

Obrada prirodnih jezika

Elektrotehnički fakultet Univerziteta u Beogradu

Master akademske studije

modul Softversko inženjerstvo

2022/2023

Uvod u obradu prirodnih jezika

Vuk Batanović, Elektrotehnički fakultet Univerziteta u Beogradu

Obrada prirodnih jezika

- ▶ Engl. *Natural Language Processing* - *NLP*
- ▶ Oblast na raskršću računarskih nauka (veštačke inteligencije/mašinskog učenja), inženjerstva, lingvistike i (kognitivne) psihologije
- ▶ Često se za NLP koristi i alternativan naziv - računarska lingvistika (engl. *computational linguistics*)
- ▶ Pod *prirodnim* se podrazumevaju jezici koje ljudi prirodno koriste za međusobnu komunikaciju
 - ▶ Engleski, srpski, japanski,...
 - ▶ Nasuprot veštačkim jezicima
 - ▶ Jezici specijalne namene - npr. Morzeovi znaci
 - ▶ Programski jezici

Čemu računarska obrada prirodnih jezika?

- ▶ Podaci na prirodnim jezicima u tekstualnom obliku su prisutni svuda i sve ih je više
 - ▶ Knjige, časopisi, novine, e-mail, društvene mreže,...
- ▶ Najveći deo ljudskog znanja je dostupan samo u nestrukturiranom tekstualnom obliku (nasuprot strukturiranim izvorima znanja poput relacionih baza podataka)
- ▶ Tekstualni podaci gotovo uvek imaju svoju internu strukturu, ali ona se obično ne može lako i direktno prevesti u mašinski čitljiv oblik
 - ▶ Lingvistička struktura - sintaktička i diskursna struktura
 - ▶ Struktura formatiranja - podela na pasuse, sekcije/poglavlja/glave

Zašto je računarska obrada prirodnih jezika teška?

- ▶ Prirodni jezici imaju veći broj osobina koji ih čine teškim za mašinsku obradu
 - ▶ Veliki stepen kompleksnosti
 - ▶ Česte nejasnoće u izražavanju
 - ▶ Česte dvosmislenosti/višesmislenosti u izražavanju
 - ▶ Razumevanje iskaza često zavisi od posedovanja šireg znanja o svetu (engl. *world knowledge*)
- ▶ Potpuno razumevanje prirodnih jezika je AI-potpun problem
 - ▶ Da bi se rešio, potrebno je da računari dostignu/prestignu ljudski nivo inteligencije
 - ▶ Nije moguće rešiti ovaj problem korišćenjem nekog uže specijalizovanog, jednostavnijeg algoritma

Kompleksnost jezika

- ▶ Postoji više različitih aspekata kompleksnosti jezika
- ▶ Morfološka kompleksnost - više različitih oblika jedne iste reči
- ▶ Sintaktička kompleksnost - više različitih sintaktičkih struktura koje su validne za jedan isti izraz
- ▶ Semantička kompleksnost - više različitih značenja za jednu istu reč/izraz
 - ▶ Frazeologizmi/idiomi - ustaljene jezičke jedinice od bar dve reči, imaju jedinstveno značenje koje se ne može izvesti iz značenja reči u njihovom sastavu
 - ▶ *Carski rez*
 - ▶ *Kupiti mačku u džaku*
 - ▶ *Izvoditi besne gliste*
 - ▶ *Novinarska patka*
 - ▶ *Obrati (zelen) bostan*
 - ▶ *Slepi putnik*

Kompleksnost jezika

- ▶ Semantička kompleksnost
 - ▶ Za razumevanje značenja frazeologizama često je neophodan kulturološki kontekst/znanje o svetu
 - ▶ *Lupati kao Maksim po diviziji*
 - ▶ *Razbiti kao bugarsku skupštinu*
 - ▶ *Ahilova peta*
 - ▶ Ovo deluje intuitivno jasno kada razmatramo kulturu u kojoj smo odrasli, ali postaje izuzetno teško kada se razmatra kultura koja nam je nepoznata
 - ▶ U kineskom jeziku postoji 5000 - 20000 idioma, izvedenih iz klasičnih kineskih tekstova
 - ▶ *Pritajeni tigar, skriveni zmaj*
 - ▶ Ekstremalni primer iz naučne fantastike - *Star Trek: The Next Generation, Season 5, Episode 2: Darmok*

