\forall i = 1, \dots, n$.
- ▶ **nombre maximum d'itérations** atteint

Deux remarques importantes :

1. Pré-requis : nombre de clusters K
2. L'algorithme converge
 - ▶ i.e., on a bien $C(j)^{(t+1)} = C(j)^{(t)}$ pour un t fini

Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

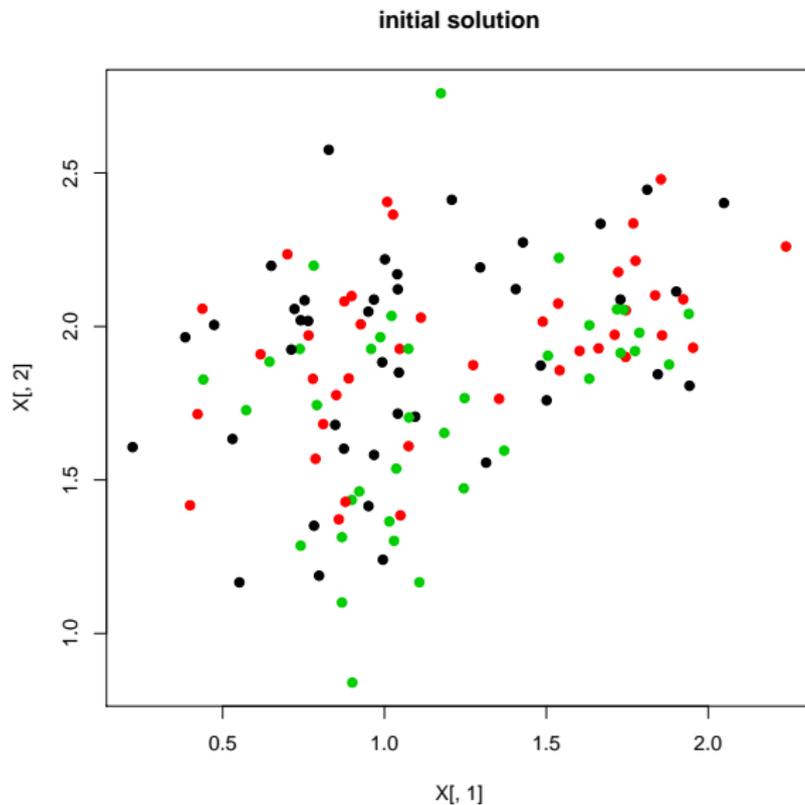
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

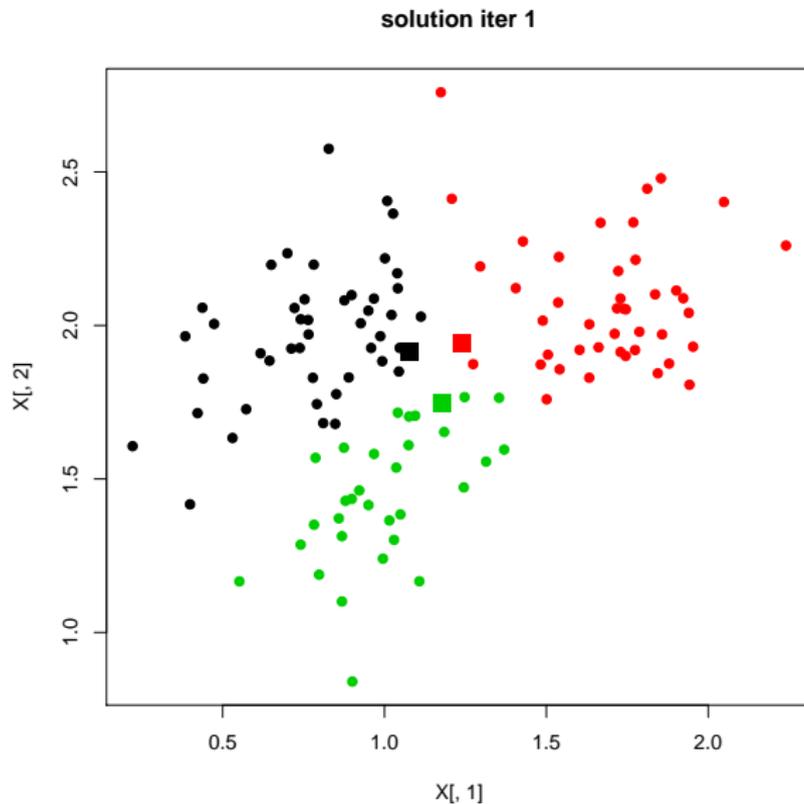
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

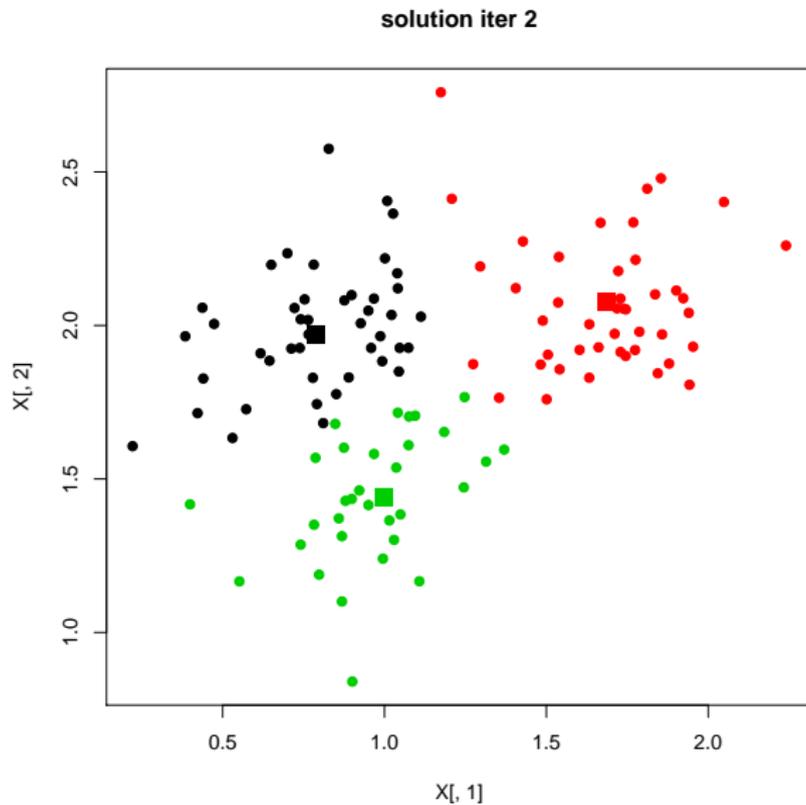
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

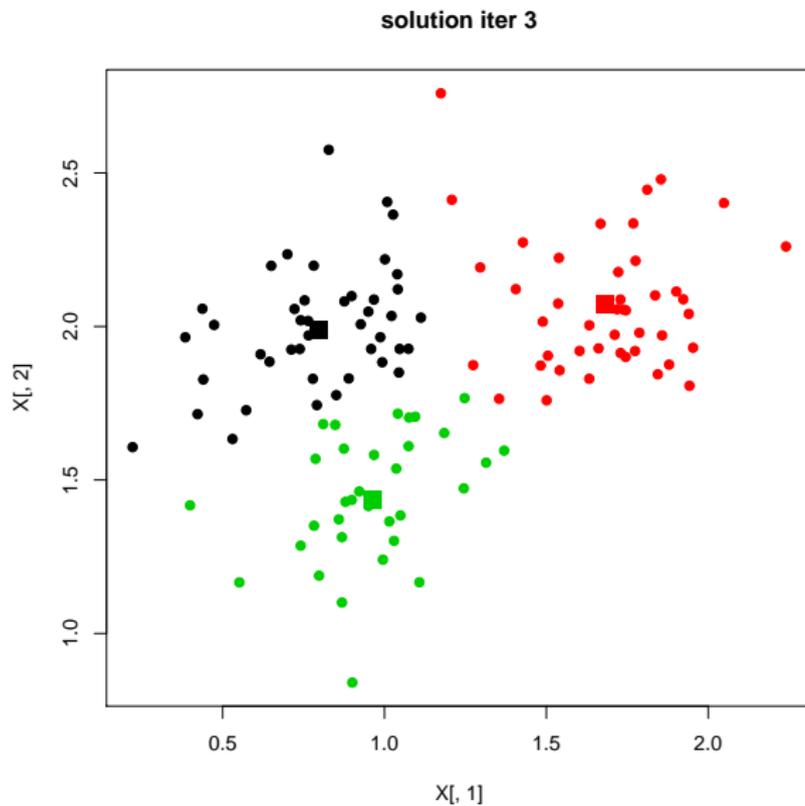
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

