

PREPOZNAVANJE ENTITETA U TEKSTU

Jelena Jovanović

Email: jeljov@gmail.com

Web: <http://jelenajovanovic.net>

Pregled predavanja

- Glavni izazovi u domenu prepoznavanja entiteta
- Osnovne vrste pristupa za prepoznavanje entiteta
 - List lookup pristupi
 - Pristupi zasnovani na pravilima
 - Pristupi zasnovani na mašinskom učenju
 - Pristupi zasnovani na m. učenju i bazama znanja (Wikipedia)
- Korisni Web resursi vezani za ovu temu

Glavni izazovi u domenu prepoznavanja entiteta

- Pravilna identifikacija segmenata teksta kojima su entiteti predstavljeni (tzv. chunking)
 - entiteti mogu biti predstavljeni jednom reči (npr. *MIT*) ili nizom reči (*Massachusetts Institute of Technology*)
- Zaključivanje da određeni segment teksta stvarno predstavlja entitet
 - posebno nezgodno u slučajevima kad se više značne reči nađu na početku rečenice (npr., *May*, *Galaxy*, ...)

Glavni izazovi u domenu prepoznavanja entiteta

▪ Određivanje tipa entiteta

Group (Team) vs. Location:

“**England** won the World Cup” vs.

“The World Cup took place in **England**”

Company vs. Artefact:

“having shares in **BBC**” vs. “watching **BBC**”

“staying in **Hotel California**” vs. “listening to **Hotel California**”

Location vs. Organisation:

“she met him at **Heathrow**” vs. “the **Heathrow** authorities”

Glavni izazovi u domenu prepoznavanja entiteta

- Prepoznavanje segmenata teksta koji se odnose na *isti* entitet
 - Problem: različiti načini referenciranja na isti entitet; primeri:
 - John Smith; Mr Smith; John
 - *UMBC; University of Maryland Baltimore County*
- Održavanje ažurnim lista/rečnika koji sadrže nazive entiteta (potrebni za većinu aktuelnih sistema)

Osnovne vrste pristupa prepoznavanju entiteta

- *List lookup* pristupi

- zasnovani na korišćenju rečnika i gazetter lista

- Pristupi zasnovani na pravilima

- shallow parsing pristupi
 - pristupi zasnovani na regularnim izrazima

- Pristupi zasnovani na mašinskom učenju

- Pristupi zasnovani na m. učenju i bazama znanja

- Hibridni pristupi

- kombinuju dva ili više navedenih pristupa
 - najčešće se primenjuju u praksi

LIST LOOKUP PRISTUPI

List lookup pristupi

- Primenjuju se kad imamo unapred date liste imena entiteta koje tražimo
 - npr., liste kompanija i/ili eksperata iz određene branže
- Prepoznaju samo one entitete čija imena su prisutna u listama/rečniku

List lookup pristupi

- Dva pristupa mečiranju imena:

- *Exact matching*: zahteva potpuno poklapanje reči/termina iz teksta i imena datih u listama/rečniku
- *Approximate matching*: proširuje exact matching tehnikama za približno poređenje stringova
 - Primer: *Levenshtein distance* (edit distance) - min. broj izmena potreban da bi se jedna reč transformisala u drugu; dozvoljene izmene su umetanje, brisanje ili zamena jednog karaktera

$Lev(\text{machine}, \text{marine}) = 2$

- brisanje karaktera 'c'
- zamena karaktera 'h' -> 'r'

List lookup pristupi

Gazetteer

- Koristi liste imena da bi prepoznao imenovane entitete u tekstu
 - gazetteer liste su obični tekstualni fajlovi, sa jednim podatkom (imenom) u svakoj liniji
 - Svaka lista sadrži skup imena,
kao što su imena gradova, organizacija, dana u nedelji,...
 - index fajl se koristi za pristup ovim listama;
 - Termin koji odgovara imenu iz neke od ovih lista biće anotiran glavnim (major type) tipom i podtipom (minor type) liste kojoj to ime pripada.
 - Primer: “Belgrade”
Anotacija: majorType = location, minorType = city