Nejasnoće u izražavanju

- ▶ Nejasnoće u izražavanju na prirodnim jezicima su ponekad slučajne, ali su vrlo često i namerne
 - ▶ Naročito kada se radi o političkim ili reklamnim porukama
- ▶ Primeri nejasnih reklamnih poruka (preuzeti iz rada Vidaković, Trninić-Janjić (2017): *Verbalni mamci u reklamnim oglasima na engleskom i srpskom jeziku*)
 - ▶ *Traje 3x duže nego što ste očekivali.* (Fairy)
 - ▶ *Muzika nikada nije bolje zvučala.* (zvučnici)
 - ▶ *Vozite dalje. Živite bolje.* (Renault)
 - ▶ *Izuzetna nega sa dva patenta pomaže u borbi protiv znakova starenja kože.* (krema za kožu)
 - ▶ *Verujte snazi Q10 plus bisernih perli u borbi protiv bora.* (krema za kožu)

Nejasnoće u izražavanju

- ▶ Primeri političkih fraza
 - ▶ *Nastavak strukturnih reformi/restrukturiranje*
 - ▶ *Treba ostaviti prošlost iza sebe i okrenuti se budućnosti*
 - ▶ *Reformska agenda je neophodna za ekonomski oporavak zemlje*
 - ▶ *Po prvi put u novijoj istoriji*
 - ▶ *Neophodan je pragmatičan pristup*
 - ▶ *Rešili smo da preuzmemo odgovornost*

Nejasnoće u izražavanju

- ▶ Povezivanjem i kombinovanjem političkih fraza dobijaju se celi iskazi za koje je nejasno šta (i da li išta) znače
 - ▶ *Mnogo se s pravom očekuje od mjera u sklopu projekta za Slavoniju, Baranju i Srijem, posebice kada je riječ o otvaranju prostora novim proizvodnim i drugim razvojnim investicijama s krajnjim ciljem pune zaposlenosti, rasta plaća i standarda. To je od ključne važnosti kako bismo zadržali mlade i očuvali ljudske resurse za buduće generacije, poručila je Grabar Kitarović.*
 - ▶ *Takođe smo od strane jedne od najaktivnijih međunarodnih nevladinih organizacija, koja se bavi Opštim periodičnim pregledom, preporučeni kao primjer pozitivne prakse u vođenju preglednog mehanizma, odnosno načina uključivanja UN agencija i nacionalnih nevladinih organizacija u proces - kazao je Đukanović.*

Dvosmislenosti/višesmislenosti u izražavanju

- ▶ Veći broj različitih izvora dvosmislenosti/višesmislenosti u jeziku
 - ▶ Kategorijska
 - ▶ Leksička
 - ▶ Sintaktička
 - ▶ Referencijalna
 - ▶ Pragmatička
- ▶ Većina iskaza sadrži bar neki oblik dvosmislenosti
 - ▶ Ljudi najčešće to ni ne primećuju
 - ▶ Ljudi dvosmislenosti uglavnom razrešavaju korišćenjem šireg tekstualnog konteksta, znanja o svetu i zdravorazumskih pretpostavki
 - ▶ Ovo svojstvo jezika se vrlo često koristi u šalama i vicevima

Kategorijska dvosmislenost/višesmislenost

- ▶ Proističe iz toga što jedan isti oblik reči može da predstavlja više vrsta reči
- ▶ *Ona je bila mlada.*
 - ▶ Ona je imala malo godina.
 - ▶ Ona je bila nevesta.
- ▶ *Gore gore gore gore.*
 - ▶ Jedan isti oblik reči može da bude i imenica, i glagol, i prilog, i pridev
 - ▶ Lošija brda gore iznad. / Brda iznad lošije gore. (pored kategorijske, postoji i sintaktička dvosmislenost)