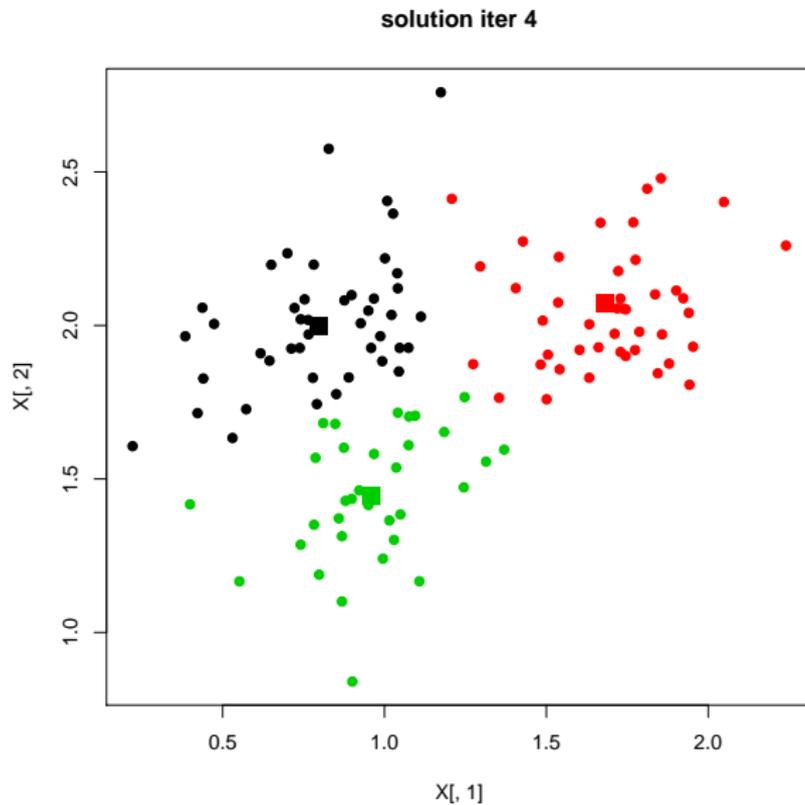
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

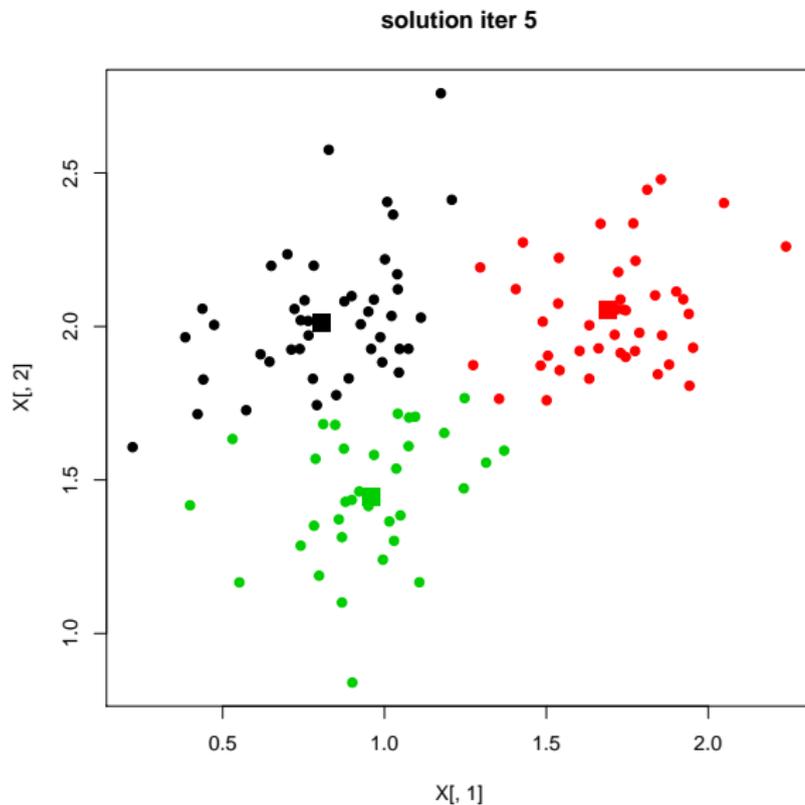
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

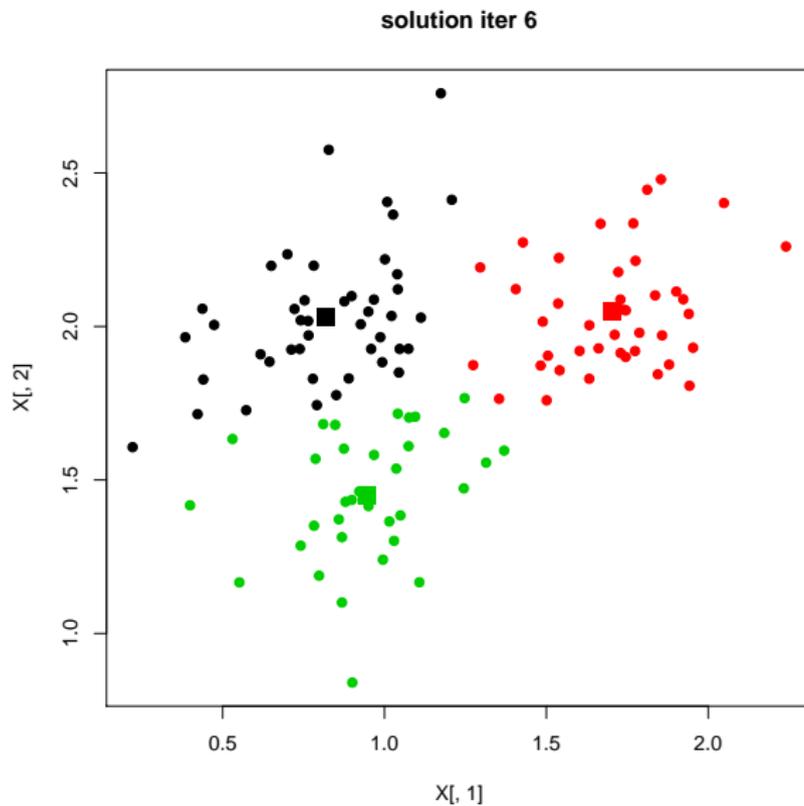
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

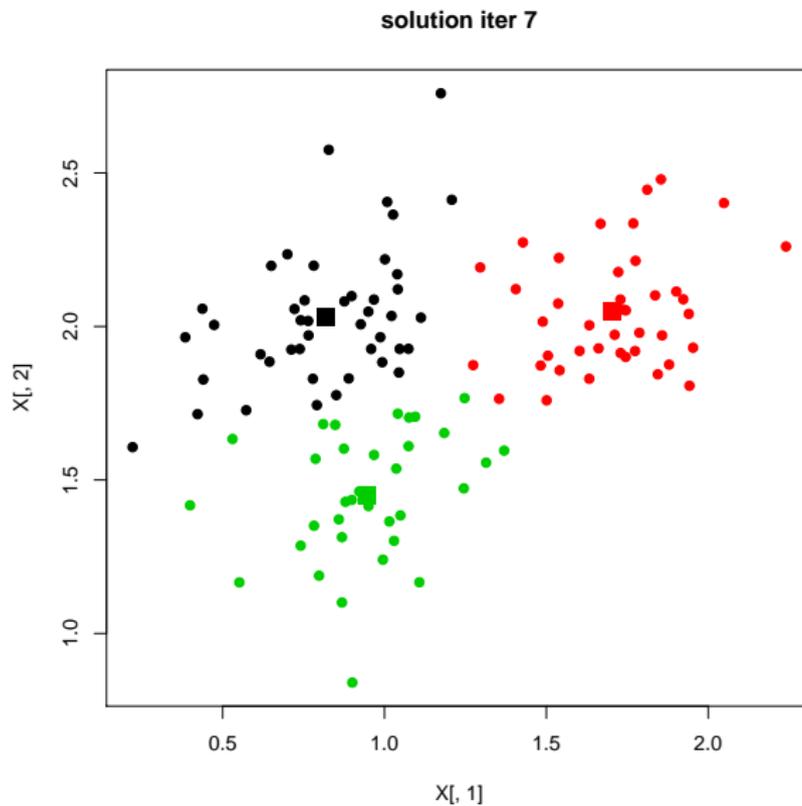
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

