Mašinsko učenje

Klasterovanje

Nemanja Maček

Sadržaj

Uvodne napomene

U čemu je razlika između klasifikacije i klasterovanja?

- Na prethodnom predavanju bavili smo se klasifikacijom kao vidom nadgledanog učenja.
- Podaci za obuku modela su bili obeleženi, a obučen model se na dalje koristio za klasifikaciju prethodno nepoznatih instanci.
- Postavljamo sledeće pitanje: šta možemo da uradimo ukoliko nemamo obeležene instance za obuku modela?
- Očigledno, model klasifikacije ne možemo da izgradimo. Ali možemo da pronađemo određene šablone u podacima.

Uvodne napomene

Formalno rečeno (podsetnik) ...

- U savremenoj oblasti mašinskog učenja dominiraju sledeći pristupi:
  - induktivno učenje,
  - analitičko učenje (analogija sa logikom),
  - učenje na slučajevima (engl. *case-based learning* – analogija sa ljudskim pamćenjem),
  - neuralne mreže (analogija sa neurobiologijom),
  - genetski algoritmi (analogija sa evolucijom) i
  - hibridni modeli (kombinacija više pristupa).
- Od najvećeg značaja za tekuću praksu u domenu računarstva i veštačke inteligencije je induktivno učenje.
- Suština ovog tipa učenja je učenje na osnovu raspoloživih primera. U svakodnevnom jeziku to možemo da nazovemo: učenje iz iskustva (drugih).
- S obzirom na objekat učenja najopštije je učenje funkcionalnih, tj. ulazno-izlaznih preslikavanja.

Uvodne napomene

Formalno rečeno (podsetnik) ...

- Ključni elementi u induktivnom učenju funkcionalnih preslikavanja su: nepoznato preslikavanje, obučavajuci skup ulazno – izlaznih parova i skup hipoteza unutar koga biramo finalnu hipotezu putem algoritma obučavanja.
- Ulazi su po pravilu *n*-dimenzioni vektori. U literaturi se pominju pod nazivima: vektori obeležja, uzorci, primeri i instance.
- Komponente ulaznih vektora se nazivaju obeležja ili atributi i mogu biti: kontinualni (beskonačan broj vrednosti) i diskretni (konačan broj vrednosti).
- Izlazni prostor može biti: kategorijalan sa *K* distikntnih vrednosti, kada obučeni sistem obavlja klasifikaciju (izlaz se naziva oznaka, klasa, kategorija ili odluka) ili realan, kada obučeni sistem realizuje regresiju (funkcionalni estimator).

Uvodne napomene

Formalno rečeno (podsetnik) ...

- Grubo, vrste obučavanja možemo da podelimo na: obučavanje sa učitenjem, obučavanje bez učitelja i obučavanje sa podsticajem (engl. *reinforcement learning*).
- Za obučavanje sa učiteljem, tj. nadgledano obučavanje (engl. *supervised learning*) važi:
  - obučavajući skup je oblika $\{xi, f(xi)\}$, gde je $f(xi)$ ciljna vrednost vektora obeležja x_i,
  - zadatak obučavanja je nalaženje aproksimacije za f, a
  - mera performansi je kvalitet aproksimaciije u tačkama koje ne pripadaju obučavajućem skupu.
- Za obučavanje bez učitelja, tj. nenadgledano obučavanje (engl. *unsupervised learning*) važi da su u obućavajućem skupu su prisutne samo ulazne instance x_i.
- Tipičan pristup nenadgledanom učenju je klasterovanje, odnosno grupisanje raspoloživih podataka u manji broj grupa unutar kojih su podaci sličniji u poređenju sa podacima iz ostalih grupa. Imenovanjem klastera se dolazi posrednim putem do označenih uzoraka.

Uvodne napomene

Šta ćemo raditi na ovom predavanju?

- Transformisaćemo postove iz grupa vesti (engl. *newsgroup*) u vektore pogodne za dalju obradu koristeći tzv. *bag of words* pristup,
- grupisati postove u klastere koristeći K-sredina (engl. *K-means*) algoritam i
- izdvojiti postove koji su povezani (dovoljno slični) sa novim postom, tj. postom koji nije bio prisutan u početnom skupu postova.

Merenje povezanosti postova

Da li je običan, neobrađen tekst od koristi?

- Sa stanovišta mašinskog učenja, običan, odnosno nepredprocesiran tekst, nam je u najvećem broju slučajeva beskoristan.
- Međutim, tekst koji smo na neki način pretvorili u numeričke vrednosti od značaja je u nekim slučajevima upotrebljiv – na takve podatke mogu se primeniti određeni algoritmi, poput klasterovanja.
- Ovo važi za neke operacije nad tekstom, kao što je merenje sličnosti.

Merenje povezanosti postova

Kako ne treba rešavati problem?

- Minimalno rastojanje između dva stringa (engl. *minimum edit distance*) jednako je minimalnom broju operacija umetanja znaka, brisanja znaka ili zamene jednog znaka drugim, potrebnih da se jedan string transformiše u drugi.
- Što je minimalno rastojanje između dva stringa manje, stringovi su sličniji.
- Na primer, minimalno rastojanje između stringova „mirna“ i „igra“ je 3 jer su potrebne tri operacije za transformaciju jednog stringa u drugi:
  - brisanje znaka „m“: „mirna“ → „irna“,
  - zamena znaka „r“ slovom „g“: „irna“→ „igna“,
  - zamena znaka „n“ slovom „r“: „irna“→ „igra“.
- U opštem slučaju, postoji više načina da se jedan string transformiše u drugi koristeći isti broj operacija.
- Za prethodni primer postoje još dva načina transformacije koristeći minimalni broj operacija.

Merenje povezanosti postova

Kako ne treba rešavati problem?

- Minimalno rastojanje između stringova koje smo razmatrali u prethodnom primeru se naziva i Levenštajnovo rastojanje (engl. *Levenshtein distance*).
- Levenštajnovo rastojanje je specijalni slučaj rastojanja između stringova, u kom se podrazmeva da operacije umetanja, brisanja i zamene znakova podjednako doprinose rastojanju između stringova, i da je dovoljno samo utvrditi minimalni broj različitih operacija potrebnih da se jedan string transformiše u drugi.
- Treba imati na umu da određivanje Levenštajnovog rastojanja može biti računski zahtevno ukoliko su stringovi vrlo dugi, zato što zavisi od dužine prvog i drugog stringa.

Merenje povezanosti postova

Kako ne treba rešavati problem?

- Imajući to na umu možemo da primenimo sledeći štos – tretiraćemo cele reči u postovima kao karaktere i određivaćemo minimalno rastojanje na nivou reči.
- Zarad jednostavnosti, u sledećem primeru ćemo analizirati samo naslove postova: „How to format my hard disk“ i „Hard disk format problems“.
- U ovom slučaju minimalno rastojanje je 5 – potrebno je izbaciti reči „How“, „to“ i „format“, a zatim dodati reči „format“ i „problems“.
- Na ovaj način se razlika između dva posta može izraziti kao broj reči koje treba dodati ili izbrisati, tako da se jedan tekst pretvori u drugi.
- Međutim, treba imati na umu da, iako smo postupak ubrzali, vremenska složenost i dalje ostaje problem.

