

Apprentissage non supervisé : Partitionnement de données (*Clustering*)

Joseph Salmon

Université de Montpellier

Plan

Introduction

k -means

Modèles de mélanges gaussiens



Introduction

Objectifs :

- ▶ Structurer les données
- ▶ Regrouper les observations “proches” en “classes”

Vocabulaire :

- ▶ partitionner les données = *Clustering*
- ▶ une méthode *non-supervisé* (sans étiquettes, *i.e.*, sans y)



Exemples d'applications

Gestion - Marketing :

- ▶ données : infos client, produits, ...
- ▶ but : segmenter la clientèle, définir des profils

Exemples d'applications

Gestion - Marketing :

- ▶ données : infos client, produits, ...
- ▶ but : segmenter la clientèle, définir des profils

Traitement Naturel du Langage NLP :

- ▶ données : texte, email, ...
- ▶ but : grouper automatiquement les textes proches

Exemples d'applications

Gestion - Marketing :

- ▶ données : infos client, produits, ...
- ▶ but : segmenter la clientèle, définir des profils

Traitement Naturel du Langage NLP :

- ▶ données : texte, email, ...
- ▶ but : grouper automatiquement les textes proches

Sociologie :

- ▶ données : attributs d'un individu, e.g., revenus, sexe, ...
- ▶ but : former des catégories de population

Exemples d'applications

Gestion - Marketing :

- ▶ données : infos client, produits, ...
- ▶ but : segmenter la clientèle, définir des profils

Traitement Naturel du Langage NLP :

- ▶ données : texte, email, ...
- ▶ but : grouper automatiquement les textes proches

Sociologie :

- ▶ données : attributs d'un individu, e.g., revenus, sexe, ...
- ▶ but : former des catégories de population

Analyse génomique :

- ▶ données : gènes
- ▶ but : former des groupes homogènes de gènes

Intérêt divers

- ▶ visualisation
- ▶ accélération des calculs (appliquer des algorithmes sur des sous parties plus petites)
- ▶ stabilisation des résultats (appliquer des algorithmes sur des sous parties plus homogènes)

Exemple analyse numérique : permet de **pré-conditionner** les données pour utiliser des outils d'algèbre linéaire

Cadre mathématique

- ▶ Données : $X = [x_1, \dots, x_n]^T \in \mathbb{R}^{n \times d}$ (matrice $n \times d$)
 x_i : i -ème observation (i -ème ligne de X)
 n : nombre d'observations / individus / exemples
 d : dimension des variables explicatives (features), covariables

Tailles usuelles pour n :

- ▶ Santé / Bio : $10 \leq n \leq 1000$ (patients) , $1000 \leq d \leq 10^5$
- ▶ Entreprises PME / Nationales : $1000 \leq n \leq 10^7$ (clients)
- ▶ Entreprises GAFA etc. : $10^6 \leq n \leq 10^{10}$ (clients)
- ▶ Visions par ordinateurs $10^0 \leq n \leq 10^{10}$ (images) ; $d =$
nombres de pixels

Rem: ici pas d'“étiquettes” collectées (coûteuses) !

Anecdote : [Imagenet](#) (2009), base de données ayant “relancé” les réseaux de neurones, recours à la “production participative” (*crowdsourcing*)

Notion de proximité

Enjeu :

- ▶ Mesurer la proximité de deux observations x_1, x_2

Ingrédients :

- ▶ **fonction de similarité** : plus la mesure est faible, plus les objets sont similaires (\approx à une distance / divergence)
- ▶ **fonction de dissimilarité** : plus la mesure est grande, plus les objets sont similaires

Distances usuelles

$$x_1 \in \mathbb{R}^d, x_2 \in \mathbb{R}^d$$

- ▶ Distance euclidienne :

$$d^2(x_1, x_2) = \sum_{i=1}^d (x_1^i - x_2^i)^2$$

- ▶ Distance de Manhattan :

$$d(x_1, x_2) = \sum_{i=1}^d |x_1^i - x_2^i|$$

- ▶ Distance de Minkowski :

$$d(x_1, x_2) = \left(\sum_{i=1}^d |x_1^i - x_2^i|^p \right)^{\frac{1}{p}}$$

- ▶ Distance de Mahalanobis (W matrice symétrique, $\succ 0$)

$$d^2(x_1, x_2) = (x_1 - x_2)^\top W (x_1 - x_2) = \sum_{i,j} W_{i,j} (x_1^i - x_2^i) (x_1^j - x_2^j)$$