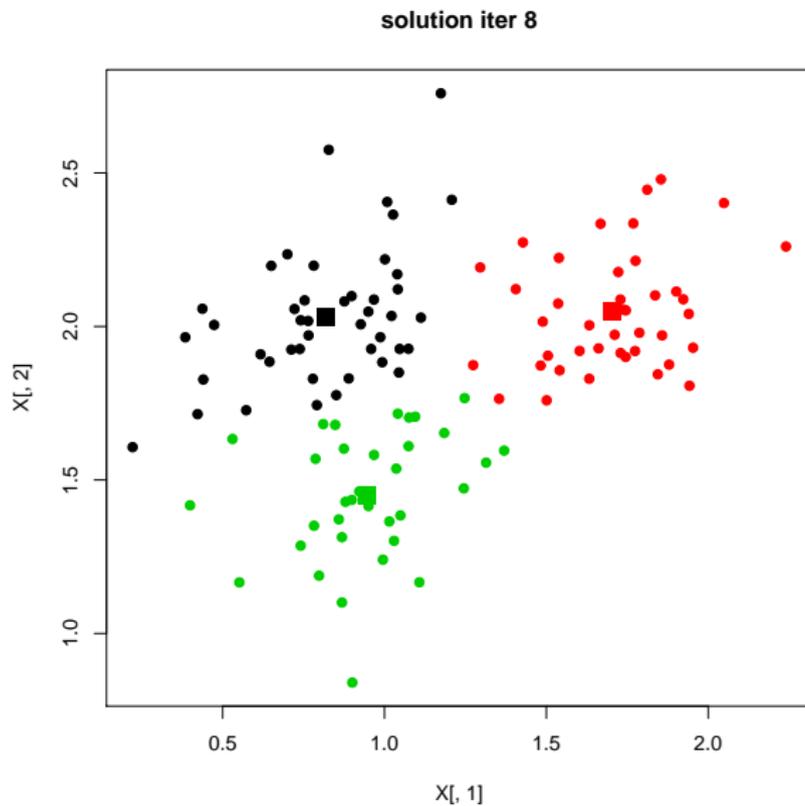
Rappels

k -means

Modèles de
mélange

Conclusion

Références



Algorithme k -means - illustration

Plan

Apprentissage
Statistique I

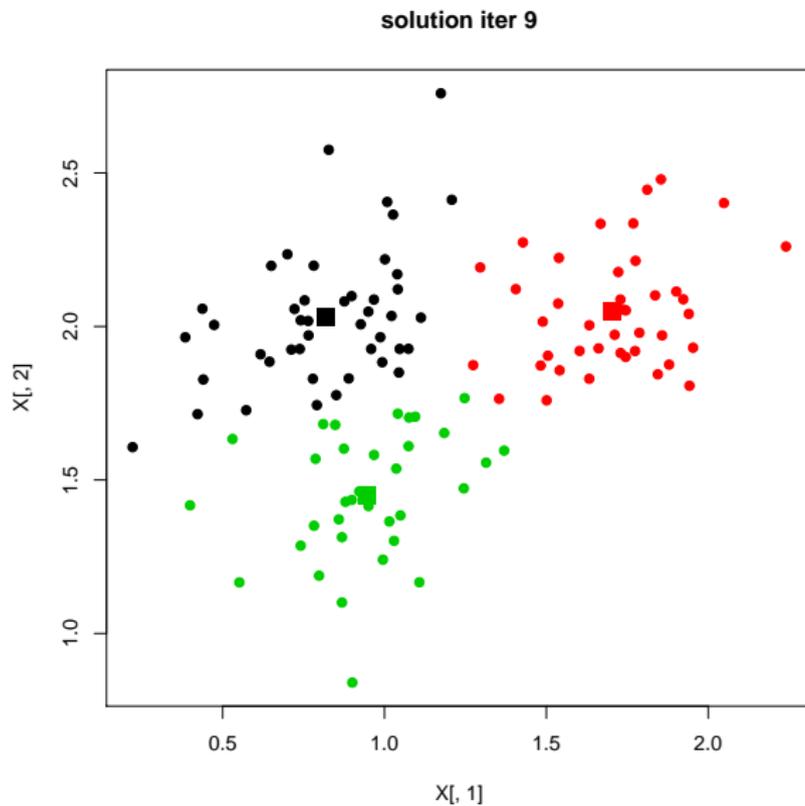
Rappels

k -means

Modèles de
mélange

Conclusion

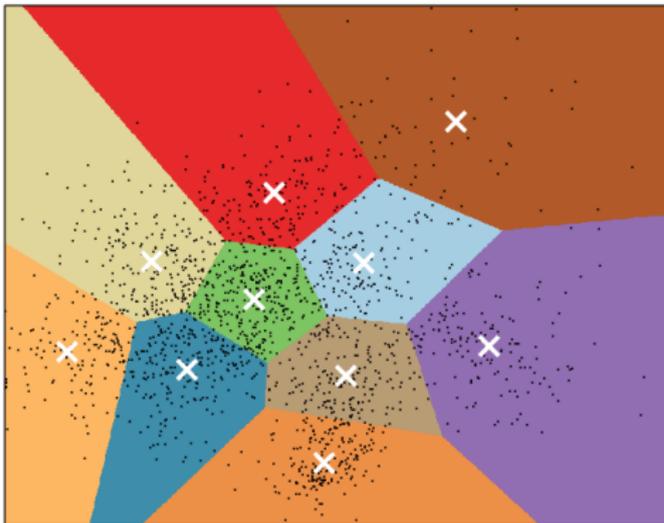
Références



Algorithme k -means - illustration

A convergence, solution = diagramme de Voronoï

K-means clustering on the digits dataset (PCA-reduced data)
Centroids are marked with white cross



- **partition** de l'espace définie par les centroïdes.

Questions ouvertes :

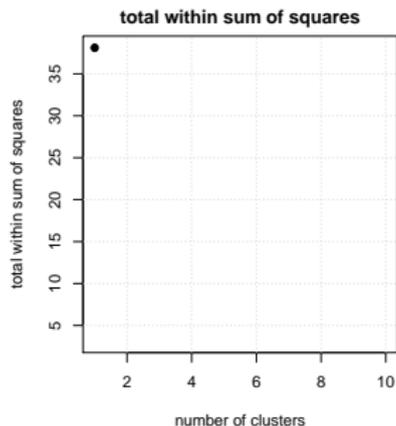
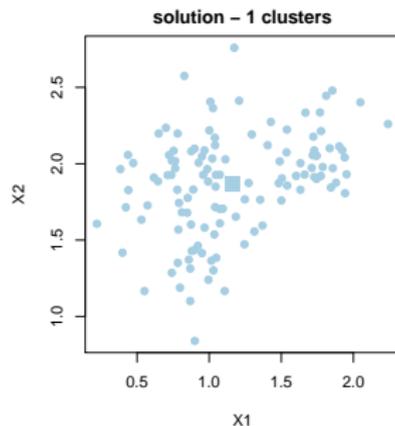
1. choix du nombre de clusters
2. stabilité de la solution
3. critère de distance

Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

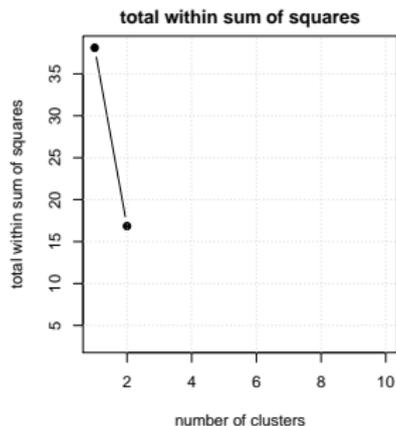
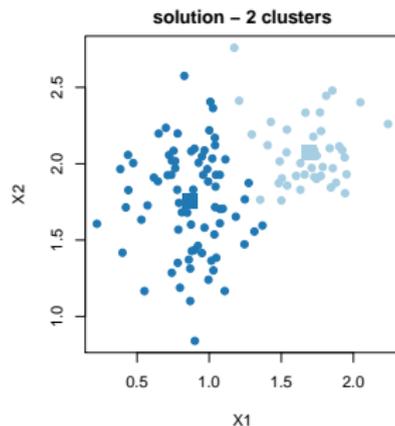


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

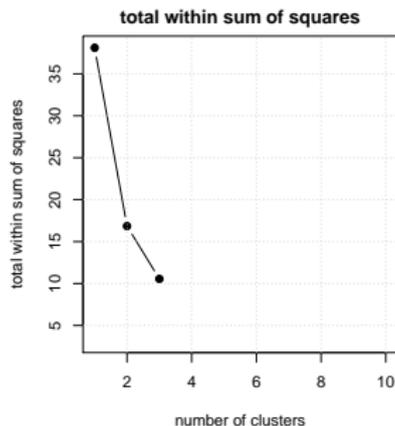
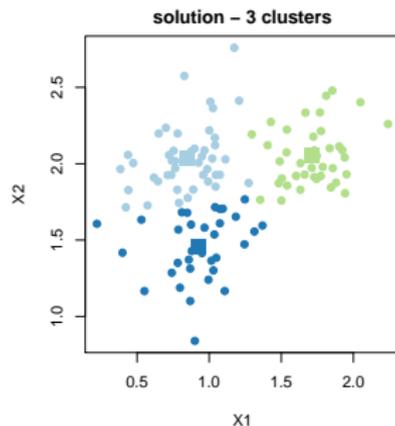


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

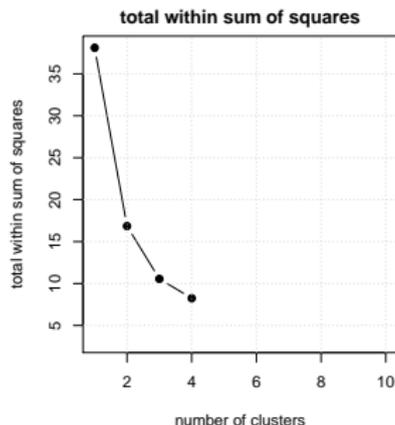
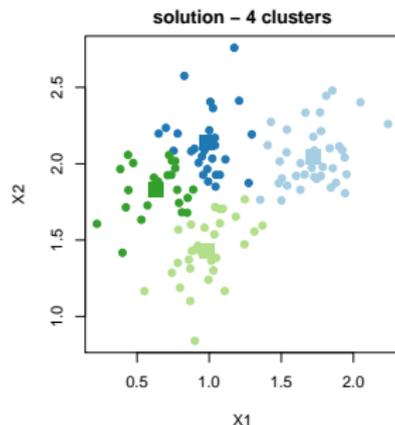


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

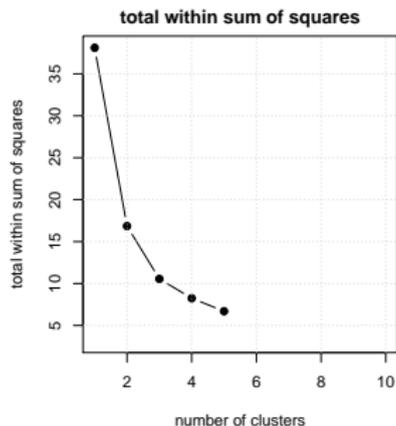
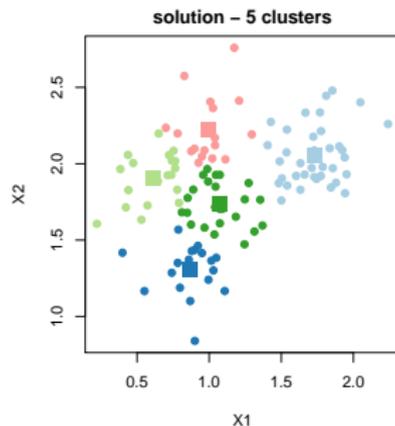