List lookup pristupi

■ Prednosti:

- Jednostavnost,
- Brzina (brži u odnosu na ostale pristupe),
- Nezavisni od jezika,
- Mogućnost jednostavne adaptacije na nove vrste teksta

■ Nedostaci:

- Kreiranje/prikupljanje i održavanje lista imena
- Ne mogu da prepoznaju entitete u slučaju slabog preklapanja imena u listama i u tekstu
- Nemaju mogućnost razumevanja entiteta u kontekstu i razrešavanja dvosmislenosti (ili više značnosti)

PRISTUPI ZASNOVANI NA PRAVILIMA

Pristupi zasnovani na pravilima: *shallow parsing*

- *Shallow parsing* pristup se oslanja na heuristička, iskustvena ‘pravila’ vezana za:
 - strukturu teksta i pojedinačnih rečenica,
 - tipično korišćene izraze i fraze u tekstu
- Ideja je identifikovati uobičajene jezičke formulacije i predstaviti ih u formi templejta
- Identifikovani templejti se, zatim, mogu formalizovati korišćenjem jezika za modelovanje pravila

Pristupi zasnovani na pravilima: *shallow parsing*

Primer – prepoznavanje lokacije:

CapWord + {City, Forest, Center}

e.g. *Sherwood Forest*

Cap Word + {Street, Boulevard, Avenue, Crescent, Road}

e.g. *Portobello Street*

“to the” COMPASS “of” CapWord

e.g. *to the south of Boston*

“based in” CapWord

e.g. *based in Boston*

CapWord “is a” (ADJ)? GeoWord

e.g. *Boston is a friendly city*

Pristupi zasnovani na pravilima: *shallow parsing*

- Korišćenje pravila za formalizaciju templejta
- Na primer, JAPE jezik* omogućuje definisanje pravila oblika:

templejt => akcija

- ▶ Leva strana pravila sastoji se od jednog ili više templejta koji se mečiraju sa tekstrom koji se analizira
- ▶ Desna strana pravila sastoji se od iskaza za anotaciju mečiranih segmenata teksta i manipulisanje tim anotacijama

*JAPE je sastavni deo GATE Java framework-a za analizu teksta

Pristupi zasnovani na pravilima: *shallow parsing*

- Primer JAPE pravila

```
Rule: Location_1 //CapWord + {City, Forest, Center}
(
  {Token.orth == "upperInitial"}
  {Token.kind == "space"}
  ( {Token.string == "City"} |
    {Token.string == "Forest"} |
    {Token.string == "Center"})
  )
):loc
-->
:loc.Location = {rule = "Location_1"}
```

