


# **k-Srednjih vrednosti (k-Means)**

TEHNIKA KLASTEROVANJA UZORAKA


# Klasterovanje





# K-means

- ▶ Najpoznatiji i najjednostavniji algoritam klasterovanja (klasterizacije)
- ▶ Pripada tehnikama nenadgledanog učenja
- ▶ Sličnost instanci se može procenjivati primenom neke od mera za računanje:
  - ▶ Sličnosti (npr. kosinusna sličnost ili koeficijent korelacije)
  - ▶ Udaljenosti dve instance (npr. Euklidsko ili Menhetn rastojanje)



# Rastojanje





# K-means (1) - Inicialno





## K-means (2) – Iteracija br. 1




## K-means (3) – Iteracija br. 2



## K-means (4) – Iteracija br. 3



# K-means (5) - Završetak



# K-means - Ulazni podaci

- ▶ Ulaz:
  - ▶ K – broj klastera
  - ▶ skup za trening sa m uzoraka (instanci), a svaki uzorak u skupu je vektor opisan sa n atributa ( $x_1, x_2, \dots, x_n$ )
  - ▶ Opciono: maksimalan broj iteracija koji se izvršava (max)

# K-means – Koraci algoritma

- ▶ 1) Slučajan odabir K težišta klastera (centroida)
- ▶ 2) Grupisanje po klasterima - svaki uzorak (instancu) dodeljujemo najbližem centroidu (najbliže težište na osnovu odabrane metrike)
- ▶ 3) Pomeranje težišta (centroida) ka centru svih uzoraka u klasteru – za svaki klaster se izračuna novo težište uzimajući prosek instanci koje su dodeljene tom klasteru
- ▶ Koraci 2) i 3) se ponavljaju sve dok algoritam ne konvergira ili broj iteracija ne dostigne MAX

# K-means - Funkcija koštanja/distorzije

- ▶ Smisao K-means algoritma je minimizacija funkcije koštanja J (eng. cost function):

$$J(c^{(1)}, \dots, c^{(m)}, \mu_{(1)}, \dots, \mu_K) = \frac{1}{m} \sum_{i=1}^m \|x^{(i)} - \mu_{c^{(i)}}\|^2$$

$x^{(i)}$  – i-ta instanca u skupu podataka za trening,  $i = 1, \dots, m$

$c^{(i)}$  – indeks klastera u koji je instanca  $x^{(i)}$  trenutno raspoređena

$\mu_j$  – težište klastera  $j$ ,  $j = 1, \dots, K$ , gde je  $K$  ukupan broj klastera

$\mu_{c(i)}$  – težište klastera u koji je instanca  $x^{(i)}$  trenutno raspoređena

# Minimizacija funkcije koštanja


- ▶ Minimizacija funkcije koštanja  $J$  kroz K-means algoritam:
  - ▶ Faza Grupisanja po klasterima (korak 2) minimizuje  $J$  po parametrima  $c^1, c^2, \dots, c^m$ , držeći  $\mu_1, \mu_2, \dots, \mu_k$  fiksnim
  - ▶ Faza Pomeranja težišta minimizuje  $J$  po parametrima  $\mu_1, \mu_2, \dots, \mu_k$ , držeći  $c^1, c^2, \dots, c^m$ , fiksnim

# K-means evaluacija

- ▶ Da li imamo tačno rešenje?
- ▶ Kriterijumi za procenu kvaliteta kreiranih klastera
  - ▶ Međusobna udaljenost težišta
  - ▶ Standardna devijacija pojedinačnih instanci u odnosu na težište
  - ▶ Suma kvadrata unutar klastera

# Problem inicijalnog izbora težišta

- ▶ U zavisnosti od inicijalnog izbora težišta:
  - ▶ K-means algoritam može konvergirati brže ili sporije
  - ▶ Može se doći do lokalnog minimuma i time imamo loše rešenje (lokalni minimum funkcije koštanja)



# K-means - višestrukna nasumična inic.

- ▶ Omogućava da se izbegne ulazak u lokalni minimum
- ▶ Sastoji se u sledećim koracima:

```
for i = 1 to N { // N obично има вредности између 50 и 1000
    Nasumično odabratи иницијални скуп тежишта
    Izvršiti K-means алгоритам
    Израчунати функцију коштанја
}
```

Izabratiinstancu algoritma koja daje najmanju vrednost funkcije koštanja.
- ▶ Ovaj pristup daje dobre rezултате уколико је број кластера relativно мали (између 2 и 10), за већи број кластера не треба да се користи.