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

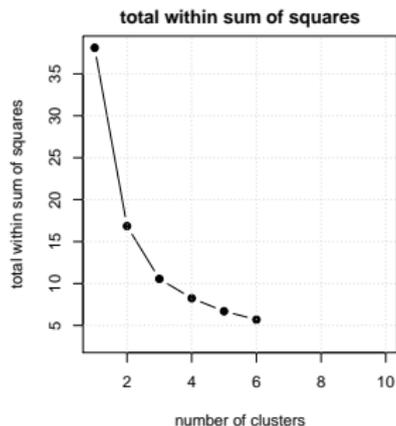
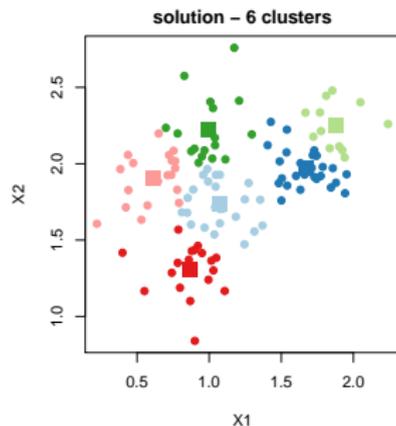


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

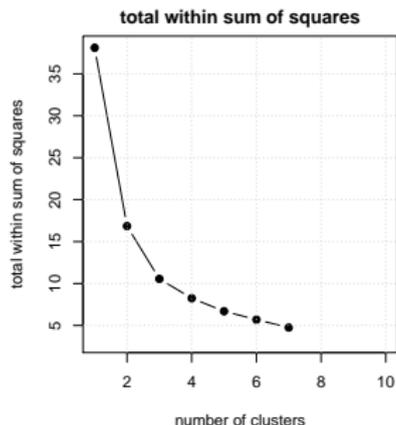
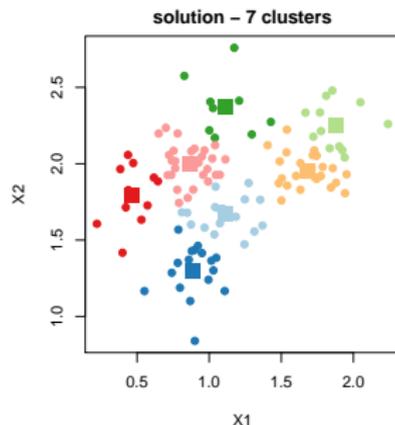


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

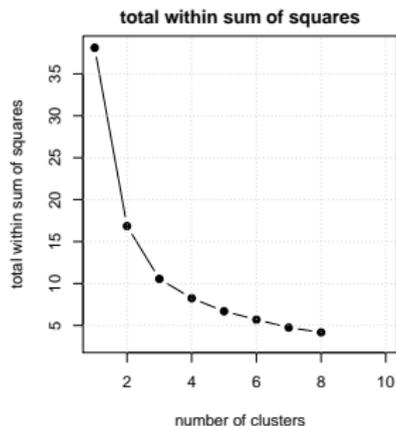
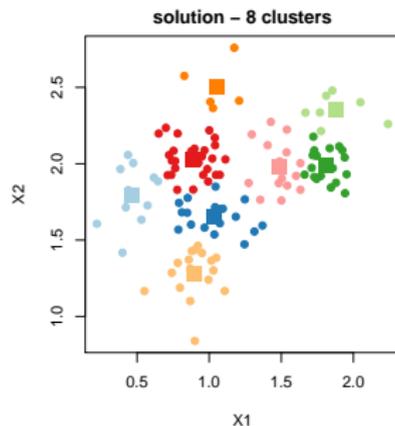


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

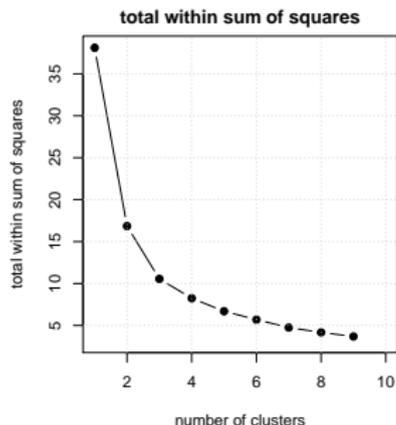
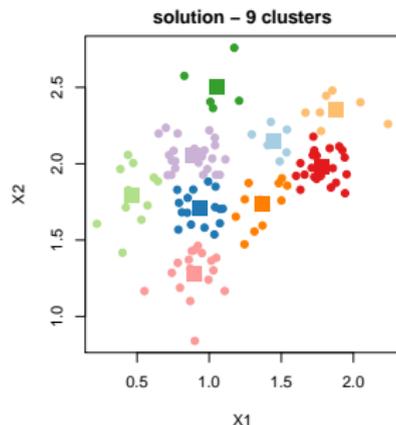


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"

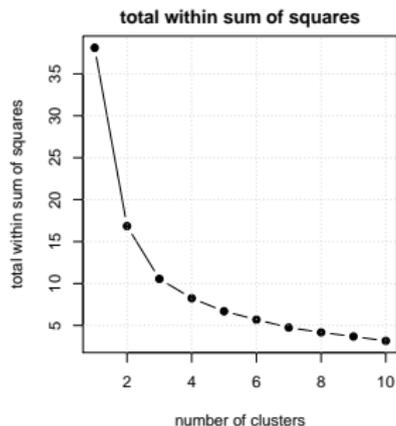
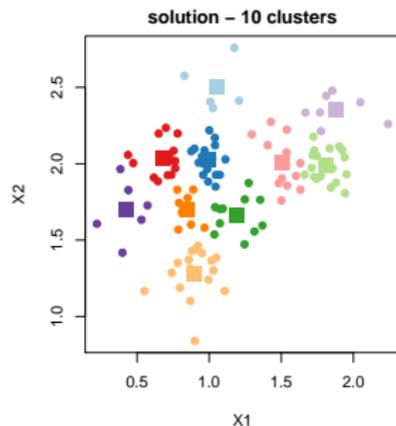


Algorithme k -means - choix du nombre de clusters

Comment choisir le nombre de clusters ?

Première idée : utiliser le critère $W_{SS}(C)$

- ▶ "total within sum of squares"



Algorithme k -means - choix du nombre de clusters

Le critère $W_{SS}(C)$ de "within sum of squares" décroît avec K

⇒ pas un bon critère pour choisir le nombre de clusters

⇒ permet de comparer différents clustering à K fixé.

Algorithme k -means - choix du nombre de clusters

Le critère $W_{SS}(C)$ de "within sum of squares" décroît avec K
⇒ pas un bon critère pour choisir le nombre de clusters
⇒ permet de comparer différents clustering à K fixé.

(au moins) 2 solutions :

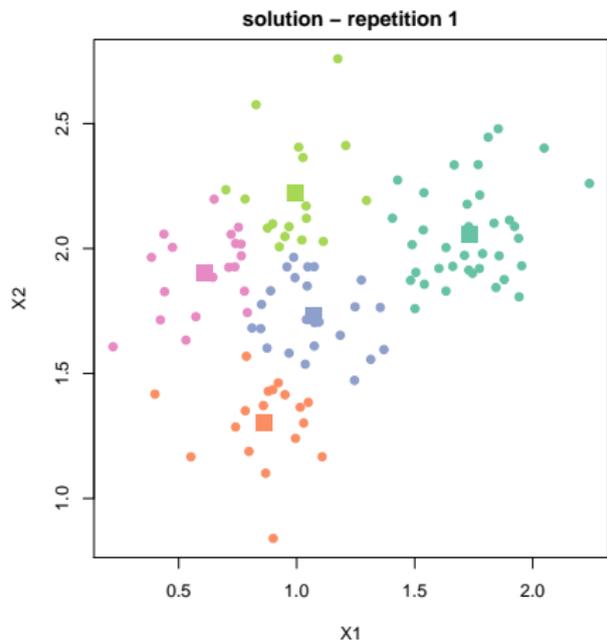
1. approche empirique basée sur le graphe $W_{SS}(C) = f(K)$
 - ▶ méthode "du coude" (elbow method)
 - ▶ ~ choisir le nombre de composantes dans une ACP
2. se placer dans un cadre probabiliste
 - ▶ compromis vraisemblance / complexité
 - ▶ voir mélanges de gaussiennes.

Algorithme k -means - stabilité de la solution

Plan

Apprentissage
Statistique I

Instabilité du résultat :



Rappels

k -means

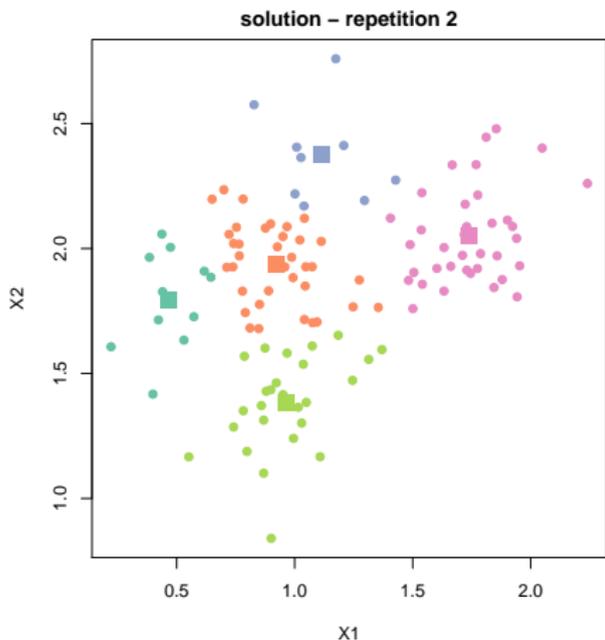
Modèles de
mélange

Conclusion

Références

Algorithme k -means - stabilité de la solution

Instabilité du résultat :