Pristupi zasnovani na pravilima: *shallow parsing*

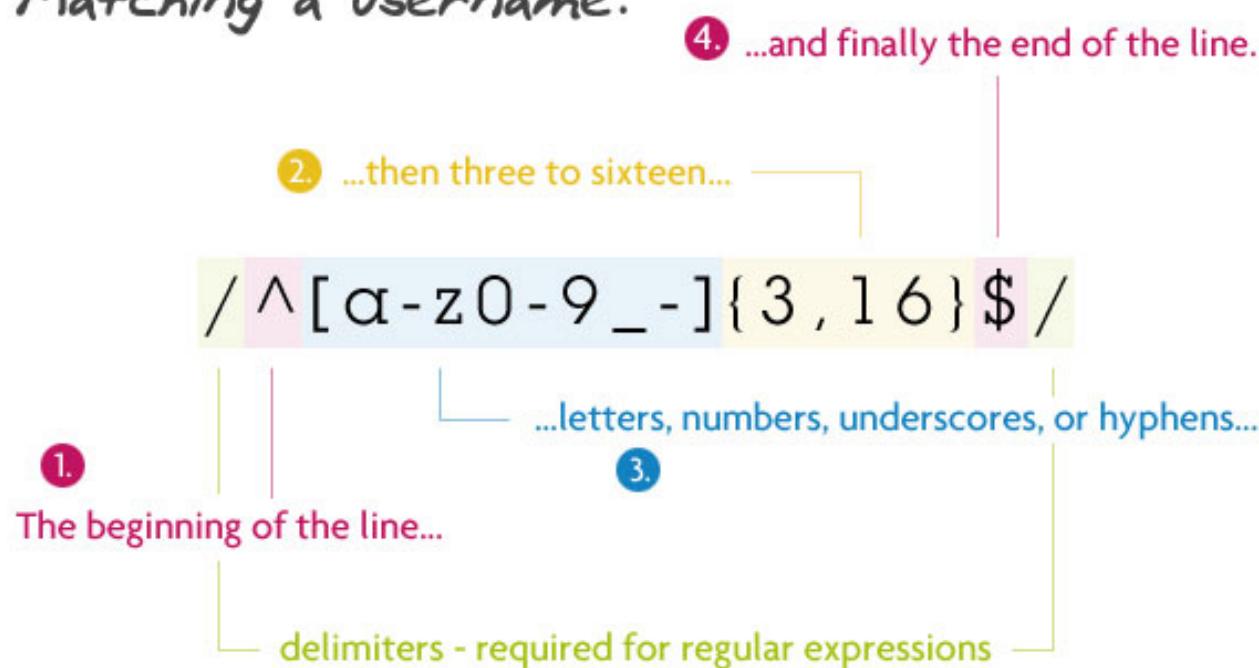
Problemi sa *Shallow Parsing* pristupom

- Identifikacija pouzdanih templejta
- Neodređenost značenja početnog prvog slova u rečenici
 - Da li označava samo početak rečenice ili je takođe sastavni deo naziva entiteta?
 - Npr. [All American Bank] vs. All [State Police]
- Strukturna višesmislenost
 - Npr. [Cable and Wireless] vs. [Microsoft] and [Dell]
 - Npr. [Center for Computational Linguistics] vs.
message from [City Hospital] for [John Smith]

Pristupi zasnovani na pravilima: regularni izrazi

- Pogodni za entitete čija tekstualna reprezentacija mora da sledi neku dobro definisanu strukturu i formu
- Primer: regularni izraz za prepoznavanje username-a

Matching a username:



PRISTUPI ZASNOVANI NA MAŠINSKOM UČENJU

Pristupi zasnovani na mašinskom učenju

- Najčešća primena algoritama *nadgledanog* m. učenja
- Osnovna ideja:
 - Program uči karakteristike/osobine koje odlikuju entitete određenog tipa
 - Osobine entiteta se određuju na osnovu termina kojima su entiteti predstavljeni u tekstu, kao i termina koji čine njihov kontekst/okruženje
- Preduslov:
 - Postojanje dovoljno velikog skupa podataka za trening tj. korpusa anotiranih/obeleženih dokumenata

Primena nadgledanog m. učenja

Razmotrićemo osnovne elemente procesa nadgledanog m. učenja pri prepoznavanju entiteta u tekstu:

- (obeleženi) podaci za treniranje modela
- atributi (features) za formiranje modela
- selekcija algoritma m. učenja
- evaluacija modela

Primena nadgledanog m. učenja: podaci za trening

Primer teksta anotiranog za potrebe “obuke” algoritma nadgledanog učenja:

Unlike <PERSON>Robert</PERSON>, <PERSON>John Briggs Jr</PERSON> contacted <ORGANIZATION>Wonderful Stockbrokers Inc</ORGANIZATION> in <LOCATION>New York</LOCATION> and instructed them to sell his <NUMBER>100</NUMBER> shares in <ORGANIZATION>Acme</ORGANIZATION>

Očigledno, priprema podataka za obučavanje algoritma je prilično zahtevna...