Leksička dvosmislenost/višesmislenost

- ▶ Polisemija - više srodnih značenja jedne reči, nastaje zbog uočavanja sličnosti
 - ▶ *Crkva* - *građevina/institucija*
 - ▶ *Glava* - *deo tela/strana novčića/deo knjige/starešina, rukovodilac/...*
 - ▶ *Miš* - *životinja/uređaj za interakciju sa računarom*
 - ▶ *Kucati* - *tekst/na vrata*
- ▶ Homonimija - više potpuno nepovezanih značenja jedne reči
 - ▶ *Sto* - *nameštaj/broj*
 - ▶ *Pop* - *sveštenik/muzički žanr*
 - ▶ *Zavijati* - *umotavati/otegnuto urlati*
- ▶ Može da iskomplikuje tumačenje značenja rečenice
 - ▶ *Siledžijama će da odgovaraju nadležni organi.*

Sintaktička dvosmislenost/višesmislenost

- ▶ Prostiće iz toga što neka sekvenca reči može imati više strukturalnih tumačenja
 - ▶ Često proizlazi iz dvosmislenosti vezivanja predložno-padežnih konstrukcija
- ▶ Nekad je rešiva korišćenjem šireg znanja o svetu
 - ▶ Naslov: *Sve složenije operacije u novopazarskoj Opštoj bolnici*
 - ▶ Primeri iz: Uvod u opštu lingvistiku, Ranko Bugarski (2003)
 - ▶ *Dve devojčice ujele meduze.*
 - ▶ *Veliki broj studenata ugrožava nastavu.*
 - ▶ *Razgovor doktora Petra Petrovića o braku sa pitomcima JNA*

Sintaktička dvosmislenost/višesmislenost

- ▶ Nekad ni šire znanje o svetu (osim ako nije vrlo specifično) ne pomaže
 - ▶ *Održao je predavanje na skupu o tehnološkim kretanjima u Londonu.*
 - ▶ *Kupio sam košulju i džemper na pruge.*
 - ▶ *Vidim čoveka bez naočara.*
 - ▶ *Doneo sam ti voće iz Španije.*
 - ▶ *Pozvao je prijatelje sa Malte.*
 - ▶ Primeri iz: Uvod u opštu lingvistiku, Ranko Bugarski (2003)
 - ▶ *Jovanu je lako verovati.*
 - ▶ *Stvaranje umetnika*
 - ▶ *Kritika članstva*

Referencijalna dvosmislenost/višesmislenost

- ▶ Proizlazi iz više mogućih tumačenja na koji entitet ili deo rečenice se neki iskaz odnosi
- ▶ *Petar je javio Marku da je kupio auto.*
 - ▶ Petar je kupio auto.
- ▶ *Petar je javio Marku da je dobio posao.*
 - ▶ Ko je dobio posao?
- ▶ - „*Profesorka, da li treba da popunjavamo neme karte ili ne?*“ - „*Naravno!*“
 - ▶ Referencijalna dvosmislenost zbog izostavljanja određenih reči (elipse)
- ▶ *Ako je bankarska kartica ispravna, klijent treba da unese svoj PIN broj u ATM. U suprotnom, biće ispisana poruka o neuspeloj transakciji.*
 - ▶ Da li se poruka ispisuje kada je kartica neispravna, ili kada klijent ne unese PIN?

Pragmatička dvosmislenost/višesmislenost

- ▶ Proizlazi iz više mogućih tumačenja cilja koji se želi postići nekim iskazom, iako je osnovno značenje iskaza jasno
- ▶ Pragmatičke dvosmislenosti/višesmislenosti se često ne mogu razrešiti ni uvidom u širi tekstualni kontekst
- ▶ *Znate li koliko je sati?*
 - ▶ Može da predstavlja upit za tačno vreme ili prekor povodom kašnjenja
- ▶ *Na putu sam.*
 - ▶ Može da predstavlja napomenu o tome da je govornik na odsustvu, ili uveravanje da ubrzo stiže.

