

Flat clustering

Algoritmul K -means

noiembrie 2017


Flat clustering

- Se presupune dată o colecție de N documente reprezentate ca o mulțime de puncte $D = \{\vec{x}_1, \vec{x}_2, \dots, \vec{x}_N\}$ într-un spațiu vectorial.
- Se dorește împărțirea mulțimii D în K submulțimi distincte $\Omega = \{\omega_1, \omega_2, \dots, \omega_K\}$:

$$\omega_1 \cup \omega_2 \cup \dots \cup \omega_K = D \text{ și } \omega_i \cap \omega_j = \emptyset \text{ dacă } i \neq j$$

Mulțimile $\omega_1, \dots, \omega_K$ se numesc **cluster**e. Fiecare cluster $\omega \in \Omega$ are un **centroid** $\vec{\mu}(\omega)$ care se calculează cu formula $\vec{\mu}(\omega) = \frac{\sum_{\vec{x} \in \omega} \vec{x}}{|\omega|}$

Exemplu: centroidul unui cluster de 3 documente $\omega = \{\vec{x}_1, \vec{x}_2, \vec{x}_3\}$



- Suma reziduală de pătrate (*engl.* residual sum of squares) a unui cluster $\omega_k \in \Omega$ este

$$RSS_k := \sum_{\vec{x} \in \omega_k} |\vec{x} - \vec{\mu}(\omega_k)|^2$$

- Suma reziduală de pătrate a unei partiții $\Omega = \{\omega_1, \dots, \omega_K\}$ este

$$RSS := \sum_{k=1}^K RSS_k$$

- Algoritmul K -means are ca obiectiv să minimizeze valoarea lui RSS pentru o mulțime dată de documente $D = \{\vec{x}_1, \vec{x}_2, \dots, \vec{x}_N\}$.

Algoritmul K-means

Pseudocod

```
K-MEANS( $\{\vec{x}_1, \dots, \vec{x}_N\}, K$ )
1 ( $\vec{s}_1, \dots, \vec{s}_K$ ) := SELECTRANDOMSEEDS( $\{\vec{x}_1, \dots, \vec{x}_N\}, K$ )
2 for  $k := 1$  to  $K$  do
3    $\vec{\mu}_k := \vec{s}_k$ 
4 while criteriul de terminare nu este satisfăcut do
5   for  $k := 1$  to  $K$  do
6      $\omega_k := \emptyset$ 
7     for  $n := 1$  to  $N$  do
8        $j := \arg \min_{j'} |\vec{\mu}_{j'} - \vec{x}_n|$ 
9        $\omega_j := \omega_j \cup \{\vec{x}_n\}$  (reatribuirea vectorilor în clustere)
10    for  $k := 1$  to  $K$  do
11       $\vec{\mu}_k := \frac{1}{|\omega_k|} \sum_{\vec{x} \in \omega_k} \vec{x}$ 
12 return  $\{\vec{\mu}_1, \dots, \vec{\mu}_K\}$ 
```



Observații

- Mai întâi, se aleg la întâmplare K centroizi inițiali de clustere (engl. *seeds*)
- algoritmul repetă modificarea centrelor inițiale încât să minimizeze RSS : la fiecare iterație: (1) se reatribuie fiecare vector $\vec{x}$ în clusterul centroidului celui mai apropiat de $\vec{x}$ și apoi (2) se recalculează coordonatele centrozilor

Algoritmul K -means

Exemplu ilustrat


Evoluția algoritmului




Algoritmul K-means

Exemplu ilustrat

Evoluția algoritmului în 9 iterații:



recomputation/movement of $\vec{\mu}$'s (iter. 1)




$\vec{\mu}$'s after convergence (iter. 9)

Algoritmul K -means

Exemplu ilustrat

Evoluția algoritmului în 9 iterații:



Algoritmul K -means

Criterii posibile de terminare

- 1 După un număr prestabilit de iterații
- 2 Când se ajunge la o iterație care nu modifică atribuirea documentelor în clustere
- 3 Când centroizii $\vec{\mu}_k$ nu se mai schimbă de la o iterație la alta
- 4 Când RSS devine mai mică decât o valoare prestabilită
- 5 Când diferența dintre două RSS -uri consecutive este mai mică decât o valoare θ

Algoritmul K -means

Criterii posibile de terminare

- 1 După un număr prestabilit de iterații
- 2 Când se ajunge la o iterație care nu modifică atribuirea documentelor în clustere
- 3 Când centroizii $\vec{\mu}_k$ nu se mai schimbă de la o iterație la alta
- 4 Când RSS devine mai mică decât o valoare prestabilită
- 5 Când diferența dintre două RSS -uri consecutive este mai mică decât o valoare θ

REMARCĂ: K -means converge în sensul că dacă definim

$$RSS_k(\vec{v}) = \sum_{\vec{x} \in \omega_k} |\vec{v} - \vec{x}|^2 \quad \text{și} \quad RSS(\vec{v}_1, \dots, \vec{v}_K) = \sum_{k=1}^K RSS_k(\vec{v}_k)$$

atunci $(\vec{\mu}_1, \dots, \vec{\mu}_K)$ este punct de **minim local** pentru $RSS(\vec{v}_1, \dots, \vec{v}_K)$ *(vezi slide următor)*

Algoritmul K -means

De ce converge RSS ?

Presupunem că documentele sunt puncte în spațiul euclidian M -dimensional $\mathbb{R}^M$

$$\Rightarrow RSS_k(\vec{v}) = \sum_{\vec{x} \in \omega_k} \sum_{m=1}^M (v_m - x_m)^2$$

$$\Rightarrow \frac{\partial RSS_k(\vec{v})}{\partial v_m} = \sum_{\vec{x} \in \omega_k} 2(v_m - x_m)$$

Proprietăți ale algoritmului K -means

- 1 În pașii 8-9, $RSS(\vec{v}_1, \dots, \vec{v}_K) = \sum_{k=1}^K \sum_{\vec{x} \in \omega_k} |\vec{v}_k - \vec{x}|^2$ scade pentru $\vec{v} = (\vec{\mu}_1, \dots, \vec{\mu}_k)$ deoarece fiecare document $\vec{x} \in \omega_k$ este reatribuit în clusterul ω_j pentru care $|\vec{v}_j - \vec{x}| \leq |\vec{v}_k - \vec{x}|$
- 2 În pașii 10-11 se recalculează fiecare $\vec{\mu}_k$ a.î. fiecare $RSS_k(\vec{v})$ să ia valoarea minimă pentru $\vec{v} = \vec{\mu}_k$.


Algoritmul K -means

Limitări

Este de dorit să se calculeze K centroizi ($\vec{\mu}_1, \dots, \vec{\mu}_K$) care sunt un **minim global** pentru RSS

- Algoritmul K -means garantează calculul unui **minim local**
 - Uneori, minim local $\neq$ minim global
 - Rezultatul calculat depinde de centroizii inițiali aleși
 - ▶ selecția unui centroid inițial îndepărtat de celelalte documente produce generarea de **clustere singleton**, sau clustere vide.

EXEMPLU:



- ▶ K -means pt. centroizii inițiali d_2 și d_5 converge la $\{\{d_1, d_2, d_3\}, \{d_4, d_5, d_6\}\}$
- ▶ K -means pt. centroizii inițiali d_2 și d_3 converge la $\{\{d_1, d_2, d_4, d_5\}, \{d_3, d_6\}\}$

Complexitatea algoritmului

- ▶ Distanța dintre două puncte în $\mathbb{R}^M$ durează ...
- ▶ Pașii 7-9 (reatribuirea în clustere) durează ...
- ▶ Pașii 10-11 (recalcularea centroizilor) durează ...
- ▶ K -means care efectuează I iterații durează ...