Primena nadgledanog m. učenja: podaci za trening

- Izvori gotovih “obeleženih” podataka tj. anotiranih tekstova za obuku algoritama
 - Stručne konferencije na temu analize i razumevanja teksta
 - Message Understanding Conference (MUC): [MUC06](#) i [MUC07](#) datasets
 - Conference on Computational Natural Language Learning (CoNLL):
[CoNNL-2002](#) i [CoNNL-2003](#) datasets
 - Stručne asocijacije u domenu obrade prirodnog jezika
 - [Linguistic Data Consortium](#) održava [katalog lingvističkih dataset-ova](#)
 - Istraživačke grupe i pojedinci
 - [Twitter NER](#) – dataset korišćen za treniranje modela za prepoznavanje entiteta u tweet porukama (više o tome [ovde](#))
 - [GeneTag dataset](#) – publikovan od strane US National Center for Biotechnology Information

Primena nadgledanog m. učenja: atributi

■ Izbor atributa

- zavisi od vrste teksta koji je predmet analize (npr. tweet poruke vs. novinski članci vs. stručni tekstovi)
- u velikoj meri utiče na performanse sistema; smatra se da ima podjednak, ako ne i veći uticaj od izbora algoritma

■ Širok spektar atributa koji se mogu koristiti:

- Atributi koji se odnose na pojedinačne reči:
dužina reči; prisutnost velikih slova; vrsta reči; učestanost pojavljivanja reči u dok. za trening; prisutnost znakova interpunkcije; pozicija reči u rečenici,...
- Atributi koji se odnose na okruženje reči:
opseg okruženja; vrsta reči u okruženju i sl.

Primena nadgledanog m. učenja: atributi

Izabrani skup atributa se koristi za predstavljanje pojedinačnih reči i/ili izraza od kojih je tekst sačinjen

Jednostavan primer

Pretpostavimo da smo izabrali sledeće attribute:

- Boolean atribut koji ukazuje da li reč počinje velikim slovom
- Numerički atribut koji predstavlja dužinu reči
- Nominalni atribut koji predstavlja reč napisanu malim slovima

Rečenica: "The apple sign makes Apple laptops easily recognizable."

će imati sledeću reprezentaciju:

```
<true, 3, "the">, <false, 5, "apple">, <false, 4, "sign">, <false, 5,  
"makes">, <true, 5, "apple">, ... , <false, 12, "recognizable">
```

Primena nadgledanog m. učenja: izbor modela

- Najčešće korišćeni modeli/algoritmi*

- Stabla odlučivanja (Decision trees)
- Hidden Markov Models (HMM)
- Maximum Entropy classification
- Support Vector Machines (SVM)
- Conditional Random Fields (CRF)

Primena nadgledanog m. učenja: evaluacija modela

- Evaluacija je zasnovana na metrikama tipičnim za sve EI zadatke:
 - Preciznost (Precision), Odziv (Recall), F mera (F measure)
- Za poređenje više pristupa/sistema (tzv. benchmarking), tipično se koriste standardni korpusi:
 - Message Understanding Conference (MUC-7): <http://goo.gl/dpWz8O>
 - CoNLL-2003 Shared Task 1: <http://www.cnts.ua.ac.be/conll2003/ner/>

Drugi oblici m. učenja

- Kao što je već rečeno, priprema dovoljno velikog skupa anotiranih dokumenata (korpusa) potrebnog za trening, je prilično zahtevan zadatak
- Usled toga, polu-nadgledano i nenadgledano m. učenje se često nameću kao alternative
 - ovi pristupi ne zahtevaju anotirani skup dokumenata
 - tradicionalno su imali slabije performanse u odnosu na pristupe nadgledanog m. učenja, ali su nova rešenja sve bolja