Istorijat obrade prirodnih jezika

- ▶ 1950 - Alan Tjuring predložio test inteligencije za mašine koji se zasniva na pisanoj komunikaciji u realnom vremenu između mašine i čoveka
 - ▶ Postavka - jedan čovek (sudija) komunicira pisanim putem sa drugim čovekom i sa mašinom; oba sagovornika pokušavaju da se predstave kao ljudi
 - ▶ Cilj - da mašina uspešno prevari sudiju, tako da on nije siguran koji sagovornik je mašina a koji čovek
 - ▶ Tjuring predvideo da će do kraja 20. veka mašina sa 10 GB memorije biti u stanju da zavara 30% ljudi tokom petominutnog razgovora
 - ▶ Od 1991. - Lebnerova nagrada - godišnje takmičenje programa u formatu Tjuringovog testa
 - ▶ Glavna ideja - korišćenje jezika na nivou ljudi je dovoljno kao operativni test inteligencije
 - ▶ Kasnije dovedeno u pitanje - Kineska soba, Džon Serl

Istorijat obrade prirodnih jezika

- ▶ 1957 - Noam Čomski objavio *Sintaksičke strukture*
 - ▶ Opisuje jezik kroz ideju generativne gramatike - skupa logičkih pravila pomoću kojih je moguće generisati beskonačan broj mogućih ispravnih rečenica u zadatom jeziku i pridodati im ispravan strukturalni opis
 - ▶ Jedno od najvažnijih dela u modernoj lingvistici
- ▶ Krajem 1950-tih i početkom 1960-tih - podela istraživanja na dve paradigme - simboličku i stohastičku
- ▶ Simbolička paradigma
 - ▶ Rad Čomskog i drugih na formalnoj teoriji jezika i generativnoj sintaksi
 - ▶ Razvoj algoritama za parsiranje
 - ▶ Istraživanja u domenu rezonovanja i logike - prvi sistemi za razumevanje prirodnih jezika zasnovani na prepoznavanju ključnih reči i jednostavnim heuristikama za prepoznavanje obrazaca i odgovaranje na pitanja

Istorijat obrade prirodnih jezika

- ▶ 1966 - Džozef Vajzenbaum napravio program ELIZA - prvi NLP sistem sposoban za (vrlo ograničenu) konverzaciju sa korisnikom
 - ▶ Zasnovan na jednostavnom detektovanju jezičkih obrazaca pomoću ključnih reči i transliranju upita korisnika u izlaz mašine
 - ▶ Program imitirao odgovore psihoterapeuta
 - ▶ User₁: You are like my father in some ways.
 - ▶ ELIZA₁: WHAT RESEMBLANCE DO YOU SEE
 - ▶ User₂: You are not very aggressive but I think you don't want me to notice that.
 - ▶ ELIZA₂: WHAT MAKES YOU THINK I AM NOT AGGRESSIVE
 - ▶ User₃: You don't argue with me.
 - ▶ ELIZA₃: WHY DO YOU THINK I DON'T ARGUE WITH YOU
 - ▶ User₄: You are afraid of me.
 - ▶ ELIZA₄: DOES IT PLEASE YOU TO BELIEVE I AM AFRAID OF YOU

Istorijat obrade prirodnih jezika

- ▶ Stohastička paradigma
 - ▶ 1964 - Bajesovske metode primenjene na zadatak određivanja autorstva Federalističkih spisa
 - ▶ 1963/64 - Brown Corpus of American English - korpus od milion reči raspodeljenih po 500 tekstova izvučenih iz različitih žanrova (vesti, romani, akademski tekstovi,...)
 - ▶ Veliki uticaj na razvoj sistema za prepoznavanje govora
 - ▶ *Noisy channel* modeli
 - ▶ Skriveni Markovljevi lanci (engl. *Hidden Markov Models*)

