

KLASTERIZACIJA

JELENA JOVANOVIĆ

Email: jeljov@gmail.com

Web: <http://jelenajovanovic.net>

PREGLED PREDAVANJA

- Šta je klasterizacija?
- Koje su oblasti/primeri primene?
- Klasterizacija primenom K-Means algoritma
 - Upoznavanje sa algoritmom kroz primer
 - K-Means algoritam
 - Potencijalni problemi pri primeni algoritma
 - Primer primene u WEKA-i

ŠTA JE KLASTERIZACIJA?

Klasterizacija je jedan od oblika nenadgledanog m. učenja

- ono što je raspoloživo od podataka su podaci oinstancama koje je potrebno na neki način grupisati;
- ne posedujemo podatke o poželjnoj / ispravnoj grupi za ulazne instance

ŠTA JE KLASTERIZACIJA?

Klasterizacija je zadatak grupisanja instanci, tako da za svaku instancu važi da je *sličnija* instancama iz svoje grupe (klastera), nego instancama iz drugih grupa (klastera)

Sličnost instanci se određuje primenom neke od mera za računanje

- sličnosti (npr. Kosinusna sličnost) ili
- udaljenosti dva objekta (npr. Euklidska udaljenost)




ŠTA JE KLASTERIZACIJA?

Za razliku od klasifikacije, ovde nemamo “tačno” rešenje

- ocena uspešnosti algoritma je dosta teža nego kod klasifikacije
- pogodnost rešenja zavisi od domena i slučaja primene – jedno isto rešenje može biti različito ocenjeno u različitim slučajevima primene
- zahteva angažovanje domenskih eksperata koji će evaluirati rešenje

Primer različitih dobrih
rešenja za isti polazni skup
podataka

T-shirt sizing



OBLASTI PRIMENE

- Segmentacija tržišta
- Uočavanje grupa u društvenim mrežama
- Identifikacija paterna u ponašanju korisnika nekog Web sajta
- Grupisanje objekata (npr., slika/dokumenata) prema zajedničkim karakteristikama
- ...

K-MEANS ALGORITAM


K-MEANS

Jedan od najpoznatijih i najjednostavnijih algoritama klasterizacije


Najlakše ga je razumeti na primeru, pa ćemo prvo razmotriti jedan primer

K-MEANS ALGORITAM – PRIMER

Prepostavimo da su ovo ulazni podaci kojima raspolažemo, opisani vrednostima dva atributa




K-MEANS: PRIMER




Inicijalizacija:
Inicijalni izbor težišta
klastera ($K = 2$) metodom
slučajnog izbora

K-MEANS: PRIMER




Iteracija 1, korak 1:
razvrstavanje instanci po
klasterima na osnovu
udaljenosti od težišta
klastera

K-MEANS: PRIMER




Iteracija 1, korak 2:
određivanje novog
težišta za svaki klaster,
na osnovu proseka
vrednosti instanci u
datom klasteru

K-MEANS: PRIMER




Iteracija 2, korak 1:
(ponovno) razvrstavanje
instanci po klasterima na
osnovu udaljenosti od
težišta klastera

K-MEANS: PRIMER




Iteracija 2, korak 2:
Ponovno određivanje
novog težišta za svaki
klaster

K-MEANS: PRIMER




Iteracija 3, korak 1:
(ponovno) razvrstavanje
instanci po klasterima na
osnovu udaljenosti od
težišta klastera

K-MEANS: PRIMER



Iteracija 3, korak 2:
Ponovno određivanje
novog težišta za svaki
klaster

K-MEANS: PRIMER



Algoritam već konvergira:
dalje iteracije neće
dovesti do značajnijih
promena i proces se
zaustavlja

K-MEANS: ALGORITAM

Ulaz:

- K - broj klastera
- (neobeležen) skup za trening sa m instanci; svaka instanca u skupu je vektor opisan sa n atributa (x_1, x_2, \dots, x_n)
- max - max broj iteracija (opcioni parametar)

K-MEANS: ALGORITAM

Koraci:

- 1) Inicialni izbor težišta klastera, slučajnim izborom
 - težišta se biraju iz skupa instanci za trening, tj. K instanci za trening se nasumično izabere i proglaši za težišta
- 2) Ponoviti dok algoritam ne konvergira ili broj iteracija $<= max$:
 - 1) *Grupisanje po klasterima*: za svaku instancu iz skupa za trening, $i = 1, m$, identifikovati najbliže težište i dodeliti instancu klasteru kome to težište pripada
 - 2) *Pomeranje težišta*: za svaki klaster izračunati novo težište uzimajući prosek tačaka (instanci) koje su dodeljene tom klasteru