Merenje povezanosti postova

Kako ne treba rešavati problem?

- Prilikom računanja minimalnog rastojanja javlja se još jedan problem.
- U prethodnom primeru smo najpre izbacili reč „format“, a zatim je dodali, što je povećalo minimalno rastojanje za 2, ali se reč i dalje nalazi u oba naslova.
- To ukazuje na činjenicu da jednostavno računanje minimalnog rastojanja nije dovoljno robusno da u obzir uzme promenu redosleda reči.

Merenje povezanosti postova

Kako treba rešavati problem?

- Bolji pristup od minimalnog rastojanja je princip *bag of words*.
- U ovom pristupu se koristi broj pojavljivanja date reči u postu, a red reči ignoriše.
- Za svaku reč u postu određuje se broj pojavljivanja koji se unosi u vektor.
- Vektor je obično ogroman jer sadrži onoliko elemenata koliko različitih reči imamo u celom skupu podataka.
- Ovaj korak se naziva vektorizacija.

Merenje povezanosti postova

Kako treba rešavati problem?

- Za prethodni primer dobijamo:

Reč	Broj pojavljivanja u postu 1	Broj pojavljivanja u postu 2
disk	1	1
format	1	1
how	1	0
hard	1	1
my	1	0
problems	0	1
to	1	0

Merenje povezanosti postova

Kako treba rešavati problem?

- Kolone „Broj pojavljivanja u postu 1“ i „Broj pojavljivanja u postu 2“ su vektori.
- Nadalje se može računati Euklidsko rastojanje između datog vektora i vektora svih postova i pronaći najmanje. Međutim, ovaj postupak takođe može biti spor.
- Ove vektore korisimo kao vektore obeležja u postupku klasterovanja i pronalaženja povezanih postova na sledeći način:
  - ekstrahuju se istaknuta obeležja iz svakog posta i čuvaju se kao vektor za dati post,
  - primeni se klasterovanje (grupisanje) na vektore,
  - odredi se klaster kome određeni post pripada,
  - iz datog klastera, uzima se nekoliko postova koji imaju različitu, ali dovoljno malu sličnost sa datim postom, čime se povećava raznolikost odgovora.

Predprocesiranje

Konverzija neobrađenog teksta u *bag of words*.

- Za brojanje reči i predstavljanje u obliku vektora koristićemo SciKit `CountVectorizer()` metodu.

```
>>> from sklearn.feature_extraction.text import CountVectorizer
>>> vectorizer = CountVectorizer(min_df=1)
```

- Parametar `min_df` određuje kako CountVectorizer tretira retke reči.
- Ukoliko je u pitanju celobrojna vrednost, sve reči koje se pojavljuju manji broj puta od te vrednosti, biće odbačene.
- Ukoliko je u pitanju razlomak, sve reči koje se pojavljuju manje od razlomkom određenog dela celokupnog skupa podataka, biće odbačene.
- Parametar `max_df` se ponaša na sličan način.

Konverzija neobrađenog teksta u *bag of words*.

- Izlaz komande `print(vectorizer)` ispisuje na ekranu podrazumevane vrednosti.
- Za sada su od značaja sledeće:

```
analyzer='word'                          # brojanje na nivou reči
token_pattern='(?u)\\b\\w\\w+\\b'        # šablon za tokenizaciju
```

- To znači da se:
  - brojanje radi na nivou reči,
  - obavlja tokenizacija, tj. deljenje teksta na tokene (nizove znakova koji predstavljaju semantičke jedinice pogodne za dalju obradu).
- Intuitivno, tokenizacija se može posmatrati kao deljenje teksta na pojedine reči, pri čemu se zanemaruju znakovi interpunkcije.
- Na primer, tekst „cross-validated“ biće razdvojen u dva tokena – „cross“ i „validated“.

Predprocesiranje

Konverzija neobrađenog teksta u *bag of words*.

- Posmatramo dve rečenice koje predstavljaju naslove postova.

```
>>> content = ["How to format my hard disk", "Hard disk format problems"]
```

- Funkcija `fit_transform()` obavlja vektorizaciju.

```
>>> X = vectorizer.fit_transform(content)
>>> vectorizer.get_feature_names()
[u'disk', u'format', u'hard', u'how', u'my', u'problems', u'to']
```

Konverzija neobrađenog teksta u *bag of words*.

- Dakle, otkriveno je sedam reči, a njihova pojavljivanja u rečenicama možemo videti i „ručno“ izbrojati.

```
>>> print(X.toarray().transpose())
[[1 1]
 [1 1]
 [1 1]
 [1 0]
 [1 0]
 [0 1]
 [1 0]]
```

- To znači da se u prvoj rečenici nalaze sve reči osim reči „problems“, a u drugoj sve reči osim „how“, „my“ i „to“.

Brojanje reči.

- Kao primer, tražimo post u sledećem skupu najsličniji kratkoj rečenici „imaging databases“.
- Datoteke se nalaze u dodatku knjige, direktorijum `data/ch03/data/toy`.

Ime datoteke	Sadržaj posta
`01.txt`	This is a toy post about machine learning. Actually, it contains not much interesting stuff.
`02.txt`	Imaging databases can get huge.
`03.txt`	Most imaging databases save images permanently.
`04.txt`	Imaging databases store images.
`05.txt`	Imaging databases store images. Imaging databases store images. Imaging databases store images.

Brojanje reči.

- Pod pretpostavkom da se postovi nalaze u direktorijumu DIR, uvešćemo ih u CountVectorizer.
- Pri tome moramo da naglasimo da se radi o celom skupu kako bi imao uvid u reči koje može da očekuje.

```
>>> posts = [open(os.path.join(DIR, f)).read() for f in os.listdir(DIR)]
>>> from sklearn.feature_extraction.text import CountVectorizer
>>> vectorizer = CountVectorizer(min_df=1)
>>> X_train = vectorizer.fit_transform(posts)
>>> num_samples, num_features = X_train.shape
>>> print("#samples: %d, #features: %d" % (num_samples, num_features))
#samples: 5, #features: 25
```

Brojanje reči.

- Ukupno imamo 5 postova sa 25 reči. Sledeće reči koje su tokenizovane biće brojane.

```
>>> print(vectorizer.get_feature_names())
[u'about', u'actually', u'capabilities', u'contains', u'data',
u'databases', u'images', u'imaging', u'interesting', u'is', u'it',
u'learning', u'machine', u'most', u'much', u'not', u'permanently',
u'post', u'provide', u'save', u'storage', u'store', u'stuff',
u'this', u'toy']
```

Brojanje reči.