Rappels

k -means

Modèles de
mélange

Conclusion

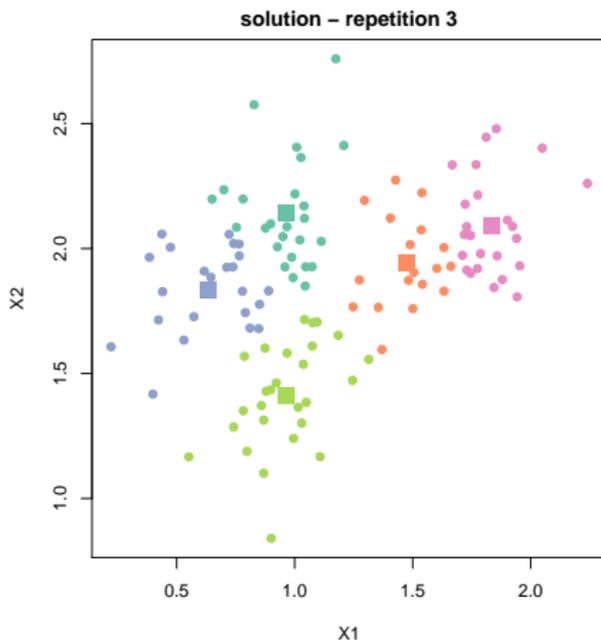
Références

Algorithme k -means - stabilité de la solution

Plan

Apprentissage
Statistique I

Instabilité du résultat :



Rappels

k -means

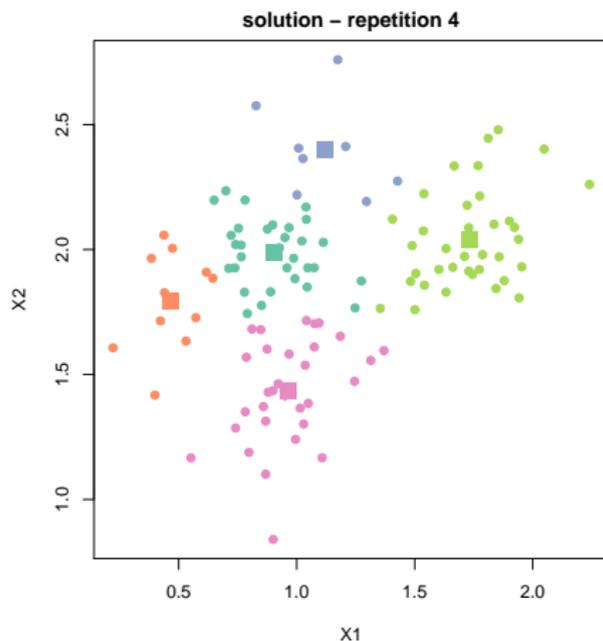
Modèles de
mélange

Conclusion

Références

Algorithme k -means - stabilité de la solution

Instabilité du résultat :



Rappels

k -means

Modèles de
mélange

Conclusion

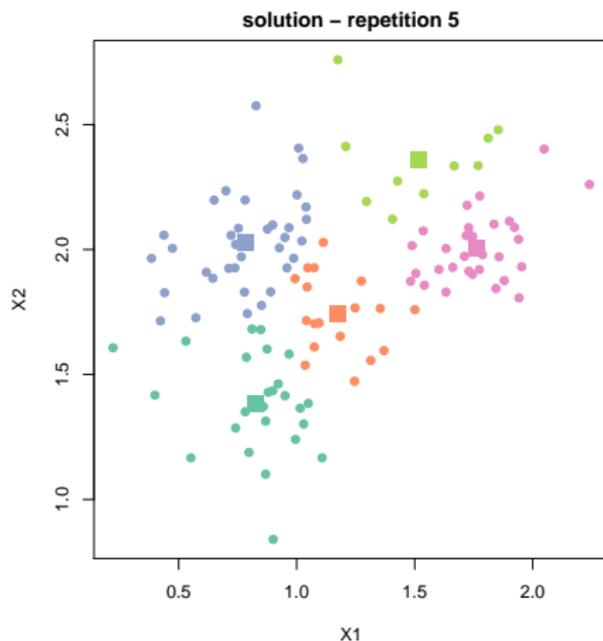
Références

Algorithme k -means - stabilité de la solution

Plan

Apprentissage
Statistique I

Instabilité du résultat :



Rappels

k -means

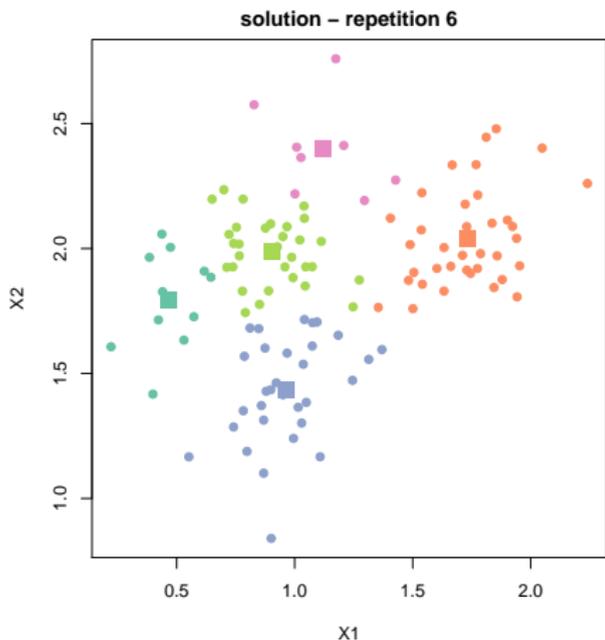
Modèles de
mélange

Conclusion

Références

Algorithme k -means - stabilité de la solution

Instabilité du résultat :



Plan

Apprentissage
Statistique I

Rappels

k -means

Modèles de
mélange

Conclusion

Références

Algorithme k -means - stabilité de la solution

Instabilité : pourquoi ?

- ▶ critère objectif non convexe : solution = minimum local
- ▶ aspect stochastique lié à l'initialisation de l'algorithme
- ▶ (+ identifiabilité de la solution)
 - ▶ \sim la couleur des clusters

Instabilité : que faire ?

1. répéter la procédure
2. choisir la meilleure solution en terme de W_{SS}
 - ▶ (NB : on est à K fixé)

Algorithme k -means - critère de distance

k -means : intrinsèquement lié à la distance Euclidienne

- ▶ ré-écriture & simplification du problème via centroïdes

Algorithme k -means - critère de distance

k -means : intrinsèquement lié à la distance Euclidienne

- ▶ ré-écriture & simplification du problème via centroïdes

Pourquoi considérer d'autres critères de distance ?

- ▶ données vectorielles mais autre notion de similarité
- ▶ travailler à partir d'une matrice de distance / similarité

Algorithme *k*-means - critère de distance

k-means : intrinsèquement lié à la **distance Euclidienne**

- ▶ ré-écriture & simplification du problème via **centroïdes**

Pourquoi considérer d'autres critères de distance ?

- ▶ données vectorielles mais autre notion de similarité
- ▶ travailler à partir d'une matrice de distance / similarité

Une solution : **algorithme des *k*-médoides**

- ▶ **médoïde** : **instance** représentative d'un cluster
- ▶ (e.g., avec la plus petite distance moyenne aux autres)

Algorithme k -means - critère de distance

k -means : intrinsèquement lié à la **distance Euclidienne**

- ▶ ré-écriture & simplification du problème via **centroïdes**

Pourquoi considérer d'autres critères de distance ?

- ▶ données vectorielles mais autre notion de similarité
- ▶ travailler à partir d'une matrice de distance / similarité

Une solution : **algorithme des k -médoides**

- ▶ **médoïde** : **instance** représentative d'un cluster
- ▶ (e.g., avec la plus petite distance moyenne aux autres)

⇒ **médoïde** = observation ; **centroïde** = moyenne

⇒ nécessaire pour travailler sur une matrice de distance

Algorithme des k -médoides

1. **Initialisation** : affecter les points aléatoirement aux clusters
2. **Itérer** la procédure suivante :
 - 2.1 calculer les **médoides** des clusters :

$$m_k^{(t)} = \arg \min_{i: C(i)^{(t)}=k} \sum_{j: C(j)^{(t)}=k} d(x_i, x_j)$$

- 2.2 affecter chaque point au cluster dont le médoides est le plus proche :

$$C(i)^{(t+1)} = \arg \min_{k=1, \dots, K} d(x_i, m_k^{(t)})$$

Critère d'arrêt :

- ▶ **convergence** : les affectations ne changent plus
 - ▶ i.e., $C(i)^{(t+1)} = C(i)^{(t)}$, $\forall i = 1, \dots, n$.
- ▶ **nombre maximum d'itérations** atteint

k -means vs k -médoids : identification des représentants :

► k -means :

$$\mu_k = \frac{1}{n_k} \sum_{i:C(i)=k} x_i$$

► k -médoids :

$$m_k = \arg \min_{i:C(i)=k} \sum_{j:C(j)=k} d(x_i, x_j)$$

⇒ identification des médoids = un problème d'optimisation

⇒ plus complexe (et long) à mettre en oeuvre

Algorithme k -means - mise en oeuvre

Algorithme k -means : très simple à programmer.

Fonction `kmeans` dans R.

Algorithme k -médoides : fonction `pam` du package `cluster`.

Voir TP.