Cas des variables discrètes

Distance de Hamming : nombre de coefs où les vecteurs diffèrent

$$d(x_1, x_2) = \sum_{i=1}^d \mathbb{1}_{\{x_1^i \neq x_2^i\}}$$

Exemple :

$$x_1 = (0, 1, 2, 1, 2, 1)^\top, x_2 = (1, 0, 2, 1, 0, 1)^\top : d(x_1, x_2) = 3$$

Bonus : pour données non “numériques”, mesure indépendante de l’encodage

Par exemple : si menthe=0, vanille=1, chocolat=2 ; la distance euclidienne rendrait menthe plus proche de vanille que de chocolat...

Panorama de clustering

<http://scikit-learn.org/stable/modules/clustering.html>

Plan

Introduction

k-means

Introduction

Propriétés

Modèles de mélanges gaussiens

Qualité d'une partition

- ▶ $\mathcal{C}_1 \cup \dots \cup \mathcal{C}_K$: partition de $\llbracket 1, n \rrbracket$, en K classes (K fixé ici)
- ▶ $|\mathcal{C}_1| = N_1, \dots, |\mathcal{C}_K| = N_K$
- ▶ "centres" μ_1, \dots, μ_K

Inertie intra-cluster


$$I = I(\mu, \mathcal{C}) = \sum_{k=1}^K \sum_{i \in \mathcal{C}_k} d^2(x_i, \mu_k)$$

Rem: vocabulaire similaire à la mécanique


Stratégie :

- (i) Minimiser l'inertie intra-cluster


Visualisation







Visualisation



Visualisation



Visualisation



$K = 3$

La méthode du k -means

Contexte : On dispose d'un échantillon de taille $n : x_1, \dots, x_n$ à valeurs dans \mathbb{R}^d

Principe :

- ▶ Classe \mathcal{C}_k : représentée par un **centroïde** $\mu_k \in \mathbb{R}^d$
- ▶ Formation des classes : affecter au centroïde le plus proche

Heuristique :

Déterminer K centroïdes μ_1, \dots, μ_K minimisant :

$$\mathcal{E}_n(\mu_1, \dots, \mu_K) = \sum_{i=1}^n \min_{1 \leq k \leq K} d(x_i, \mu_k)^2$$

Idéalement il faut résoudre le problème (non-convexe / NP-dur) :

$$\min_{\mu_1, \dots, \mu_K \in (\mathbb{R}^d)^K} \mathcal{E}_n(\mu_1, \dots, \mu_K)$$

Algorithme de Lloyd^{(1), (2)} : optimisation alternée

Objectif : minimiser le critère de distorsion $\mathcal{E}_n(\mu_1, \dots, \mu_K)$

Initialisation des K centres μ_1, \dots, μ_K

Affectation de chaque observation au centre le plus proche

Mise à jour des centres, en calculant la moyenne empirique des observations dans chaque classe

Itérer jusqu'à convergence

Rem: algorithme non publié par Lloyd, alors aux Bell Labs en 1957

(1). S. LLOYD. "Least squares quantization in PCM". In : *IEEE Trans. Inf. Theory* 28.2 (1982), p. 129-137.

(2). H. STEINHAUS. "Sur la division des corps matériels en parties". In : *Bull. Acad. Polon. Sci. Cl. III.* 4 (1956), 801-804 (1957).