- Sledeće što radimo je vektorizacija nove rečenice „imaging databases“.
- Vektor vraćen metodom transformacije ne čuva vrednosti broja za svaku reč (tzv. *sparse* format), pošto će većina tih brojeva biti nula (post ne sadrži reč).
- Ukoliko želite da vidite sve vrednosti, koristi se metod `toarray()`. Ovo nam je potrebno za računanje sličnosti između postova.

```
>>> new_post = "imaging databases"
>>> new_post_vec = vectorizer.transform([new_post])
>>> print(new_post_vec)
(0, 7) 1
(0, 5) 1
>>> print(new_post_vec.toarray())
[[0 0 0 0 0 1 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0]]
```

Brojanje reči.

- Kao meru sličnosti možemo koristićemo Euklidsko rastojanje između novog posta i starih postova.
- Definisaćemo funkciju `dist_raw` koja računa Euklidsko rastojanje koristeći `norm()` funkciju.

```
import scipy as sp
def dist_raw(v1, v2):
  delta = v1-v2
  return sp.linalg.norm(delta.toarray())
```

- Koristeći definisanu funkciju, potrebno je proći kroz sve postove i naći najsličniji.
- Deo koda kojim se to radi dat je na str. 25, za kompletan kod v. dodatak knjige.

Brojanje reči.

```
import sys
best_doc = None
best_dist = sys.maxint
best_i = None
for i, post in enumerate(num_samples):
  if post == new_post:
    continue
  post_vec = X_train.getrow(i)
  d = dist_raw(post_vec, new_post_vec)
  print("=== Post %i with dist=%.2f: %s"%(i, d, post))
  if d<best_dist:
    best_dist = d
    best_i = i
print("Best post is %i with dist=%.2f"%(best_i, best_dist))
```

Brojanje reči.

- Kada se prethodni kod pokrene, dobija se sledeći izlaz:

```
=== Post 0 with dist=4.00: This is a toy post about machine learning.
Actually, it contains not much interesting stuff.
=== Post 1 with dist=1.73: Imaging databases provide storage
capabilities.
=== Post 2 with dist=2.00: Most imaging databases save images
permanently.
=== Post 3 with dist=1.41: Imaging databases store data.
=== Post 4 with dist=5.10: Imaging databases store data. Imaging
databases store data. Imaging databases store data.
Best post is 3 with dist=1.41
```

Brojanje reči.

- Šta možemo da zaključimo?
- Post 0 je najmanje sličan, zato što nema nijednu zajedničku reč sa novom rečenicom.
- Post 1 je vrlo sličan, ali, u odnosu na post 3 sadrži jednu reč viška koje nema u novoj rečenici.
- Šta je u izlazu prethodnog koda čudno?
- Post 4 možemo da posmatramo kao utrostručeni post 3 (tri puta ponovljen).
- Iako neko može da pomisli da bi sličnost nove rečenice sa postovima 3 i 4 trebala biti ista, prikazivanjem njihovih vektora se može zaključiti da je brojanje reči isuviše jednostavno i da je potrebno normalizovati vektore brojanja reči.

```
>>> print(X_train.getrow(3).toarray())
[[0 0 0 0 1 1 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 1 0 0 0]]
>>> print(X_train.getrow(4).toarray())
[[0 0 0 0 3 3 0 3 0 0 0 0 0 0 0 0 0 0 0 0 0 3 0 0 0]]
```

Normalizovanje vektora brojanja reči.

- Izmenićemo funkciju `dist_raw` tako da računa rastojanje između normalizovanih vektora.

```
def dist_norm(v1, v2):
  v1_normalized = v1/sp.linalg.norm(v1.toarray())
  v2_normalized = v2/sp.linalg.norm(v2.toarray())
  delta = v1_normalized - v2_normalized
  return sp.linalg.norm(delta.toarray())
```

- U ovom slučaju se, prilikom poređenja nove rečenice sa svim postovima dobija drugačiji rezultat.

Normalizovanje vektora brojanja reči.

- Iz izlaza programa se vidi da su sada post 3 i post 4 podjednako slični novoj rečenici.

```
=== Post 0 with dist=1.41: This is a toy post about machine learning.
Actually, it contains not much interesting stuff.
=== Post 1 with dist=0.86: Imaging databases provide storage
capabilities.
=== Post 2 with dist=0.92: Most imaging databases save images
permanently.
=== Post 3 with dist=0.77: Imaging databases store data.
=== Post 4 with dist=0.77: Imaging databases store data. Imaging
databases store data. Imaging databases store data.
Best post is 3 with dist=0.77
```

Uklanjanje stop reči.

- Ukoliko ponovo pogledamo post 2, primetićemo da se reči „most“, „save“, „images“ i „permanently“ ne nalaze u novoj rečenici.
- Uticaj ovih reči na značenje posta, odnosno količina informacije koju nose, je različita.
- Reči poput „most“ (u prevodu: većina) se često pojavljuju u svim različitim kontekstima i nazivaju se stop reči (engl. *stop words*).
- Stop reči ne sadrže toliko informacija i ne treba im pridavati isti značaj kao rečima poput „images“, koje se ne pojavljuju često u različitim kontekstima.
- Najbolja opcija bila bi uklanjanje svih reči koje su tako česte da ne pomažu u razlikovanju različitih tekstova.

Uklanjanje stop reči.

- Pošto je uklanjanje stop reči tipičan korak u obradi prirodnih jezika, dovoljno je parametar `stop_words` podesiti na jezik čije stop reči želimo da uklonimo.
- Za engleski jezik uklanja se 318 stop reči, od kojih je prvih 20 dato u listing (radi ilustracije).

```
>>> vectorizer = CountVectorizer(min_df=1, stop_words='english')
>>> sorted(vectorizer.get_stop_words())[0:20]
['a', 'about', 'above', 'across', 'after', 'afterwards', 'again',
'against', 'all', 'almost', 'alone', 'along', 'already', 'also',
'although', 'always', 'am', 'among', 'amongst', 'amoungst']
```

- Nakon uklanjanja stop reči, uklanja se 7 tokenizovanih stop reči iz našeg primera: „about“, „is“, „it“, „most“, „much“, „not“ i „this“.

Uklanjanje stop reči.

- Nakon uklanjanja stop reči dobićemo sledeće mere sličnosti (primetite da je udaljenost postova 1 i 2 od nove rečenice sada ista, jer imaju identičan broj reči kojih nema u novoj rečenici):

```
=== Post 0 with dist=1.41: This is a toy post about machine learning.
Actually, it contains not much interesting stuff.
=== Post 1 with dist=0.86: Imaging databases provide storage
capabilities.
=== Post 2 with dist=0.86: Most imaging databases save images
permanently.
=== Post 3 with dist=0.77: Imaging databases store data.
=== Post 4 with dist=0.77: Imaging databases store data. Imaging
databases store data. Imaging databases store data.
Best post is 3 with dist=0.77
```

Predprocesiranje

Stemming.