Algorithme k -means et traitement d'image

Plan

Apprentissage
Statistique I

Rappels

k -means

Modèles de
mélange

Conclusion

Références

Segmentation / compression :

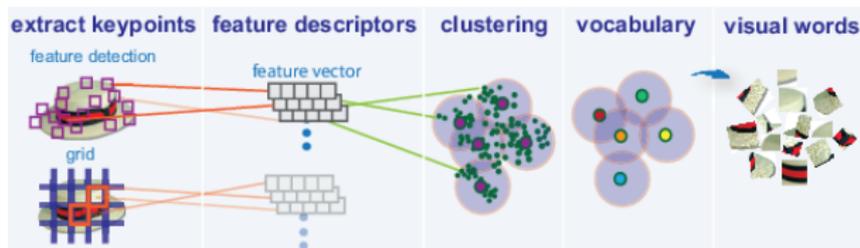


Figure: Image tirée de Bishop (2006)

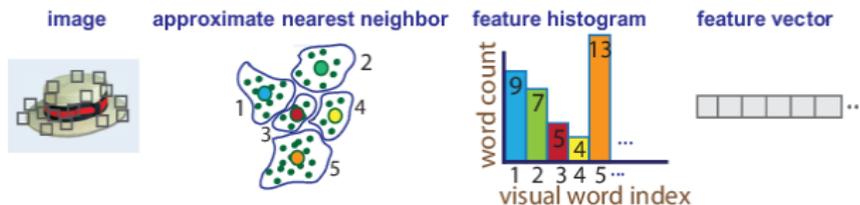
Algorithme k -means et traitement d'image

Catégorisation d'images et représentation mots visuels¹ :

- ▶ apprentissage des "mots visuels" :



- ▶ représentation d'une image :



- ▶ (puis approches supervisées)

Modèles de mélange

k-means & modèles de mélange

Avantages *k*-means :

- ▶ simple à mettre en oeuvre
- ▶ utile pour de nombreuses applications

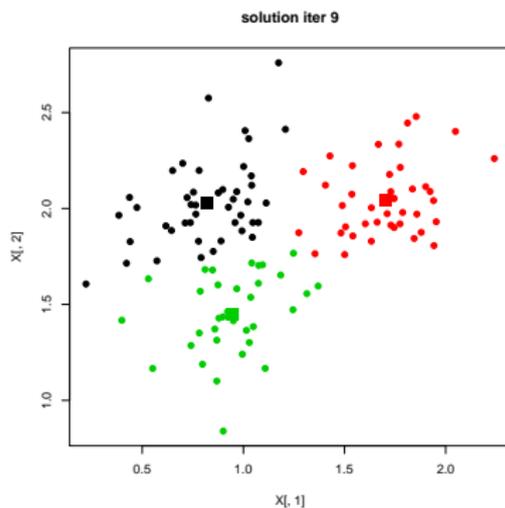
Limites :

- ▶ clustering "hard" : pas d'incertitude dans l'affectation
- ▶ pas de critère objectif pour choisir K

Modèles de mélange : extension probabiliste de *k*-means

- ▶ (par mélange de gaussiennes)

Clustering "hard" ?



⇒ Pas de distinction entre les points :

- ▶ proches du centre du cluster
- ▶ proches de la frontière avec les autres clusters

Modèle de mélange : modèle probabiliste

- ▶ prenant en compte des sous-populations...
- ▶ ...sans qu'elles soient spécifiées à l'avance

Modèles de mélange

Modèle de mélange : modèle probabiliste

- ▶ prenant en compte des sous-populations...
- ▶ ...sans qu'elles soient spécifiées à l'avance

Formellement :

$$p(x) = \sum_{k=1}^K \pi_k f(x; k)$$

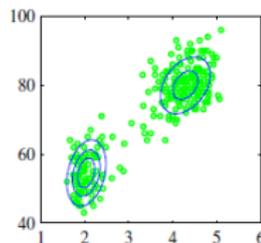
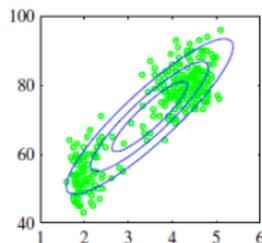
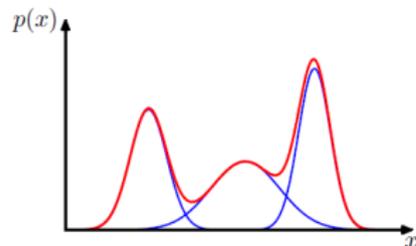
où :

1. $\{f(x; k)\}$ sont les K densités
2. $\{\pi_k\}$ sont les proportions de mélange : $\sum_{k=1}^K \pi_k = 1$

Mélange de Gaussiennes à K composantes :

$$p(x) = \sum_{k=1}^K \pi_k \mathcal{N}(x; \mu_k, \sigma_k), \quad \text{si } x \in \mathbb{R}$$

$$p(\mathbf{x}) = \sum_{k=1}^K \pi_k \mathcal{MN}(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k), \quad \text{si } \mathbf{x} \in \mathbb{R}^p, p > 1.$$



Rappels

k-meansModèles de
mélange

Conclusion

Références

Modèle de mélange & clustering

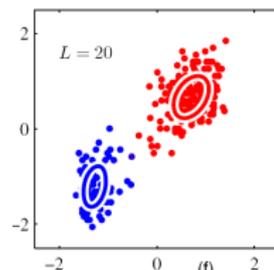
Variables aléatoires mises en jeu (pour chaque observation) :

1. $\mathbf{x} \in \mathbb{R}^p$: observations (multivariées)
2. $\{z_k\}_{k=1, \dots, K}$: appartenance aux clusters
 - ▶ $z_k \in \{0, 1\}$

Hypothèse : distributions gaussiennes au sein des clusters :

$$p(\mathbf{x} | z_1 = 1) = \mathcal{MN}(\mathbf{x}; \boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1)$$

$$p(\mathbf{x} | z_2 = 1) = \mathcal{MN}(\mathbf{x}; \boldsymbol{\mu}_2, \boldsymbol{\Sigma}_2)$$



⇒ Clustering : basé sur $p(z_k = 1 | \mathbf{x})$.

Modèle de mélange & clustering

On peut ré-écrire le modèle général comme :

$$\begin{aligned} p(\mathbf{x}) &= \sum_{k=1}^K p(\mathbf{x}; z_k = 1) \\ &= \sum_{k=1}^K p(z_k = 1) p(\mathbf{x} | z_k = 1) \\ &= \sum_{k=1}^K \pi_k \mathcal{MN}(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \end{aligned}$$

- ▶ $p(\mathbf{x} | z_k = 1)$: densité au sein des classes
- ▶ $p(z_k = 1)$: loi a priori
- ▶ $p(\mathbf{x}; z_k = 1)$: loi jointe

⇒ on passe de $p(\mathbf{x} | z_k = 1)$ à $p(z_k = 1 | \mathbf{x})$ par la loi de Bayes.

Formule de Bayes :

$$p(A = a_1 | B = b) = \frac{p(A = a_1; B = b)}{p(B = b)}$$

Formule de Bayes :

$$\begin{aligned} p(A = a_1 | B = b) &= \frac{p(A = a_1; B = b)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1) p(A = a_1)}{p(B = b)} \end{aligned}$$

Formule de Bayes :

$$\begin{aligned} p(A = a_1 | B = b) &= \frac{p(A = a_1; B = b)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1)p(A = a_1)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1)p(A = a_1)}{\sum_i p(B = b; A = a_i)} \end{aligned}$$

Rappels

k-meansModèles de
mélange

Conclusion

Références

Formule de Bayes :

$$\begin{aligned} p(A = a_1 | B = b) &= \frac{p(A = a_1; B = b)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1)p(A = a_1)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1)p(A = a_1)}{\sum_i p(B = b; A = a_i)} \\ &= \frac{p(B = b | A = a_1)p(A = a_1)}{\sum_i p(B = b | A = a_i)p(A = a_i)} \end{aligned}$$

Rappels

k-means

Modèles de
mélange

Conclusion

Références

Formule de Bayes :

$$\begin{aligned} p(A = a_1 | B = b) &= \frac{p(A = a_1; B = b)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1) p(A = a_1)}{p(B = b)} \\ &= \frac{p(B = b | A = a_1) p(A = a_1)}{\sum_i p(B = b; A = a_i)} \\ &= \frac{p(B = b | A = a_1) p(A = a_1)}{\sum_i p(B = b | A = a_i) p(A = a_i)} \end{aligned}$$

⇒ on peut "inverser" $p(B|A)$ en $p(A|B)$ (et vice versa)

Rappels

k-means

Modèles de
mélange

Conclusion

Références

Modèle de mélange & clustering

Grâce à la **formule de Bayes**, on peut écrire :

$$p(z_k = 1|\mathbf{x}) = \frac{p(\mathbf{x}; z_k = 1)}{p(\mathbf{x})}$$

Modèle de mélange & clustering

Grâce à la **formule de Bayes**, on peut écrire :

$$\begin{aligned} p(z_k = 1|\mathbf{x}) &= \frac{p(\mathbf{x}; z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{p(\mathbf{x})} \end{aligned}$$

Modèle de mélange & clustering

Grâce à la [formule de Bayes](#), on peut écrire :

$$\begin{aligned} p(z_k = 1|\mathbf{x}) &= \frac{p(\mathbf{x}; z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{\sum_{i=1}^K p(\mathbf{x}|z_i = 1)p(z_i = 1)} \end{aligned}$$

Modèle de mélange & clustering

Grâce à la **formule de Bayes**, on peut écrire :

$$\begin{aligned} p(z_k = 1|\mathbf{x}) &= \frac{p(\mathbf{x}; z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{\sum_{i=1}^K p(\mathbf{x}|z_i = 1)p(z_i = 1)} \end{aligned}$$

⇒ **affection probabiliste** d'une observation \mathbf{x} aux clusters :

$$p(z_k = 1|\mathbf{x})$$

Modèle de mélange & clustering

Grâce à la **formule de Bayes**, on peut écrire :

$$\begin{aligned} p(z_k = 1|\mathbf{x}) &= \frac{p(\mathbf{x}; z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{p(\mathbf{x})} \\ &= \frac{p(\mathbf{x}|z_k = 1)p(z_k = 1)}{\sum_{i=1}^K p(\mathbf{x}|z_i = 1)p(z_i = 1)} \end{aligned}$$