k-means

Objectif : trouver une partition optimale

Algorithme : *k*-means

Entrées : X, K

Initialisation : $t = 0$ et $\mu_1, \dots, \mu_K \in \mathbb{R}^d$

k-means

Objectif : trouver une partition optimale

Algorithme : *k*-means

Entrées : X, K

Initialisation : $t = 0$ et $\mu_1, \dots, \mu_K \in \mathbb{R}^d$

tant que *pas convergé* **faire**

|

k -means

Objectif : trouver une partition optimale

Algorithme : k -means

Entrées : X, K

Initialisation : $t = 0$ et $\mu_1, \dots, \mu_K \in \mathbb{R}^d$

tant que *pas convergé* **faire**

$t \leftarrow t + 1, C_1 \leftarrow \emptyset, \dots, C_K \leftarrow \emptyset$

k-means

Objectif : trouver une partition optimale

Algorithme : *k*-means

Entrées : X, K

Initialisation : $t = 0$ et $\mu_1, \dots, \mu_K \in \mathbb{R}^d$

tant que *pas convergé* **faire**

$t \leftarrow t + 1, \mathcal{C}_1 \leftarrow \emptyset, \dots, \mathcal{C}_K \leftarrow \emptyset$

pour $i = 1, \dots, n$ **faire**

$h = h^*(x_i) = \arg \min_{k \in \llbracket 1, K \rrbracket} d^2(x_i, \mu_k)$

$\mathcal{C}_h \leftarrow \mathcal{C}_h \cup \{i\}$

// Affectation

k-means

Objectif : trouver une partition optimale

Algorithme : *k*-means

Entrées : X, K

Initialisation : $t = 0$ et $\mu_1, \dots, \mu_K \in \mathbb{R}^d$

tant que *pas convergé* **faire**

$t \leftarrow t + 1, \mathcal{C}_1 \leftarrow \emptyset, \dots, \mathcal{C}_K \leftarrow \emptyset$

pour $i = 1, \dots, n$ **faire**

 // Affectation

$h = h^*(x_i) = \arg \min_{k \in \llbracket 1, K \rrbracket} d^2(x_i, \mu_k)$

$\mathcal{C}_h \leftarrow \mathcal{C}_h \cup \{i\}$

pour $k = 1, \dots, K$ **faire**

 // Estimation

$\mu_k \leftarrow \frac{1}{|\mathcal{C}_k|} \sum_{j \in \mathcal{C}_k} x_j$

k-means

Objectif : trouver une partition optimale

Algorithme : *k*-means

Entrées : X, K

Initialisation : $t = 0$ et $\mu_1, \dots, \mu_K \in \mathbb{R}^d$

tant que *pas convergé* **faire**

$t \leftarrow t + 1, \mathcal{C}_1 \leftarrow \emptyset, \dots, \mathcal{C}_K \leftarrow \emptyset$

pour $i = 1, \dots, n$ **faire**

// Affectation

$h = h^*(x_i) = \arg \min_{k \in \llbracket 1, K \rrbracket} d^2(x_i, \mu_k)$

$\mathcal{C}_h \leftarrow \mathcal{C}_h \cup \{i\}$

pour $k = 1, \dots, K$ **faire**


// Estimation

$\mu_k \leftarrow \frac{1}{|\mathcal{C}_k|} \sum_{j \in \mathcal{C}_k} x_j$

Sorties : μ_1, \dots, μ_K et $\mathcal{C}_1, \dots, \mathcal{C}_K$


Exemple (1/3)

Centres initiaux




Exemple (1/3)

Groupes initiaux




Exemple (1/3)

Centres Itération 1




Exemple (1/3)

Groupes Itération 1



Exemple (1/3)

Groupes et Centres finaux



En pratique

- ▶ Initialisation : au hasard ou kmeans++⁽³⁾
- ▶ Faire tourner plusieurs fois, avec différentes initialisations (choisir la meilleure solution au vue de l'inertie)

(3). D. ARTHUR et S. VASSILVITSKII. "k-means++ : The advantages of careful seeding". In : *Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms*. Society for Industrial et Applied Mathematics. 2007, p. 1027-1035.