- Do sada smo različite pojavne oblike reči i slične reči posmatrali kao različite reči.
- Na primer, post 2 sadrži reči „imaging“ i „images“.
- Pošto reči ukazuju na isti ili vrlo slični koncept, možemo da ih brojimo zajedno.
- Dakle, potrebna nam je funkcija koja će reči svesti na stem oblik koji je pogodan za brojanje.
- SciKit ovakvu funkciju za sada nema, ali se zato može preuzeti besplatan alat Natural Language Toolkit (NLTK) – ovaj alat obezbeđuje stemer koji se može jednostavno koristiti uz CountVectorizer.
- NLTK obezbeđuje više stemera – ovo je logično zato što svaki jezik ima različita pravila dovođenja reči u osnovni oblik.
- Za Engleski jezik koristićemo SnowballStemmer. Uzmite u obzir da rezultat ove operacije ne mora uvek da rezultuje ispravnim engleskim rečima.

* Za detalje o instalaciji NTLK, v. knjigu str. 60.

Stemming.

- Primer:

```
>>> import nltk.stem
>>> s = nltk.stem.SnowballStemmer('english')
>>> s.stem("graphics")
u'graphic'
>>> s.stem("imaging")
u'imag'
>>> s.stem("image")
u'imag'
>>> s.stem("imagination")
u'imagin'
>>> s.stem("imagine")
u'imagin'
```

Stemming.

- Primer:

```
>>> s.stem("buys")
u'buy'
>>> s.stem("buying")
u'buy'
```

- Napomena – ova operacija ponekad ne vraća stem oblik. Na primer, stemovanje reči „bought“ trebalo bi da rezultuje rečju „buy“.

```
>>> s.stem("bought")
u'bought'
```

Stemming.

- Proširivanje CountVectorizer klase NTLK funkcionalnošću:

```
import nltk.stem
english_stemmer = nltk.stem.SnowballStemmer('english'))
class StemmedCountVectorizer(CountVectorizer):
  def build_analyzer(self):
    analyzer = super(StemmedCountVectorizer, self).build_analyzer()
    return lambda doc: (english_stemmer.stem(w) for w in analyzer(doc))
vectorizer = StemmedCountVectorizer(min_df=1, stop_words='english')
```

- Šta dati kod radi?

Stemming.

- Prethodni kod:
  - pretvara sva slova u mala slova u fazi predprocesiranja,
  - izdvaja sve reči u procesu tokenizacije,
  - izvacuje stop reči i
  - pretvara reči u stem oblik.
- Nakon pokretanja ovog koda izbačena je još jedno obeležje, odnosno stem oblik reči, zato što su nakon stemming-a oblici reči „images“ i „imaging“ identični.

```
print(vectorizer.get_feature_names())
[u'actual', u'capabl', u'contain', u'data', u'databas', u'imag',
u'interest', u'learn', u'machin', u'perman', u'post', u'provid',
u'save', u'storag', u'store', u'stuff', u'toy']
```

Stemming.

- Koji je sad post najsličniji rečenici „imaging databases“?

```
=== Post 0 with dist=1.41: This is a toy post about machine learning.
Actually, it contains not much interesting stuff.
=== Post 1 with dist=0.86: Imaging databases provide storage
capabilities.
=== Post 2 with dist=0.63: Most imaging databases save images
permanently.
=== Post 3 with dist=0.77: Imaging databases store data.
=== Post 4 with dist=0.77: Imaging databases store data. Imaging
databases store data. Imaging databases store data.
Best post is 2 with dist=0.63
```

Term frequency – inverse document frequency (TF-IDF).

- Za sada možemo da kažemo da smo pronašli dobar način da formiramo kompaktni vektor na osnovu zašumljenog tekstualnog posta.
- Međutim, postavićemo pitanje: šta vrednosti obeležja zapravo znače u ovom slučaju?
- Vrednosti obeležja se dobijaju na osnovu broja pojavljivanja termina u postu, a naša pretpostavka je da veća vrednost znači da je termin od većeg značaja.
- Međutim, može se izvesti zaključak da duži dokumenti imaju prednost nad kraćima.
- Dakle, potrebno je normalizovati brojanje na osnovu dužine dokumenta.
- Takođe, potrebno je izbaciti beskorisne termine (na primer, termin „subject“, koji se nalazi u skoro svakom postu).

Term frequency – inverse document frequency (TF-IDF).

- Jednostavna implementacija TF-IDF:

```
import scipy as sp
def tfidf(term, doc, corpus):
  tf = doc.count(term) / len(doc)
  num_docs_with_term = len([d for d in corpus if term in d])
  idf = sp.log(len(corpus) / num_docs_with_term)
  return tf * idf
```

Term frequency – inverse document frequency (TF-IDF).

- Za dati korpus D koji sadrži tokenizovane dokumente a, abb i abc prethodna funkcija vraća sledeće:

```
>>> a, abb, abc = ["a"], ["a", "b", "b"], ["a", "b", "c"]
>>> D = [a, abb, abc]
>>> print(tfidf("a", a, D))
0.0
>>> print(tfidf("a", abb, D))
0.0
>>> print(tfidf("a", abc, D))
0.0
```

- Na osnovu toga zaključujemo da je termin a neznačajan jer se nalazi svugde.

Term frequency – inverse document frequency (TF-IDF).

- Za dati korpus D koji sadrži tokenizovane dokumente a, abb i abc prethodna funkcija vraća:

```
>>> print(tfidf("b", abb, D))
0.270310072072
>>> print(tfidf("b", abc, D))
0.135155036036
>>> print(tfidf("c", abc, D))
0.366204096223
```

- Na osnovu toga zaključujemo da je termin b značajniji za dokument abb nego za document abc jer se u njemu pojavljuje dva puta.

Term frequency – inverse document frequency (TF-IDF).

- SciKit implementacija (koristimo TfidfVectorizer koji nasleđuje CountVectorizer) je data sledećim kodom:

```
from sklearn.feature_extraction.text import TfidfVectorizer
class StemmedTfidfVectorizer(TfidfVectorizer):
  def build_analyzer(self):
    analyzer = super(TfidfVectorizer, self).build_analyzer()
    return lambda doc: (english_stemmer.stem(w) for w in analyzer(doc))
vectorizer = StemmedTfidfVectorizer(min_df=1, stop_words='english', decode_error='ignore')
```

Koji su nedostaci pristupa *bag of words*?

- Relacije između reči se ne uzimaju u obzir.
  - Na primer, rečenice „cars hits wall“ i „wall hits car“ imaće identičan vektor obeležja.
- Postoji problem sa negacijama.
  - Na primer, rečenice „I will eat ice cream“ i „I will not eat ice cream“ imaće vrlo sličan vektor obeležja i ako imaju suprotno značenje.
  - Ovaj problem je rešiv ukoliko se prilikom brojanja reči u obzir ne uzmu samo pojedinačne reči, već i bigrami (parovi reči) ili trigrami (tri reči za redom).
- Postoji problem sa pogrešno napisanim rečima.
  - Iako je čitaocu jasno da reči „database“ i „databas“ imaju isto značenje, odnosno da je u pitanju greška u pisanju, pristup koji mi koristimo će ih tretirati kao dve različite reči.