⇒ **affection probabiliste** d'une observation \mathbf{x} aux clusters :

$$p(z_k = 1|\mathbf{x})$$

Remarques :

- ▶ on connaît $p(\mathbf{x}|z_k = 1)$ et $p(z_k = 1)$
- ▶ on vérifie facilement que $\sum_{k=1}^K p(z_k = 1|\mathbf{x}) = 1$

Clustering "hard" vs clustering "soft"

Algorithme *k*-means :

$$C(\mathbf{x}) = \arg \min_{k=1, \dots, K} \|\mathbf{x} - \mu_k\|^2$$

Clustering "hard" vs clustering "soft"

Algorithme *k*-means :

$$C(\mathbf{x}) = \arg \min_{k=1, \dots, K} \|\mathbf{x} - \mu_k\|^2$$

Peut s'écrire comme :

$$p(z_i = 1 | \mathbf{x}) = \mathbb{1}(i = \arg \min_{k=1, \dots, K} \|\mathbf{x} - \mu_k\|^2)$$

Clustering "hard" vs clustering "soft"

Algorithme *k*-means :

$$C(\mathbf{x}) = \arg \min_{k=1, \dots, K} \|\mathbf{x} - \mu_k\|^2$$

Peut s'écrire comme :

$$p(z_i = 1 | \mathbf{x}) = \mathbb{1}(i = \arg \min_{k=1, \dots, K} \|\mathbf{x} - \mu_k\|^2)$$

soit :

$$p(z_i = 1 | \mathbf{x}) = \begin{cases} 1 & \text{si } \mu_i \text{ est le plus proche centroïde} \\ 0 & \text{sinon} \end{cases}$$

⇒ affectation "hard" au cluster le plus proche

Mélanges de Gaussiennes - estimation

Pour une observation \mathbf{x} on a donc le modèle :

$$\begin{aligned} p(\mathbf{x}) &= \sum_{k=1}^K \pi_k \mathcal{M}\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \\ &= \sum_{k=1}^K p(z_k = 1) p(\mathbf{x} | z_k = 1) \end{aligned}$$

Mélanges de Gaussiennes - estimation

Pour une observation \mathbf{x} on a donc le modèle :

$$\begin{aligned} p(\mathbf{x}) &= \sum_{k=1}^K \pi_k \mathcal{M}\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \\ &= \sum_{k=1}^K p(z_k = 1) p(\mathbf{x} | z_k = 1) \end{aligned}$$

⇒ Paramètres à estimer : $\{\pi_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$, pour $k = 1, \dots, K$.

Mélanges de Gaussiennes - estimation

Pour une observation \mathbf{x} on a donc le modèle :

$$\begin{aligned} p(\mathbf{x}) &= \sum_{k=1}^K \pi_k \mathcal{M}\mathcal{N}(\mathbf{x}; \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \\ &= \sum_{k=1}^K p(z_k = 1) p(\mathbf{x} | z_k = 1) \end{aligned}$$

\Rightarrow Paramètres à estimer : $\{\pi_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$, pour $k = 1, \dots, K$.

Principe = maximiser la vraisemblance :

$$p(D) = \prod_{i=1}^n p(\mathbf{x}_i)$$

à partir du jeu de données $D = \{\mathbf{x}_i\}$, $i = 1, \dots, n$.

Mélanges de Gaussiennes - estimation

Vraisemblance : $p(D) = \prod_{i=1}^n p(\mathbf{x}_i)$, où $D = \{\mathbf{x}_i\}$, $i = 1, \dots, n$.

Mélanges de Gaussiennes - estimation

Vraisemblance : $p(D) = \prod_{i=1}^n p(\mathbf{x}_i)$, où $D = \{\mathbf{x}_i\}$, $i = 1, \dots, n$.

Log-vraisemblance :

$$\ln p(D) = \sum_{i=1}^n \ln p(\mathbf{x}_i)$$

Mélanges de Gaussiennes - estimation

Vraisemblance : $p(D) = \prod_{i=1}^n p(\mathbf{x}_i)$, où $D = \{\mathbf{x}_i\}$, $i = 1, \dots, n$.

Log-vraisemblance :

$$\begin{aligned}\ln p(D) &= \sum_{i=1}^n \ln p(\mathbf{x}_i) \\ &= \sum_{i=1}^n \ln \left(\sum_{k=1}^K p(\mathbf{x}_i | z_k^{(i)} = 1) p(z_k^{(i)} = 1) \right)\end{aligned}$$

Mélanges de Gaussiennes - estimation

Vraisemblance : $p(D) = \prod_{i=1}^n p(\mathbf{x}_i)$, où $D = \{\mathbf{x}_i\}$, $i = 1, \dots, n$.

Log-vraisemblance :

$$\begin{aligned}\ln p(D) &= \sum_{i=1}^n \ln p(\mathbf{x}_i) \\ &= \sum_{i=1}^n \ln \left(\sum_{k=1}^K p(\mathbf{x}_i | z_k^{(i)} = 1) p(z_k^{(i)} = 1) \right) \\ &= \sum_{i=1}^n \ln \left(\sum_{k=1}^K \mathcal{MN}(\mathbf{x}_i; \mu_k, \Sigma_k) \pi_k \right)\end{aligned}$$

Mélanges de Gaussiennes - estimation

Vraisemblance : $p(D) = \prod_{i=1}^n p(\mathbf{x}_i)$, où $D = \{\mathbf{x}_i\}$, $i = 1, \dots, n$.

Log-vraisemblance :

$$\begin{aligned}\ln p(D) &= \sum_{i=1}^n \ln p(\mathbf{x}_i) \\ &= \sum_{i=1}^n \ln \left(\sum_{k=1}^K p(\mathbf{x}_i | z_k^{(i)} = 1) p(z_k^{(i)} = 1) \right) \\ &= \sum_{i=1}^n \ln \left(\sum_{k=1}^K \mathcal{MN}(\mathbf{x}_i; \mu_k, \Sigma_k) \pi_k \right)\end{aligned}$$

⇒ à maximiser selon $\{\pi_k, \mu_k, \Sigma_k\}$:

1. on dérive $\ln p(D)$ selon $\{\pi_k, \mu_k, \Sigma_k\}$
2. on annule les dérivées

On obtient les équations suivantes :

$$\pi_k = \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n} \quad (1)$$

$$\mu_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) \mathbf{x}_i \quad (2)$$

$$\Sigma_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) (\mathbf{x}_i - \mu_k)(\mathbf{x}_i - \mu_k)^T \quad (3)$$

⇒ chaque observation \mathbf{x}_i contribue à l'estimation de l'ensemble des $\{\pi_k, \mu_k, \Sigma_k\}$ à hauteur de $p(z_k^{(i)} = 1 | \mathbf{x}_i)$.

Mélanges de Gaussiennes - estimation

Interprétation : différence avec *k*-means

$$\pi_k = \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n}$$

$$\neq \frac{1}{n} \sum_{i=1}^n \mathbb{1}(C(i) = k) = \frac{n_k}{n}$$

\Rightarrow *k*-means

Mélanges de Gaussiennes - estimation

Interprétation : différence avec k -means

$$\begin{aligned} \pi_k &= \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n} \\ &\neq \frac{1}{n} \sum_{i=1}^n \mathbb{1}(C(i) = k) = \frac{n_k}{n} \quad \Rightarrow \text{k-means} \end{aligned}$$

$$\begin{aligned} \mu_k &= \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) \mathbf{x}_i \\ &\neq \frac{1}{n_k} \sum_{i:C(i)=k} \mathbf{x}_i = \frac{1}{n_k} \sum_{i=1}^n \mathbb{1}(C(i) = k) \mathbf{x}_i \quad \Rightarrow \text{k-means} \end{aligned}$$

Mélanges de Gaussiennes - estimation

Interprétation : différence avec k -means

$$\begin{aligned}\pi_k &= \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n} \\ &\neq \frac{1}{n} \sum_{i=1}^n \mathbb{1}(C(i) = k) = \frac{n_k}{n} \quad \Rightarrow \text{k-means}\end{aligned}$$

$$\begin{aligned}\mu_k &= \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) \mathbf{x}_i \\ &\neq \frac{1}{n_k} \sum_{i:C(i)=k} \mathbf{x}_i = \frac{1}{n_k} \sum_{i=1}^n \mathbb{1}(C(i) = k) \mathbf{x}_i \quad \Rightarrow \text{k-means}\end{aligned}$$

\Rightarrow chaque observation \mathbf{x}_i contribue à l'estimation de l'ensemble des $\{\pi_k, \mu_k, \Sigma_k\}$ à hauteur de $p(z_k^{(i)} = 1 | \mathbf{x}_i)$.