Théorème (4)

L'algorithme k -means fait décroître l'inertie, et s'arrête donc en un nombre fini d'étapes.

$$\begin{aligned} I(\mu^t, \mathcal{C}^t) &= \sum_{k=1}^K \sum_{i \in \mathcal{C}_k^t} d^2(x_i, \mu_k^t) \geq \sum_{k=1}^K \sum_{i \in \mathcal{C}_k^t} d^2(x_i, \mu_{h^*(x_i)}^t) \quad (\text{affectation}) \\ &= \sum_{k=1}^K \sum_{i \in \mathcal{C}_k^{t+1}} d^2(x_i, \mu_{h^*(x_i)}^t) \geq \sum_{k=1}^K \sum_{i \in \mathcal{C}_k^{t+1}} d^2(x_i, \mu_k^{t+1}) \quad (\text{estimation}) \end{aligned}$$

en remarquant que $h^*(x_i)$ est constant sur \mathcal{C}_k^{t+1} et que

$$\forall \mu \in \mathbb{R}^d, \sum_{i \in \mathcal{C}} d^2(x_i, \mu) \geq \sum_{i \in \mathcal{C}} d^2(x_i, \bar{x}), \text{ avec } \bar{x} = \frac{1}{|\mathcal{C}|} \sum_{i \in \mathcal{C}} x_i$$

Pour la convergence : il n'y a qu'un nombre fini de partitions

Le k -means en quantification

Quantification vectorielle :


- ▶ L'objet de la quantification est de **remplacer** un ensemble de données par une **représentation compacte**, sous la forme de **centroïdes** μ_1, \dots, μ_K .
- ▶ Une mesure de perte, ou de **distorsion**, est l'erreur quadratique moyenne.
- ▶ L'algorithme des k -means permet de sélectionner les centroïdes minimisant le critère quadratique de distorsion.

Application imagerie : compression d'images ou de signaux



$$n = 427 \times 640, d = 3 \text{ (RGB)}$$

Application imagerie : compression d'images ou de signaux



$$K = 2$$

Application imagerie : compression d'images ou de signaux



$$K = 8$$

Application imagerie : compression d'images ou de signaux



$$K = 16$$

Application imagerie : compression d'images ou de signaux



$$K = 32$$

Application imagerie : compression d'images ou de signaux



$$K = 64$$

Géométrie des classes

Définition : Partition de Voronoi

Les K centres μ_1, \dots, μ_K induisent une partition de \mathbb{R}^d appelé la **partition de Voronoi** V_1, \dots, V_K , où :

- ▶ $V_k = \{x \in \mathbb{R}^d : \|x - \mu_k\| \leq \min_{\ell \neq k} \|x - \mu_\ell\|\}$
- ▶ $V_1 \cup \dots \cup V_K = \mathbb{R}^d$
- ▶ $V_k \cap V_\ell = \emptyset$, pour $k \neq \ell$ (aux bords près...).





Les V_k sont appelées **cellules** (de Voronoi)

Affectation des classes :


- ▶ l'observation x_i est affectée à la k -ième classe si $\|x_i - \mu_k\| \leq \min_{\ell \neq k} \|x_i - \mu_\ell\|$
- ▶ dans ce cas, x_i appartient à la **cellule** V_k

Rem: les cellules de Voronoi sont **convexes**

Visualisation



Visualisation



Plan

Introduction

k-means

Modèles de mélanges gaussiens

Mélange de lois

Estimation des paramètres

Définition

Un mélange de lois gaussiennes est une loi dont la densité s'écrit :

$$f(x) = \sum_{m=1}^M \alpha_m \phi(x; \mu_m, \Sigma_m), \quad x \in \mathbb{R}^d,$$

où :

- (i) α_m sont les coefficients du mélange : $\alpha_m \geq 0$ et $\sum_{m=1}^M \alpha_m = 1$.
- (ii) $\phi(\cdot; \mu_m, \Sigma_m)$ est la densité de la loi gaussienne, de moyenne μ_m , et de matrice de covariance Σ_m .

Rem: autres familles de lois possibles (Cauchy, Laplace, t-student,)

Estimation des paramètres du modèle

Paramètres à estimer :


- ▶ les coefficients α_m
- ▶ les moyennes μ_m
- ▶ les matrices de covariance Σ_m ,
- ▶ (souvent) le nombre de composantes du mélange, M

Problème. L'estimation par maximum de vraisemblance est ardue. Sur l'échantillon x_1, \dots, x_n , la vraisemblance s'écrit :

$$L(\theta) = \prod_{i=1}^n f(x_i; \theta) = \prod_{i=1}^n \left(\sum_{m=1}^M \alpha_m \phi(x_i; \mu_m, \Sigma_m) \right).$$


→ Pas de formule analytique pour $\hat{\mu}_m$ et $\hat{\Sigma}_m$ si $M > 1$.

