

# 9. Clustering

---

---

Definiții

Algoritmul  $k$ -means

Convergența algoritmului  $k$ -means

Funcția de distorsiune

---

---

Clustering-ul este o problemă de învățare nesupervizată, în care setul de date de antrenare conține doar caracteristicile  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$  ( $x^{(i)} \in \mathbb{R}^n$ ), etichetele corespunzătoare  $y^{(i)}$  nefiind disponibile. În această situație, obiectivul metodei este de a grupa datele în câteva clustere.

Pașii algoritmului  $k$ -means sunt următorii:

1. inițializarea aleatoare a *centrelor clusterelor*  $\mu_1, \mu_2, \dots, \mu_k \in \mathbb{R}^n$ .
2. repetarea până la convergență: {

Pentru fiecare  $i$  se setează

$$c^{(i)} := \arg \min_j \|x^{(i)} - \mu_j\|^2 \quad (9.1)$$

Pentru fiecare  $j$  se setează

$$\mu^{(j)} := \frac{\sum_{i=1}^m 1\{c^{(i)} = j\}x^{(i)}}{\sum_{i=1}^m 1\{c^{(i)} = j\}} \quad (9.2)$$

}

În metoda prezentată, parametrul algoritmului este  $k$ .  $k$  este numărul de clustere pe care dorim să le găsim, iar centrele clusterelor  $\mu_j$  reprezintă estimatele curente pentru pozițiile centrelor clusterelor. Centrele inițiale ale clusterelor (pasul 1 de mai sus) se pot seta pe valorile a  $k$  exemple de antrenare alese aleatoriu din baza de date de antrenare. Bineînțeles, sunt posibile și alte metode de inițializare.

Bucula internă a algoritmului efectuează repetitiv doi pași: (i) asignează fiecare exemplu de antrenare  $x^{(i)}$  celui mai apropiat centru de cluster  $\mu_j$  și (ii) deplasează fiecare centru de cluster  $\mu_j$  la media punctelor asigurate lui. Două iterații ale algoritmului  $k$ -means sunt ilustrate în figura 9.1.