Mélanges de Gaussiennes - estimation

Remarque : de la même manière

$$\Sigma_k = E[(\mathbf{x} - \mu_k)(\mathbf{x} - \mu_k)^T]$$

⇒ estimateur "classique" :

$$\Sigma_k = \frac{1}{n_k} \sum_{i=1}^{n_k} (\mathbf{x}_i - \mu_k)(\mathbf{x}_i - \mu_k)^T$$

⇒ modèle de mélange :

$$\Sigma_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) (\mathbf{x}_i - \mu_k)(\mathbf{x}_i - \mu_k)^T$$

(NB : Σ_k pas utilisé dans k-means)

Mélanges de Gaussiennes - estimation

Problème : les équations suivantes :

$$\pi_k = \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n}$$

$$\mu_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) \mathbf{x}_i$$

$$\Sigma_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) (\mathbf{x}_i - \mu_k)(\mathbf{x}_i - \mu_k)^T$$

$$\text{et } p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{\mathcal{MN}(\mathbf{x}_i; \mu_k, \Sigma_k) \pi_k}{\sum_{j=1}^K \mathcal{MN}(\mathbf{x}_i; \mu_j, \Sigma_j) \pi_j}$$

sont **liées** (couplées) :

- ▶ il nous faut $p(z_k^{(i)} = 1 | \mathbf{x}_i)$ pour avoir (π_k, μ_k, Σ_k)
- ▶ il nous faut $\{\pi_k, \mu_k, \Sigma_k\}$ pour avoir $p(z_k^{(i)} = 1 | \mathbf{x}_i)$

Mélanges de Gaussiennes - estimation

Solution = procédure itérative :

1. estimer $p(z_k^{(i)} = 1 | \mathbf{x}_i)$

$$p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{\mathcal{MN}(\mathbf{x}_i; \mu_k, \Sigma_k) \pi_k}{\sum_{j=1}^K \mathcal{MN}(\mathbf{x}_i; \mu_j, \Sigma_j) \pi_j}$$

2. mettre à jour les estimations de $\{\pi_k, \mu_k, \Sigma_k\}$

$$\pi_k = \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n}$$

$$\mu_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) \mathbf{x}_i$$

$$\Sigma_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) (\mathbf{x}_i - \mu_k)(\mathbf{x}_i - \mu_k)^T$$

Mélanges de Gaussiennes - estimation

Solution = procédure itérative :

1. estimer $p(z_k^{(i)} = 1 | \mathbf{x}_i)$

$$p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{\mathcal{MN}(\mathbf{x}_i; \mu_k, \Sigma_k) \pi_k}{\sum_{j=1}^K \mathcal{MN}(\mathbf{x}_i; \mu_j, \Sigma_j) \pi_j}$$

2. mettre à jour les estimations de $\{\pi_k, \mu_k, \Sigma_k\}$

$$\pi_k = \frac{1}{n} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) = \frac{n'_k}{n}$$

$$\mu_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) \mathbf{x}_i$$

$$\Sigma_k = \frac{1}{n'_k} \sum_{i=1}^n p(z_k^{(i)} = 1 | \mathbf{x}_i) (\mathbf{x}_i - \mu_k)(\mathbf{x}_i - \mu_k)^T$$

⇒ un cas particulier de l'algorithme EM

▶ étape 1 = "Expectation", étape 2 = "Maximization"

⇒ ~ une version probabiliste de k-means

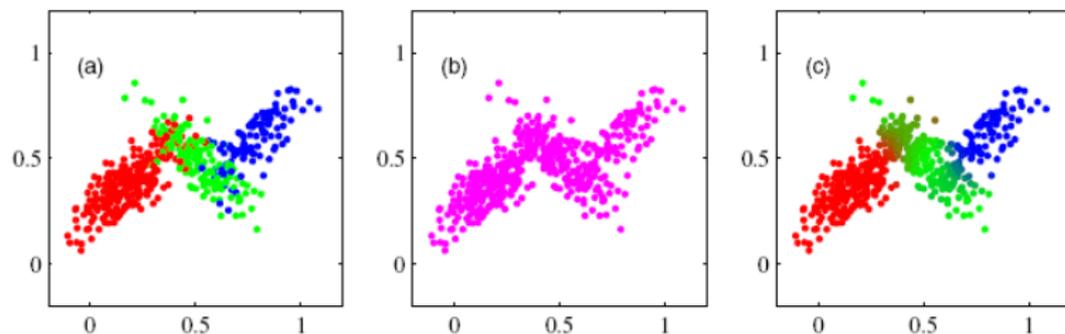
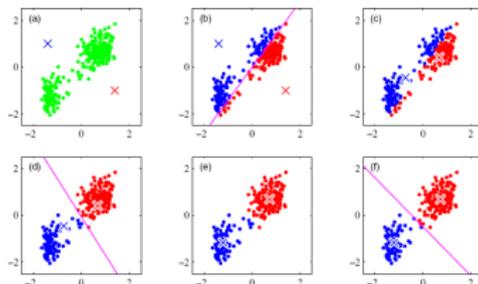


Figure: Figure tirée de Bishop (2006)

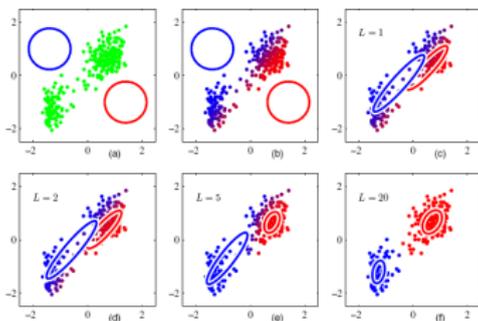
- ▶ **Gauche** : simulation des données (3 clusters)
- ▶ **Milieu** : données d'entrée (cadre non supervisé)
- ▶ **Droite** : résultat (couleur en fonction de $p(z_k = 1|\mathbf{x})$)

Algorithme EM - illustration

k-means :



Mélange de Gaussiennes & EM :



(images tirées de Bishop (2006))

Plan

Apprentissage
Statistique I

Rappels

k-means

Modèles de
mélange

Conclusion

Références

Choisir le nombre de clusters

La vraisemblance augmente avec K :

$$p(D) = \prod_{i=1}^n p(\mathbf{x}_i) = \prod_{i=1}^n \sum_{k=1}^K \pi_k \mathcal{M}\mathcal{N}(\mathbf{x}_i; \mu_k, \Sigma_k),$$

- ▶ (de la même manière que l'erreur diminue avec *k*-means)

Choisir le nombre de clusters

La vraisemblance augmente avec K :

$$p(D) = \prod_{i=1}^n p(\mathbf{x}_i) = \prod_{i=1}^n \sum_{k=1}^K \pi_k \mathcal{M}\mathcal{N}(\mathbf{x}_i; \mu_k, \Sigma_k),$$

- ▶ (de la même manière que l'erreur diminue avec k -means)

Critères de sélection de modèles = compromis :

1. **qualité** du modèle : $p(D)$ = maximum de **vraisemblance**
2. **complexité** du modèle : m = nombre de **paramètres**

Choisir le nombre de clusters

La vraisemblance augmente avec K :

$$p(D) = \prod_{i=1}^n p(\mathbf{x}_i) = \prod_{i=1}^n \sum_{k=1}^K \pi_k \mathcal{MN}(\mathbf{x}_i; \mu_k, \Sigma_k),$$

- ▶ (de la même manière que l'erreur diminue avec k -means)

Critères de sélection de modèles = compromis :

1. **qualité** du modèle : $p(D)$ = maximum de **vraisemblance**
2. **complexité** du modèle : m = nombre de **paramètres**

Classiquement :

- ▶ Bayesian Information Criterion = $-2 \ln p(D) + \ln(n)m$
- ▶ Akaike Information Criterion = $-2 \ln p(D) + 2m$

⇒ à minimiser

Choisir le nombre de clusters

Bayesian Information Criterion :

$$\text{BIC} = -2 \ln p(D) + \ln(n)m$$

⇒ à minimiser : meilleur modèle = BIC le plus faible

- ▶ à vraisemblance égale on préfère le modèle le plus simple
- ▶ paramètre supplémentaire si améliore $\ln p(D)$ de $\ln(n)/2$

Choisir le nombre de clusters

Bayesian Information Criterion :

$$\text{BIC} = -2 \ln p(D) + \ln(n)m$$

⇒ à minimiser : meilleur modèle = BIC le plus faible

- ▶ à vraisemblance égale on préfère le modèle le plus simple
- ▶ paramètre supplémentaire si améliore $\ln p(D)$ de $\ln(n)/2$

Stratégie :

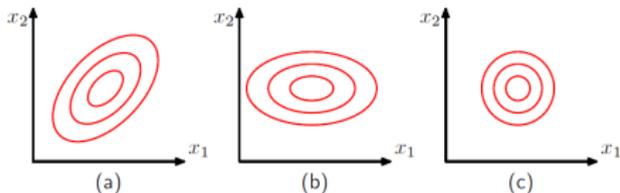
1. faire varier K
2. caculer la vraisemblance par EM
3. calculer le BIC
4. retenir le modèle de BIC minimum

Choisir le nombre de clusters

Attention : c'est bien le **nombre de paramètres** qui entre en jeu dans le BIC, et pas le **nombre de clusters**

⇒ 1 cluster = 1 **Gaussienne multivariée** :

- ▶ p paramètres pour μ_k
- ▶ de 1 à $\frac{p(p+1)}{2}$ paramètres pour Σ_k
- ▶ + 1 paramètre pour π_k



⇒ en pratique, considérer différentes **structures de covariance**

Package `Mclust` de R.

La fonction `mclust` :

1. estime les différents modèles
 - ▶ nombre de clusters
 - ▶ structure de covariance
2. calcule les BIC associés
3. sélectionne le meilleur modèle

La fonction `plot.mclust` propose différentes sorties graphiques

- ▶ BIC, clustering, incertitude...

Conclusion

Conclusion

Clustering et critères de dispersion

Algorithme *k*-means

- ▶ distance Euclidienne, diagramme de Voronoï
- ▶ algorithme itératif, minimum local
- ▶ *k*-means vs *k*-médoides
- ▶ applications en imagerie

Modèles de mélange

- ▶ extension probabiliste de *k*-means, "soft" clustering
- ▶ maximum de vraisemblance, algorithme EM
- ▶ critère BIC et sélection de modèle
- ▶ **NB : vont bien au delà du clustering**

TP : *k*-means (+ modèles de mélanges).

Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.