Polu-nadgledano m. učenje

- *Bootstrapping* je popularna tehnika polu-nadgledanog m. učenja
 - Podrazumeva mali stepen “nadgledanja”, tipično u formi inicijalno zadatog skupa primera, potrebnog za pokretanje procesa učenja
- Ilustracije radi, razmotrimo primer sistema namenjenog prepoznavanju oboljenja koja se pominju u tekstu
 - inicijalno, korisnik zadaje mali broj primera tj. naziva različitih oboljenja;
 - sistem kreće sa analizom teksta i pokušava da identificuje elemente koji karakterišu kontekst zadatih primera; zatim, pokušava da identificuje druga pojavljivanja oboljenja na osnovu identifikovanih karakteristika konteksta;
 - proces učenja se ponovo primenjuje polazeći od novo-otkrivenih instanci (oboljenja), što vodi otkrivanju novih relevantnih konteksta;
 - ponavljajući ovaj proces, veliki broj naziva oboljenja i konteksta u kojima se ona pojavljuju će biti otkriven.

Polu-nadgledano m. učenje

Preporuka:

Predavanje Tom Mitchell-a pod nazivom

Semisupervised Learning Approaches

održano u okviru

Autumn School 2006: Machine Learning over Text and Images

URL: http://videolectures.net/mlas06_mitchell_sla/

PRISTUPI ZASNOVANI NA M. UČENJU I BAZAMA ZNANJA

Pristupi zasnovani na m. učenju i bazama znanja

- Kombinacija nadgledanog m. učenja (klasifikacija) i znanja sadržanog u bazama znanja na Web-u
- Najčešće korišćene baze znanja: Wikipedia, Freebase, DBpedia
- Dodatne, napredne mogućnosti ovog pristupa:
pored prepoznavanja tipa entiteta, omogućuju i *jedinstveno identifikovanje entiteta* (disambiguation)

Pristupi zasnovani na m. učenju i bazama znanja

- Klasično prepoznavanje entiteta u tekstu:

Peter Norvig presents as part of the UBC Department of Computer Science's Distinguished Lecture Series, September 23, 2010.

- Prepoznavanje entiteta uz korišćenje baze znanja:

Tagged text

Topics

Peter Norvig presents as part of the UBC Department of Computer Science's Distinguished

Tagged text

Topics

Peter Norvig presents as part of the UBC Department of Computer Science's Distinguished Lecture Series, September 23, 2010.

UBC Computer Science Department

The UBC Computer Science department at the University of British Columbia was established in May 1968 and is among the top computer science departments in the world. UBC CS is located in Vancouver, Br...

Pristupi zasnovani na m. učenju i bazama znanja

- Dodatna pogodnost ovih pristupa je jednostavnije kreiranje skupa podataka za obučavanje algoritma
- Na primer, u slučaju Wikipedia-e:
 - Svaki termin koji predstavlja interni link u Wikipedia-i – zvaćemo ga *anchor* – tretira se kao potencijalni entitet
 - Svaki *anchor* obezbeđuje nekoliko trening instanci:
 - pozitivni primer: destinacija linka (Wikipedia stranica), odnosno “pravo” značenje datog anchor termina u datom kontekstu
 - negativni primjeri: sve ostale moguće destinacije, odnosno ostala moguća značenja datog anchor termina

Kreiranje dataset-a za obuku algoritma korišćenjem internih Wikipedia linkova – ilustracija pristupa

Za termin (anchor) *tree* postoji 26 mogućih destinacija (tj. značenja), što daje 1 poz. primer i 25 neg. primera za trening algoritma

Depth-first search

From Wikipedia, the free encyclopedia

Depth-first search (DFS) is an algorithm for traversing or searching a tree structure or graph. One starts at the root (selecting some node as the root in the graph case) and explores as far as possible along each branch before backtracking.