Koji su nedostaci pristupa *bag of words*?

- Međutim, fokus ovog izlaganja je na klasterovanju, a ne na obradi prirodnih jezika, tako da ćemo pristup *bag of words* koristiti za dalju klaster analizu.

Šta je klasterovanje?

- Klasterovanje, tj. klaster analiza je pronalaženje grupa objekata takvih da su objekti u grupi slični (ili povezani), i da su objekti u različitim grupama različiti (ili nepovezani).
- Klasterovanje se koristi za pregledanje dokumenata iz iste grupe, grupisanje gena i proteina koji imaju iste funkcionalnosti, grupisanje akcija sa sličnim promenama cena itd.
- Primer: klasterovanje padavina u Australiji.

Dvosmislenost pojma klastera.

- Koliko klastera imamo u ovom slučaju?

Dvosmislenost pojma klastera.

- Koliko klastera imamo u ovom slučaju?

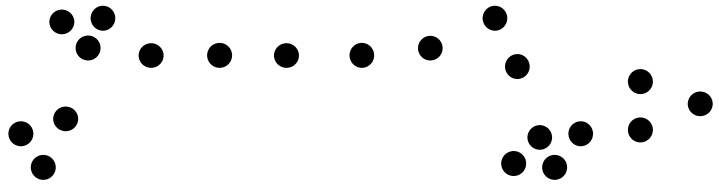

Koji tipovi klasterovanja postoje?

- Postoji značajna razlika između particionog i hijerarhijskog skupa klastera.
- Particiono klasterovanje je podela skupa podataka u nepreklapajuće podskupove (klastere) takve da je svaki podatak tačno u jednom podskupu.
- Hijerarhijsko klasterovanje je skup ugnježdenih klastera organizovan u obliku hijerarhijskog drveta.
- Hijerarhijsko klasterovanje može biti tradicionalno i netradicionalno, što rezultuje tradicionalnim i netradicionalnim dendogramom.

Klasterovanje pomoću algoritma K-sredina.

- K-sredina (engl. *K-means*) je pristup particionom klasterovanju u kome je svakom klasteru pridružen centroid (centralna tačka) a svaka tačka je dodeljena klasteru sa najbližim centroidom.
- Broj klastera K mora da se navede.
- Osnovni algoritam je krajnje jednostavan:

1. *Select K points as initial centroids.*
2. **repeat**
3. *Form K clusters by assigning all points to the closest centroid.*
4. *Recompute centroid for each cluster.*
5. **until** *the centroids don't change*

Klasterovanje pomoću algoritma K-sredina.

- Početni centroid se često bira na slučajni način.
- Dobijeni klasteri mogu da se razlikuju u uzastopnim izvršenjima programa. Rezultati mogu da budu relativno loši.
- Uobičajeno je da je centroid srednja vrednost tačaka u klasteru.
- „Najbliže“ se meri kao Euklidsko rastojanje, kosinusno rastojanje, korelacija, itd.
- K-sredine konvergiraju ka prethodno pomenutim merama sličnosti.
- Najveći deo konvergencije se dešava u prvih nekoliko iteracija.
- Često se uslov zaustavljanja menja na „sve dok relativno malo tačaka ne promeni klaster“.

Klasterovanje pomoću algoritma K-sredina.