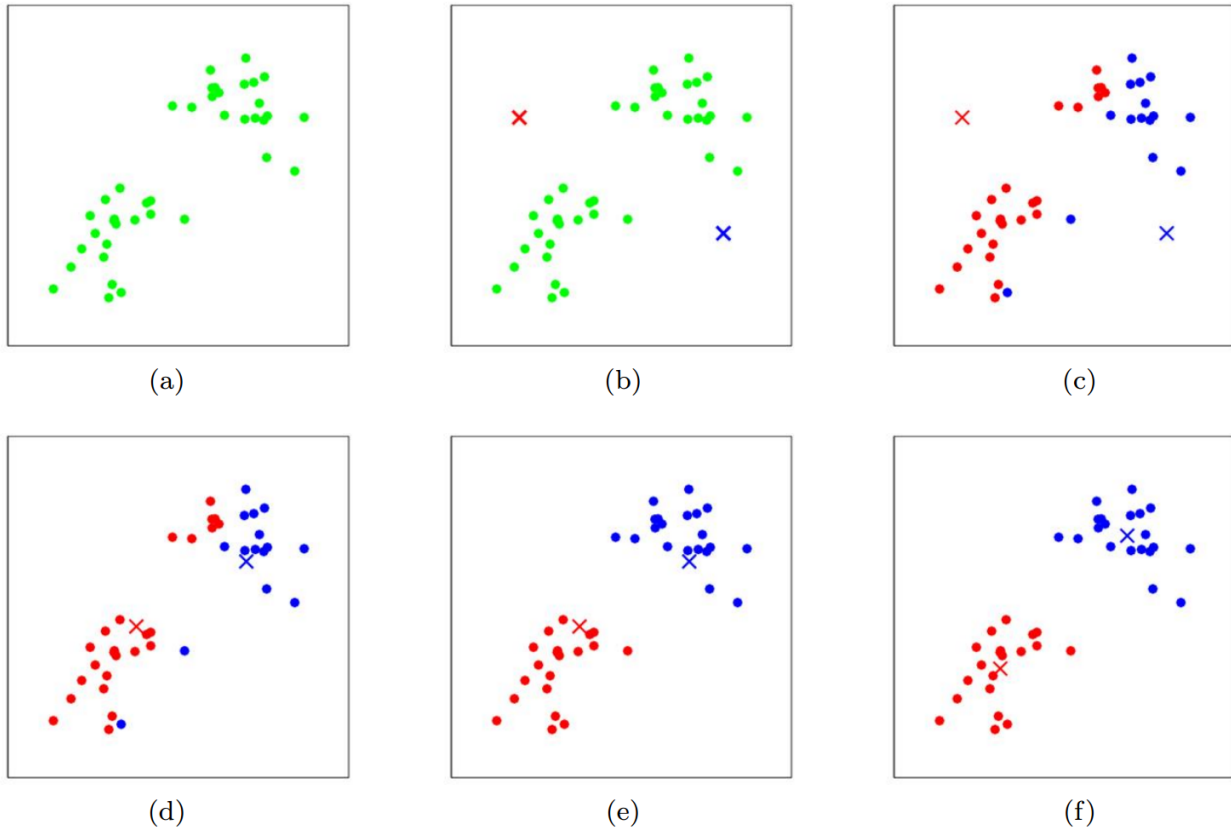


Fig. 9.1 Algoritmul  $k$ -means. Exemplele de antrenare sunt ilustrate sub formă de puncte, iar centrele clusterelor sub formă de  $x$ : (a) setul de date de antrenare original; (b) centrele clusterelor alese aleatoriu (în acest exemplu nu sunt alese ca și două valori din exemplele de antrenare); (c-f) ilustrarea rezultatului după rularea a două iterații ale algoritmului  $k$ -means. În fiecare iterație, fiecare exemplu de antrenare este asignat celui mai apropiat centru de cluster (acest lucru este vizibil prin colorarea fiecărui exemplu de antrenare în culoarea clusterului de care aparține); în pasul următor, deplasăm fiecare centru de cluster la media punctelor ce îi sunt atribuite.

Într-un anumit sens, convergența algoritmului  $k$ -means este garantată. În mod particular, se poate defini funcția de distorsiune ca:

$$J(c, \mu) := \sum_{i=1}^m \|x^{(i)} - \mu_{c(i)}\|^2. \quad (9.3)$$

$J$  măsoară suma pătratică a diferențelor dintre fiecare exemplu de antrenare  $x^{(i)}$  și centrele clusterelor  $\mu_{c(i)}$  cărora exemplele i-au fost atribuite. Se poate demonstra că metoda  $k$ -means este echivalentă minimizării coordonatelor lui  $J$ . În mod particular, bucla internă a algoritmului minimizează  $J$  în mod repetat față de  $c$ , în timp ce  $\mu$  este ținut constant. Apoi, minimizează  $J$  față de  $\mu$ , în timp ce  $c$  este ținut constant. Astfel,  $J$  trebuie să descrească monoton, iar valoarea lui  $J$  trebuie să convergă. (De obicei, acest lucru implică de asemenea faptul că atât  $c$ , cât și  $\mu$ , vor converge. Teoretic, este posibil pentru  $k$ -means să oscileze între câteva configurații de cluster (e.g. câteva valori diferite pentru  $c$  și/sau  $\mu$ ) ce au exact aceeași valoare a funcției  $J$ . Cu toate acestea, acest fenomen se întâmplă foarte rar în

practică.)

Funcția de distorsiune  $J$  este o funcție non-convexă. Astfel, minimizarea coordonatelor lui  $J$  nu garantează convergența către minimul global. Cu alte cuvinte,  $k$ -means este susceptibil la minime locale. Cu toate acestea,  $k$ -means va funcționa optim. În cazul în care se dorește o verificare suplimentară a convergenței, o abordare utilă este rularea algoritmului de mai multe ori, utilizându-se diferite valori aleatoare pentru centrele clusterelor  $\mu_j$ . Din multitudinea de clustere obținute, se poate alege configurația ce întoarce cea mai mică valoare a funcției de distorsiune  $J(c, \mu)$ .

### 9.1 Cerințe

Să se scrie un script Python ce calculează centrele a trei clustere descrise de datele din arhiva "lab9Data.zip".



# Bibliografie

---

---