# K-means ++ algoritam


## ► Alternativno rešenje

1. Initialize an empty set  $\mathbf{M}$  to store the  $k$  centroids being selected.
2. Randomly choose the first centroid  $\mu^{(j)}$  from the input samples and assign it to  $\mathbf{M}$ .
3. For each sample  $x^{(i)}$  that is not in  $\mathbf{M}$ , find the minimum squared distance  $d(x^{(i)}, \mathbf{M})^2$  to any of the centroids in  $\mathbf{M}$ .
4. To randomly select the next centroid  $\mu^{(p)}$ , use a weighted probability distribution equal to  $\frac{d(\mu^{(p)}, \mathbf{M})^2}{\sum_i d(x^{(i)}, \mathbf{M})^2}$ .
5. Repeat steps 2 and 3 until  $k$  centroids are chosen.
6. Proceed with the classic k-means algorithm.

# K-means: Kako odrediti K?

- ▶ Kako odrediti broj klastera K?
  - ▶ Ukoliko imamo znanje o oblasti/pojavi koju podaci opisuju
    - ▶ Prepostaviti broj K na osnovu domenskog znanja
    - ▶ Testirati model sa K-1, K i K+1 klastera i uporediti grešku
  - ▶ Ukoliko ne posedujemo znanje o oblasti/pojavi koju podaci opisuju
    - ▶ Krenuti od malog broja iteracija i u više iteracija testirati model uvek sa jednim klasterom više
    - ▶ U svakoj iteraciji uporediti grešku (nekom metodom) tekućeg i prethodnog modela i kad smanjenje greške postane zanemarljivo, prekinuti postupak

# Primer kada nemamo znanje o domenu



# Hard vs Soft klasterovanje

- ▶ Hard klasterovanje – grupa algoritama gde svaki uzorak (instanca) u skupu je dodeljena tačno jednom klasteru
- ▶ Soft (Fuzzy) klasterovanje – uzorak dodeljen više klastera  
(primer: fuzzy C-means, ili soft k-means)

$$\begin{bmatrix} \mu^{(1)} \rightarrow 0 \\ \mu^{(2)} \rightarrow 1 \\ \mu^{(3)} \rightarrow 0 \end{bmatrix}$$

$$\begin{bmatrix} \mu^{(1)} \rightarrow 0.1 \\ \mu^{(2)} \rightarrow 0.85 \\ \mu^{(3)} \rightarrow 0.05 \end{bmatrix}$$

# Expectation-Maximization algoritam

- ▶ EM algoritam spada u grupu probabilističke klasterizacija
- ▶ Ideja: uzorci nam ne pripadaju jednom i samo jednom klasteru, već svaki uzorak sa određenom verovatnoćom pripada svakom od klastera
- ▶ Ova vrsta klasterizacije podrazumeva:
  - ▶ Svaki klaster je opisan određenom verovatnoćom (jedna raspodela zajednička za sve atributе kojima su uzorci opisani ili više raspodela, po jedna za svaki od atributa)
  - ▶ Postoji i raspodela verovatnoća koja karakteriše pripadnost klasteru.

# Probabilističko klasterovanje

- ▶ Svi uzorci su opisani jednim numeričkim atributom koji ima Normalnu raspodelu u svim klasterima (ukupno K klastera)
- ▶ Svaki klaster  $C_i$  ima specifične vrednosti parametara Normalne raspodele – srednje vrednosti i standardne devijacije
- ▶  $p_i$  predstavlja prior probability i-tog klastera  $C_i$ , odnosno verovatnoću da nasumice odabrana instanca pripada klasteru  $C_i$
- ▶ Dobili smo skup uzoraka (instanci) za koje znamo da dolaze iz opisanih K klastera, ali ne znamo iz kojih, niti znamo parametre modela ( $\mu_i, \sigma_i, p_i$ , gde je  $i = 1, \dots, K$ )
- ▶ Za svaku instancu treba odrediti verovatnoću pripadnosti svakom od K klastera