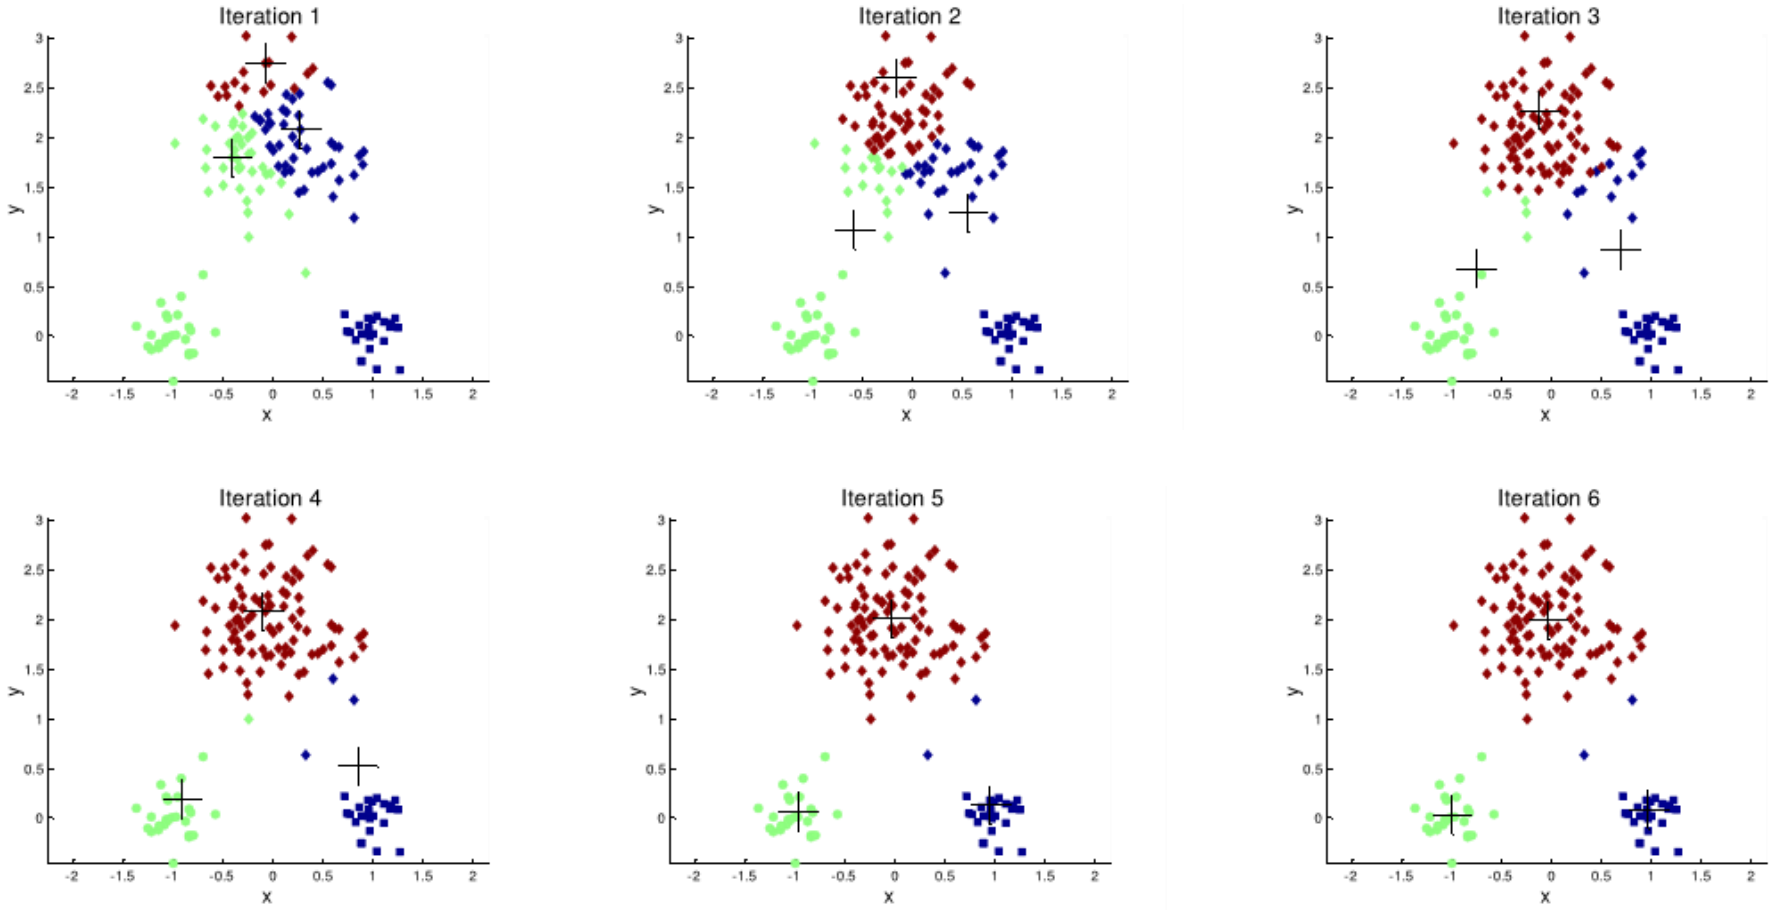

Jednostavan primer.

- Klaster analizu tekstualnih podataka možemo da ilustrujemo klasterovanjem postova koji sadrže dve reči.
- Strelice na grafikonu na str. 56 označavaju pomeraj centroida.
- Nakon pet iteracija na ovom primeru, centroidi se „neprimetno pomeraju“ (SciKit tolerancija, odnosno prag je u podrazumevanom stanju 0,0001).
- Nakon što je klasterovanje završeno, potrebno je da zabeležimo centroide i identitet klastera.
- Svaki novi dokument se vektorizuje i poredi sa svim centroidima.
- Centroid sa najmanjim rastojanjem od novog vektora posta pripada klasteru koji ćemo dodeliti novom postu.

Jednostavan primer.

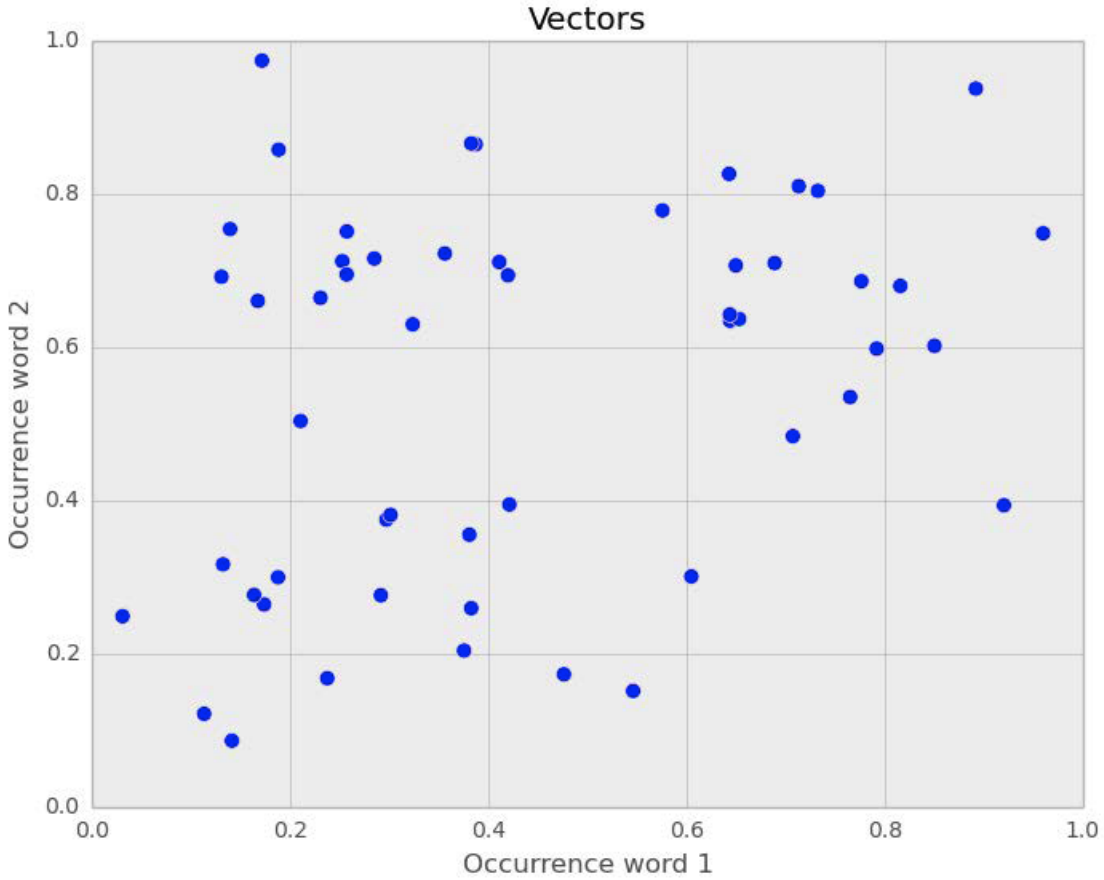

Jednostavan primer.

Jednostavan primer.