Exemple 2D



$$f(x) = \frac{1}{3}\phi(x; \mu_1, \sigma_1^2) + \frac{2}{3}\phi(x; \mu_2, \sigma_2^2), \text{ tq. } \begin{cases} \mu_1 = 0, \sigma_1 = 0.5 \\ \mu_2 = 5, \sigma_2 = 2 \end{cases}$$

Exemple 2D



Maximum a posteriori

Une fois le modèle ajusté (les coefficients $\hat{\alpha}$, $\hat{\mu}_m$, $\hat{\Sigma}_m$ estimés), on affecte x_i à la classe $\mathcal{C}_{\hat{m}_i}$ défini par

$$\hat{m}_i = \arg \max_m \hat{p}_{im} := \frac{\hat{\alpha}_m \phi(x_i; \hat{\mu}_m, \hat{\Sigma}_m)}{\sum_{r=1}^M \hat{\alpha}_r \phi(x_i; \hat{\mu}_r, \hat{\Sigma}_r)}$$

Interprétation “Variable cachée” / “variable latente”

G_i : variable aléatoire donnant le groupe auquel x_i appartient, c'est une **variable cachée**, *i.e.*, non observée

La probabilité que l'observation x_i soit dans le groupe \mathcal{C}_m s'écrit :

$$\mathbb{P}(G_i = \mathcal{C}_m | X_i = x_i) = \frac{\hat{\alpha}_m \phi(x_i; \hat{\mu}_m, \hat{\Sigma}_m)}{\sum_{r=1}^M \hat{\alpha}_r \phi(x_i; \hat{\mu}_r, \hat{\Sigma}_r)}.$$

Ainsi

$$\hat{m}_i = \arg \max_m \hat{p}_{im}.$$

Lien avec les k -means

Méthode du k -means

- (i) Estimation de M centroïdes.
- (ii) Chaque donnée est affectée au centroïde le plus proche

Modèles de mélange :

- (i) Estimation M moyennes et matrices de covariance.
- (ii) Chaque donnée est affecté au groupe dont la composante du mélange est la plus probable

→ La partition obtenue dépend des centroïdes, mais également des matrices de covariances, qui déterminent la forme des groupes

Principe de l'algorithme EM

Maximisation directe de la vraisemblance difficile \implies approche alternée (comme pour k -means / algorithme de Lloyd)

Algorithme EM Expectation - Maximisation :

Initialisation : choix d'un mélange de départ.

Expectation Pour chaque donné x_i , calculer la probabilité que x_i soit dans le groupe m

Maximization Étant données les affectations des données en groupes, estimer les paramètres μ_m et Σ_m par maximum de vraisemblance

Itérer 2 et 3 jusqu'à convergence

Complexité du modèle

Pour M composantes, avec $x \in \mathbb{R}^d$, les paramètres sont :

- ▶ M moyennes, soit $M \times d$ réels
- ▶ M matrices de covariances, soit $M \times d(d + 1)/2$ réels
- ▶ $(M - 1)$ coefficients α_m

Hypothèses sur la variance

Pour simplifier, rajouter des hypothèses sur les Σ_m , e.g., :

Famille sphérique :

- ▶ $\Sigma_1 = \Sigma_2 = \dots = \Sigma_M = \sigma^2 \text{Id}_d$
- ▶ Pour chaque m , $\Sigma_m = \sigma_m^2 \text{Id}_d$ (spherical)

Famille diagonale :


- ▶ $\Sigma_1 = \Sigma_2 = \dots = \Sigma_M = \text{diag}(\sigma_1^2, \dots, \sigma_d^2)$
- ▶ $\forall m, \Sigma_m = \text{diag}(\sigma_{1,m}^2, \dots, \sigma_{d,m}^2)$ (diag)

Rem: (full) : sans hypothèse, (tied) : covariance partagée


$$\Sigma_1 = \Sigma_2 = \dots = \Sigma_M$$

Exemple


spherical



diag



tied



full