# EM algoritam

- ▶ Opisani problem se može rešiti primenom postupka koji predstavlja generalizaciju K-means algoritma:
- ▶ 1) Inicijalno, definisati broj klastera ( $k$ ) i nasumice izabrati vrednosti parametara modela ( $\mu_i, \sigma_i, p_i, i=1,k$ )
- ▶ 2) Za date vrednosti parametara, za svaku instancu iz dataset-a, izračunati verovatnoću pripadanja svakom od klastera
- ▶ 3) Na osnovu izračunatih verovatnoća pripadnosti klasterima, odrediti nove vrednosti parametara modela
- ▶ Iterativno ponavljati korake 2) i 3) dok vrednosti parametara ne počnu da konvergiraju

# Koraci kod EM algoritma (1)

- ▶ Sastoji se iz:
- ▶ Korak **Inicijalizacije (I)** – središta klastera na osnovu inicijalno postavljenih vrednosti parametara modela
- ▶ **E (expectation) korak** – u ovom koraku podrazumevamo da znamo vrednosti parametara modela i na osnovu njih, za svaku instancu, računamo verovatnoću pripadanja svakom od klastera
- ▶ **M (maximization) korak** – na osnovu datih instanci, računamo (ponovo) vrednosti parametara modela; maksimizacija se odnosi na usklađivanje (parametara) modela sa datim podacima

# Koraci kod EM algoritma (2)

## E korak

- ▶ Za svaku instancu iz skupa podataka  $x_j$  ( $j=1,n$ ) računamo verovatnoću pripadanja  $i$ -tom klasteru  $C_i$  ( $i=1,k$ ):

$$e_{ij} = p_i * P(x_j | C_i)$$

- ▶  $P(x_j | C_i)$  se računa primenom funkcije Normalne raspodele  $f(x; \mu, \sigma)$

## M korak

- ▶ Određuju se nove vrednosti parametara modela:

- ▶ prior probability

$$p_i = \sum_j \frac{e_{ij}}{n}$$

- ▶ srednja vrednost

$$\mu_i = \frac{\sum_j e_{ij} * x_j}{\sum_j e_{ij}}$$

- ▶ varijansa

$$\sigma_i^2 = \frac{\sum_j e_{ij} * (x_j - \mu_i)^2}{\sum_j e_{ij}}$$

# Koraci kod EM algoritma (3)

## Konvergencija

- ▶ Koraci algoritma se ponavljaju sve dok ima značajne promene (tj. porasta) loga ukupne verovatnoće modela (overall log-likelihood):

$$\log P(x) = \log \sum_i (p_i * P(x|C_i))$$


- ▶ Tipično, ova vrednost intenzivno raste tokom prvih nekoliko iteracija algoritma, a zatim vrlo brzo dolazi u stanje gde skoro da nema promene

# Organizacija klastera kao hijerarhijsko stablo


- ▶ Alternativni pristup klasterovanju zasnovanom na prototipu je hijerarhijsko klasterovanje
- ▶ Prednosti ovog pristupa:
  - ▶ crtanje Dendrograma (vizuelizacija hijerarhijskog klasterovanja)
  - ▶ ne treba da preciziramo broj klastera unapred
- ▶ Dva osnovna tipa:
  - ▶ Aglomerativno klasterovanje
  - ▶ Podeljeno hijerarhijsko klasterovanje

# Aglomerativno klasterovanje


- ▶ Dva standardna algoritma:
  - ▶ algoritam sa jednostrukom vezom  
(eng. single linkage)
  - ▶ algoritam sa potpunom vezom  
(eng. complete linkage)
- ▶ Algoritam sa jednostrukom vezom: izračunavamo udaljenosti između najsličnijih članova za svaki par klastera i spajamo dva klastera za koje je udaljenost između najsličnijih članova najmanja
- ▶ Algoritam sa potpunom vezom: ne upoređujemo najsličnije članove u svakom paru klastera, već upoređujemo najviše različitih članova kako bismo obavili spajanje



# Izlaz: dijagram sa klasterima



# Izlaz: dendrogram



# Izlaz: heat map