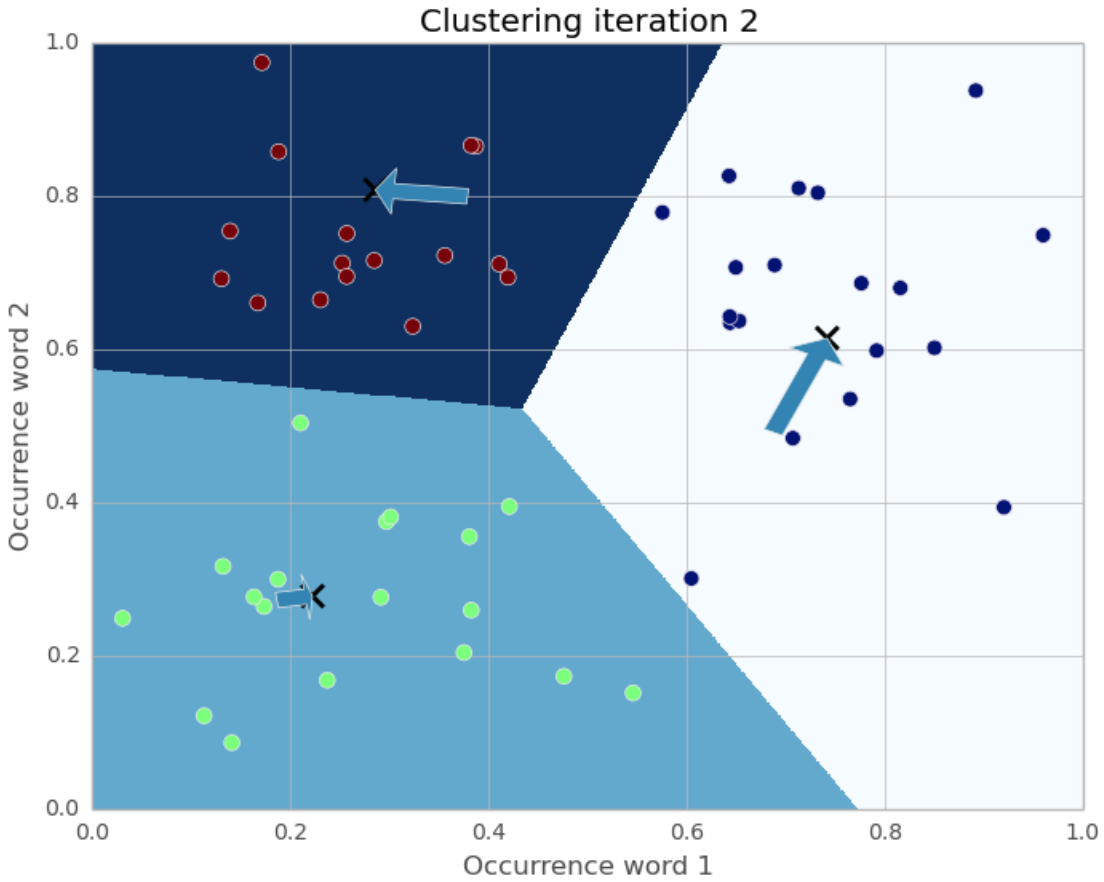

Skup podataka

O skupu podataka.

- Skup podataka 20newsgroup je jedan od „standardnih“ skupova podataka u oblasti mašinskog učenja koji se često koristi za ilustrovanje klaster analize (slično kao što se iris koristi za ilustrovanje klasifikacije).
- Sadrži 18.826 postova iz 20 različitih grupa vesti (engl. *newsgroup*), od kojih su neke tehničkog karaktera (comp.sys.mac.hardware, sci.crypt i slične), dok se neke odnose na politiku ili religiju. U našem eksperimentu ograničićemo se na tehničke.
- Pretpostavićemo da je svaka grupa jedan klaster i ispitati da li naš pristup pronalaženju povezanih postova radi.

* Za detalje o skupu podataka i lokacijama za preuzimanje, v. knjigu str. 70.

Skup podataka

Uvoz skupa.

- Modul sklearn.datasets sadrži funkciju `fetch_20newsgroups` koja automatski uvozi ove podatke:

```
>>> import sklearn.datasets
>>> all_data = sklearn.datasets.fetch_20newsgroups(subset='all')
>>> print(len(all_data.filenames))
18846
>>> print(all_data.target_names)
['alt.atheism', 'comp.graphics', 'comp.os.ms-windows.misc',
'comp.sys.ibm.pc.hardware', 'comp.sys.mac.hardware',
'comp.windows.x', 'misc.forsale', 'rec.autos', 'rec.motorcycles',
'rec.sport.baseball', 'rec.sport.hockey', 'sci.crypt',
'sci.electronics', 'sci.med', 'sci.space', 'soc.religion.christian',
'talk.politics.guns', 'talk.politics.mideast', 'talk.politics.misc',
'talk.religion.misc']
```

Skup podataka

Uvoz skupa.

- Ukoliko želimo da uvezemo odvojeno obučavajući i test skup, radimo sledeće:

```
>>> train_data = sklearn.datasets.fetch_20newsgroups(subset='train', categories=groups)
>>> print(len(train_data.filenames))
11314
>>> test_data = sklearn.datasets.fetch_20newsgroups(subset='test')
>>> print(len(test_data.filenames))
7532
```

Skup podataka

Uvoz skupa.

- Ograničićemo se na određeni broj grupa vesti korišćenjem parametra `categories` na sledeći način:

```
>>> groups = ['comp.graphics', 'comp.os.ms-windows.misc', 'comp.sys.ibm.pc.hardware',
'comp.sys.mac.hardware', 'comp.windows.x', 'sci.space']
>>> train_data = sklearn.datasets.fetch_20newsgroups(subset='train', categories=groups)
>>> print(len(train_data.filenames))
3529
>>> test_data = sklearn.datasets.fetch_20newsgroups(subset='test', categories=groups)
>>> print(len(test_data.filenames))
2349
```

Klasterovanje postova

Kreiranje vektora i uklanjanje šuma.

- Jednu stvar uvek trebamo da uzmemo u obzir – stvarni podaci su zašumljeni.
- Skup podataka koji koristimo nije izuzetak jer sadrži karaktere koji mogu dovesti do greške tipa UnicodeDecodeError.
- Dakle, treba naznačiti da se prilikom vektorizacije ovi karakteri ignorišu.

```
>>> vectorizer = StemmedTfidfVectorizer(min_df=10, max_df=0.5,
...                                     stop_words='english', decode_error='ignore')
>>> vectorized = vectorizer.fit_transform(train_data.data)
>>> num_samples, num_features = vectorized.shape
>>> print("#samples: %d, #features: %d" % (num_samples, num_features))
#samples: 3529, #features: 4712
```

Klasterovanje postova

Formiranje klastera.

- To znači da smo imamo skup od 3.529 posta i da smo za svaki post formirali vektor od 4.712 obeležja.
- Ovo su ulazni podaci za algoritam K-sredina.
- Postavićemo broj klastera na 50 (za vežbu možete da isprobate druge vrednosti za broj klastera).

```
>>> num_clusters = 50
>>> from sklearn.cluster import KMeans
>>> km = KMeans(n_clusters=num_clusters, init='random', n_init=1, verbose=1, random_state=3)
>>> km.fit(vectorized)
```

Klasterovanje postova

Informacije o klasteru.

- Nakon klastera, za svaki vektorizovani post možemo da izdvojimo broj klastera kome pripada (celobrojna vrednost) koristeći `km.labels_`.
- Centroidi su dostupni preko `km.cluster_centers_`.

```
>>> print(km.labels_)
[48 23 31 ..., 6 2 22]
>>> print(km.labels_.shape)
3529
```

- Nove postove možemo da dodeljujemo klasterima koristeći `km.predict`.

Novi post.

- Sve što smo do sada napravili iskoristićemo na sledećem postu koji je dodeljen promenljivoj `new_post`.

„Disk drive problems. Hi, I have a problem with my hard disk.
After 1 year it is working only sporadically now.
I tried to format it, but now it doesn't boot any more.
Any ideas? Thanks.“

Rešavanje zadatog problema

Vektorizacija i klasterovanje.