K-MEANS ALGORITAM: FUNKCIJA KOŠTANJA

Smisao K-means algoritma je *minimizacija funkcije koštanja J* (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, $i=1,m$

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

μ_j – težište klastera j , $j=1,K$

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

Ova funkcija se zove i funkcija distorzije (distortion function)

K-MEANS ALGORITAM: FUNKCIJA KOŠTANJA

$$\min_{\substack{c^{(1)}, \dots, c^{(m)}, \\ \mu_1, \dots, \mu_K}} J(c^{(1)}, \dots, c^{(m)}, \mu_1, \dots, \mu_K)$$

Minimizacija funkcije koštanja J kroz K-means algoritam:

- faza *Grupisanja po klasterima* minimizuje J po parametrima $c^{(1)}, \dots, c^{(m)}$, držeći μ_1, \dots, μ_K fiksnim
- faza *Pomeranja težišta* minimizuje J po parametrima μ_1, \dots, μ_K , držeći $c^{(1)}, \dots, c^{(m)}$ fiksnim

K-MEANS: EVALUACIJA


Kriterijumi za procenu “kvaliteta” kreiranih klastera:

- Međusobna udaljenost težišta
 - što su težišta dalje jedno od drugog, to je stepen preklapanja klastera manji, i njihov kvalitet viši
- St. devijacija pojedinačnih instanci u odnosu na težište
 - što je st. devijacija manja, to su instance tešnje grupisane oko težišta i klasteri se smatraju boljim
- Suma kvadrata greške unutar klastera (within cluster sum of squared errors)
 - daje kvantitativnu meru za procenu kvaliteta kreiranih klastera
 - razmotrićemo detaljnije na primeru (slajd 23)


K-MEANS: PROBLEM INICIJALNOG IZBORA TEŽIŠTA

Zavisno od inicijalnog izbora težišta:

- K-means algoritam može konvergirati brže ili sporije;
- Takođe, može “upasti” u tzv. lokalni minimum i dati loše rešenje
 - reč je o lokalnom min. funkcije koštanja



Dобра иницијализација



Иницијализација која води у локалне минимуме

K-MEANS:

VIŠESTRUKA NASUMIČNA INICIJALIZACIJA

Omogućuje da se izbegnu situacije koje K-means dovode u lokalni minimum

Sastoje se u sledećem:

```
for i = 1 to n { //n obično uzima vrednosti 50 - 1000
    Nasumično odabratи inicialni skup težišta;
    Izvršiti K-Means algoritam;
    Izračunati funkciju koštanja (cost function)
}
```

Izabratи instancu algoritma koja daje najmanju vrednost za f. koštanja

Ovaj pristup daje dobre rezultate ukoliko je broj klastera relativno mali (2 - 10); za veći broj klastera ne bi ga trebalo koristiti

K-MEANS: KAKO ODREDITI K?

Kako odrediti broj klastera K?

- U slučaju da posedujemo znanje o fenomenu/pojavi koju podaci opisuju
 - Prepostaviti broj klastera (K) na osnovu domenskog znanja
 - Testirati model sa K-1, K, K+1 klastera i uporediti grešku*
- Ukoliko ne posedujemo znanje o fenomenu/pojavi
 - Krenuti od malog broja klastera i u više iteracija testirati model uvek sa jednim klasterom više
 - U svakoj od iteracija, uporediti grešku* tekućeg i prethodnog modela i kad smanjenje greške postaje zanemarljivo, prekinuti postupak

*Na primer, within cluster sum of squared errors

K-MEANS: PRIMER PRIMENE U WEKA-I

Primer je preuzet iz članka sa IBM Developer Works sajta:

<http://www.ibm.com/developerworks/library/os-weka2/>

ZAHVALNICA I PREPORUKA

Stanford Machine Learning

Andrew Ng

Learn about the most effective machine learning techniques, and gain practice implementing them and getting them to work for yourself.

Workload: 5-7 hours/week

Taught In: English

Subtitles Available In: English

Preview



Sessions:

Oct 14th 2013 (10 weeks long)

[Sign Up](#)

Apr 22nd 2013 (10 weeks long)

[Sign Up](#)

3,484

12k

13k

[Tweet](#)

[+1](#)

[Like](#)

Coursera:

<https://www.coursera.org/course/ml>

Stanford YouTube channel:

http://www.youtube.com/view_play_list?p=A89DCFA6ADACE599

(Anonimni) upitnik za vaše kritike,
komentare, predloge:

<http://goo.gl/cqdp3I>