Formally, DFS is an uninformed search that progresses by expanding the first child node of the search tree that appears and thus going deeper and deeper until a goal node is found, or until it hits a node that has no children. Then the search backtracks, returning to the most recent node it hadn't finished exploring. In a non-recursive implementation, all freshly expanded nodes are added to a LIFO stack for exploration.

sense	commonness	relatedness
Tree	92.82%	15.97%
Tree (graph theory)	2.94%	59.91%
Tree (data structure)	2.57%	63.26%
Tree (set theory)	0.15%	34.04%
Phylogenetic tree	0.07%	20.33%
Christmas tree	0.07%	0.0%
Binary tree	0.04%	62.43%
Family tree	0.04%	16.31%
...		

Ovim pristupom se, npr., od svega 500 Wikipedia članaka, može dobiti dataset od > 50,000 instanci

Pristupi zasnovani na m. učenju i bazama znanja

Osnovni koraci u procesu prepoznavanja entiteta u tekstu:

- 1) *Spotting* – identifikacija tzv. *entity-spots* tj. termina za koje se prepostavlja da bi mogli predstavljati entitete u tekstu
- 2) *Candidate selection* – za svaki *entity-spot*, vrši se selekcija potencijalnih koncepata* iz baze znanja (npr. Wikipedia-e)
- 3) *Disambiguation* – izbor “najboljeg” koncepta za svaki *entity-spot*, tj. koncepta koji najbolje odražava semantiku datog termina u datom kontekstu
- 4) *Filtering* – filtriranje rezultata u cilju eliminacije irrelevantnih entiteta

* Koncept je predstava realnog entiteta u bazi znanja; npr. za entitet Beograd, koncept u Wikipedia-i je <http://en.wikipedia.org/wiki/Belgrade>

Pristupi zasnovani na m. učenju i bazama znanja

Servisi koji implementiraju opisani pristup

- Wikipedia Miner - obezbeđuje niz servisa:
 - *wikify* – identificuje entitete/koncepte iz Wikipedia-e u zadatom tekstu
 - *compare* – utvrđuje i objašnjava povezanost između dva Wikipedia koncepta
 - *suggest* – predlaže teme/koncepte koji su semantički slični/srodni zadatim konceptima
- TagMe – obezbeđuje sledeće servise:
 - *tagging* – identificuje entitete/koncepte iz Wikipedia-e u zadatom tekstu
 - *spotting* – detektuje relevantne termine u tekstu (ne povezuje ih sa Wikipedia konceptima)
 - *relating* – određuje semantičku povezanost dva zadata koncepta

KORISNI WEB RESURSI

Korisni Web resursi vezani za ovu temu

Google Wikilinks Corpus

- Najveći javno dostupan dataset za obuku algoritama nadgledanog m. učenja za prepoznavanje (Wikipedia) entiteta u tekstu
- Osnovni podaci:
 - 10 miliona Web stranica
 - 3 miliona Wikipedia entiteta
 - 40 miliona jedinstveno identifikovanih pominjanja entiteta
 - publikovan 08.03.2013. od strane Google Research-a
- Više informacija u članku:
[Learning from Big Data: 40 Million Entities in Context](#)

Korisni Web resursi vezani za ovu temu

Softverski alati za prepoznavanje entiteta u tekstu

- AlchemyAPI: <http://www.alchemyapi.com/tools/>
- Open Amplify: <http://www.openamplify.com/quickstart>
- Text Razor: <http://www.textrazor.com/>
- Machine Linking: <http://www.machinelinking.com/>
- TagMe: <http://tagme.di.unipi.it/>
- Wikipedia Miner: <http://wikipedia-miner.cms.waikato.ac.nz/>
- Denote: <http://denote.io/>

Korisni Web resursi vezani za ovu temu

- Aktuelni Java okviri (frameworks) za analizu i razumevanje teksta
 - Apache OpenNLP: <http://opennlp.apache.org/>
 - Apache Stanbol: <http://stanbol.apache.org/>
 - GATE: <http://gate.ac.uk/>
 - LingPIPE: <http://alias-i.com/lingpipe/>

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

<http://goo.gl/cqdp3I>