- Kao što je rečeno, pre predviđanja klastera moramo da vektorizujemo post.

```
>>> new_post_vec = vectorizer.transform([new_post])
>>> new_post_label = km.predict(new_post_vec)[0]
```

- Vektor novog posta ne poredimo sa svim postovima, već samo sa onim koji pripadaju istom klasteru. Preuzećemo njihove indekse iz originalnog skupa podataka.

```
>>> similar_indices = (km.labels_==new_post_label).nonzero()[0]
```

- Poređenje u zagradi rezultuje nizom Bulovskih vrednosti, a funkcija `nonzero()` pretvara rezultujući niz u manji niz koji sadrži samo vrednosti True.

Rešavanje zadatog problema

Računanje sličnosti (povezanosti) postova.

- Kreiraćemo listu svih postova u klasteru i mere sličnosi postojećih postova sa novim.

```
>>> similar = []
>>> for i in similar_indices:
... dist = sp.linalg.norm((new_post_vec - vectorized[i]).toarray())
... similar.append((dist, dataset.data[i]))
>>> similar = sorted(similar)
>>> print(len(similar))
131
```

Prikazivanje relevantnih postova.

- Nakon računanja sličnosti može se prikazati najsličniji post (smešten u promenljivu `show_at_1`), a da bi stekli uvid u rezultate računanja sličnosti, prikazaćemo i dva manje slična posta iz istog klastera.

```
>>> show_at_1 = similar[0]
>>> show_at_2 = similar[int(len(similar)/10)]
>>> show_at_3 = similar[int(len(similar)/2)]
```

Prikazivanje relevantnih postova.

- Sličnost posta smeštenog u promenljivu `show_at_1` sa novim postom je 1,038 a sadržaj je:

BOOT PROBLEM with IDE controller
Hi,
I've got a Multi I/O card (IDE controller + serial/parallel interface) and two floppy drives (5 1/4, 3 1/2) and a Quantum ProDrive 80AT connected to it. I was able to format the hard disk, but I could not boot from it. I can boot from drive A: (which disk drive does not matter) but if I remove the disk from drive A and press the reset switch, the LED of drive A: continues to glow, and the hard disk is not accessed at all. I guess this must be a problem of either the Multi I/o card or floppy disk drive settings (jumper configuration?) Does someone have any hint what could be the reason for it. […]

Prikazivanje relevantnih postova.

- Sličnost posta smeštenog u promenljivu `show_at_2` sa novim postom je 1,150 a sadržaj je:

  Booting from B drive
  I have a 5 1/4" drive as drive A. How can I make the system boot from my 3 1/2" B drive? (Optimally, the computer would be able to boot: from either A or B, checking them in order for a bootable disk. But: if I have to switch cables around and simply switch the drives so that: it can't boot 5 1/4" disks, that's OK. Also, boot_b won't do the trick for me. […]

Prikazivanje relevantnih postova.

- Sličnost posta smeštenog u promenljivu `show_at_3` sa novim postom je 1,280 a sadržaj je:

  IBM PS/1 vs TEAC FD
  Hello, I already tried our national news group without success. I tried to replace a friend s original IBM floppy disk in his PS/1-PC with a normal TEAC drive. I already identified the power supply on pins 3 (5V) and 6 (12V), shorted pin 6 (5.25"/3.5" switch) and inserted pullup resistors (2K2) on pins 8, 26, 28, 30, and 34. The computer doesn't complain about a missing FD, but the FD s light stays on all the time. The drive spins up o.k. when I insert a disk, but I can't access it. The TEAC works fine in a normal PC. Are there any points I missed? […]

Analiza rezultata.

- Interesantno je kako postovi odražavaju rezultat merenja sličnosti.
- Prvi post sadrži sve istaknute reči iz našeg novog posta.
- Drugi post se takođe odnosi na problem sa pokretanjem, ali se radi o flopi diskovima, a ne čvrstim diskovima.
- Konačno, treći post se ne odnosi ni na problem sa pokretanjem niti na čvrste diskove.
- Međutim, možemo da primetimo da sva tri posta (uključujući i najmanje sličan) pripadaju istom problemskom domenu kao i novi post.

Osvrt na šum

Da li je realno da očekujemo savršeno klasterovanje?

- Ne možemo očekivati savršeno klasterovanje u kontekstu da su postovi iz iste grupe vesti (na primerm, comp.graphics) smešteni u isti klaster.
- Jedan od razloga za to je šum.
- Obratite pažnju na sledeći post:

```
>>> post_group = zip(train_data.data, train_data.target)
>>> all = [(len(post[0]), post[0], train_data.target_names[post[1]]) for post in post_group]
>>> graphics = sorted([post for post in all if post[2]=='comp.graphics'])
>>> print(graphics[5])
(245, 'From: SITUNAYA@IBM3090.BHAM.AC.UK\nSubject:
test....(sorry)\nOrganization: The University of Birmingham, United
Kingdom\nLines: 1\nNNTP-Posting-Host: ibm3090.bham.ac.uk<…snip…>',
'comp.graphics')
```

Osvrt na šum

Da li postoje pokazatelji da ovaj post pripada grupi u kojoj se nalazi?

- Nakon predprocesiranja (tokenizacija, uklanjanje stop reči i svođenje na mala slova) dobićemo reči koje nisu dovoljan pokazatelj da dati post pripada grupi comp.graphics.

```
>>> noise_post = graphics[5][1]
>>> analyzer = vectorizer.build_analyzer()
>>> print(list(analyzer(noise_post)))
['situnaya', 'ibm3090', 'bham', 'ac', 'uk', 'subject', 'test',
'sorri', 'organ', 'univers', 'birmingham', 'unit', 'kingdom', 'line',
'nntp', 'post', 'host', 'ibm3090', 'bham', 'ac', 'uk']
```

- Ukoliko uvedemo dodatno filtriranje pomoću parametara `min_df` i `max_df`, situacija postaje još gora jer dobijamo sledeće reči: „ac“, „birmingham“, „host“, „kingdom“, „nntp“, „sorri“, „test“, „uk“, „unit“ i „univers“.

Zaključne napomene

1. Proces obrade kolekcije jezičkih dokumenata nije trivijalan. U našem slučaju predprocesiranje podataka se svodi na konverziju tekstualnih dokumenata u numeričke vektore pogodne za klasterovanje i merenje sličnosti.
2. Klaster analiza je pokazala da se vektorizovani postovi iz istog problemskog domena (uglavnom) mogu grupisati u iste klastere, iz kojih se merenjem sličnosti mogu izdvojiti postovi povezani sa novim.
3. Šum u podacima može negativno da utiče na performanse klasterovanja.

- Eksperimentišite sa brojem klastera, izborom početnih centroida, pristupima klasterovanju zasnovanim na drugim metrikama!

Literatura

- Beleške pripremljene prema knjizi – Luis Pedro Coelho, Willi Richert (2015): „Building Machine Learning Systems with Python, Second Edition“. Packt Publishing.
- Dodatni material korišćen u pripremi – Milan Milosavljević (2018): beleške sa predavanja iz predmeta mašinsko učenje, Univerzitet Singidunum.

Hvala na pažnji

Pitanja su dobrodošla.