Determinarea numărului K de clustere

Metode euristice

Se presupune dată o mulțime de N documente: $D = \{\vec{x}_1, \dots, \vec{x}_N\}$

- Algoritmul K -means ia ca **parametru de intrare** valoarea lui K și calculează K centroizi pentru K clustere $\omega_1, \dots, \omega_K$
- Uneori e greu de să se estimeze o valoare bună pentru K

Problemă: Cum putem găsi o valoare plauzibilă pentru K ?

Determinarea numărului K de clustere

Metode euristice

Se presupune dată o mulțime de N documente: $D = \{\vec{x}_1, \dots, \vec{x}_N\}$

- Algoritmul K -means ia ca **parametru de intrare** valoarea lui K și calculează K centroizi pentru K clustere $\omega_1, \dots, \omega_K$
- Uneori e greu de să se estimeze o valoare bună pentru K

Problemă: Cum putem găsi o valoare plauzibilă pentru K ?

EURISTICA 1: RSS să aibe valoare minimă:

⇒ Dacă $K = N$ atunci $\omega_i = \{\vec{x}_i\}$ pentru $1 \leq i \leq K$ și $RSS = 0$.
Deși $RSS = 0$, acesta nu este un clustering optim: **sunt prea multe clustere!**

Determinarea numărului K de clustere

Metode euristice

Se presupune dată o mulțime de N documente: $D = \{\vec{x}_1, \dots, \vec{x}_N\}$

- Algoritmul K -means ia ca **parametru de intrare** valoarea lui K și calculează K centroizi pentru K clustere $\omega_1, \dots, \omega_K$
- Uneori e greu de să se estimeze o valoare bună pentru K

Problemă: Cum putem găsi o valoare plauzibilă pentru K ?

EURISTICA 1: RSS să aibe valoare minimă:


⇒ Dacă $K = N$ atunci $\omega_i = \{\vec{x}_i\}$ pentru $1 \leq i \leq K$ și $RSS = 0$.
Deși $RSS = 0$, acesta nu este un clustering optim: **sunt prea multe clustere!**

EURISTICA 2: Pentru mai multe valori valori ale lui K , se calculează $\widehat{RSS}_{\min}(K) = \min\{rss_1, \dots, rss_i\}$ unde rss_j ($1 \leq j \leq i$) este valoarea lui RSS pentru un set de K centroizi inițiali $(\vec{s}_{j,1}, \dots, \vec{s}_{j,K})$. i are o valoare prestabilită, de ex., $i = 10$.

Se alege K pentru care vectorul $(\widehat{RSS}_{\min}(K+1) - \widehat{RSS}_{\min}(K), 1)$ începe să-și mențină direcția.

Determinarea numărului K de clustere

Estimarea valorii lui K cu euristica 2



Exemplu ilustrat pentru o mulțime de 1203 documente Reuters-RCV1

- ▶ curba $\widehat{RSS}_{\min}$ se netezește semnificativ după $K = 4$ și $K = 9$
 $\Rightarrow$ 4 și 9 sunt valori plauzibile pentru K .
- ▶ pentru $K = 4$, algoritmul K -means calculează centroizi în jurul categoriilor *China*, *Germany*, *Russia* și *Sports*.

Determinarea numărului K de clustere

Alte euristici

- ▶ Minimizarea distorsiunii ca măsură a complexității modelului

$$K = \arg \min_K (RSS_{\min}(K) + \lambda K)$$

unde $0 \leq \lambda \leq 1$ este un factor de pondere.

- ▶ Criteriul AIC (engl. *Aikake Information Criterion*) are forma generală

$$K = \arg \min_K (-2 L(K) + 2 q(K))$$

unde ...

Pentru algoritmul K means, are forma specială

$$K = \arg \min_K (RSS_{\min}(K) + 2 M K)$$

Christopher D. Manning, Prabhakar Raghavan, Hinrich Schütze:
Capitolul 16 din **AN INTRODUCTION TO INFORMATION
RETRIEVAL**.
Ediție online (c) 2009 Cambridge UP.