Istorijat obrade prirodnih jezika

- ▶ 1950-tih i 60-tih godina puno pažnje posvećeno problemu mašinskog/automatskog prevodenja
 - ▶ Veliko interesovanje državnih i vojnih aktera u SAD-u zbog Hladnog rata
 - ▶ 1954 - Georgetown-IBM eksperiment - demonstracija automatskog prevodenja preko 60 rečenica sa ruskog na engleski
 - ▶ Autori tvrdili da će mašinsko prevodenje biti rešen problem za tri do pet godina
- ▶ Istraživači izuzetno potcenili kompleksnost problema
 - ▶ 1966 - zbog velikih obećanja, a slabih rezultata, američki savetodavni komitet za automatsku obradu jezika (ALPAC) dao negativno mišljenje o rezultatima istraživanja mašinskog prevodenja
 - ▶ Dovelo do dramatičnog pada finansiranja i zanimanja za ovu problematiku, sve do 1980-tih i pojave statističkih sistema za prevodenje
 - ▶ Posredno dovelo do usporenog razvoja u celoj oblasti NLP-a

Istorijat obrade prirodnih jezika

- ▶ 1970-tih godina - Modeli zasnovani na konačnim automatima (engl. *finite-state models*) i ručno pisanim pravilima postaju prominentni u fonološkim, morfološkim i sintaktičkim problemima
- ▶ 1968-70 - Teri Vinograd napravio SHRDLU - prvi sistem za razumevanje prirodnog jezika (engl. *natural language understanding*)
 - ▶ Simulacija robota koji se kreće u svetu blokova koje treba pomeriti
 - ▶ Prvi pokušao da u NLU sistem ugradi sveobuhvatnu gramatiku engleskog jezika
 - ▶ Sistem bio u stanju da razume do tada neviđen nivo kompleksnosti komandi
 - ▶ *Move the red block on top of the smaller green one*
 - ▶ Uspeh sistema demonstrirao da je problem parsiranja prirodnog jezika rešen u meri da se može preći na probleme semantike i analize diskursa

Istorijat obrade prirodnih jezika

- ▶ Kasnih 1980-tih godina - Probabilistički modeli i modeli zasnovani na upotrebi podataka se razvijaju za probleme iz sintakse i semantike
- ▶ Od 1990-tih godina na dalje - „*Statistička revolucija*“
 - ▶ Velike količine tekstualnih podataka postaju dostupne preko interneta
 - ▶ Porast brzine i memorijskih kapaciteta računara dovodi do komercijalne primene većeg broja NLP zadataka (prepoznavanje govora, provera pravopisa, dohvatanje informacija, itd.)
 - ▶ Modeli zasnovani na upotrebi podataka/mašinskom učenju, kao i metodologija evaluacije razvijena za takva rešenja, nameću se kao standard u većini NLP zadataka
 - ▶ Izuzetno intenzivan razvoj novih modela, konceptualizacija novih zadataka, i razvoj NLP rešenja i za jezike osim engleskog

Obrada prirodnih jezika danas

- ▶ 2002 - prvi radovi na temu analize sentimenta
- ▶ 2011 - *Apple Siri*
- ▶ 2011 - *IBM Watson* pobedio šampione u kvizu *Jeopardy!*
- ▶ Od oko 2013 na dalje - sve šira upotreba neuralnih mreža u NLP-u
 - ▶ 2013 - *word2vec*
 - ▶ 2016/2017 - *WaveNet*
 - ▶ 2017 - *Google Neural Machine Translation*
 - ▶ 2018/2019 - *BERT*
- ▶ Istraživanja se sve više kreću u pravcu multilingvalnih, kros-lingvalnih, i multimodalnih rešenja (kombinovanje analiza teksta i slike/videa)

Konceptualni pristupi obradi prirodnih jezika

- ▶ Metode zasnovane na ručno sastavljenim pravilima i bazama znanja (engl. *rule-based NLP*)
 - ▶ Simboličko procesiranje, konačni automati, logičko rezonovanje
 - ▶ Generalno govoreći prilično tačne metode, ali veoma krhke
 - ▶ Loše performanse na primerima koji nisu pokriveni postojećim pravilima/bazama znanja
 - ▶ Izrada sveobuhvatnih skupova pravila/baza znanja za određenu problematiku je izuzetno naporna i često zahteva ekspertsко znanje
 - ▶ Jezik se vremenom menja - neophodno je stalno ručno ažurirati sistem
- ▶ Metode zasnovane na statistici i podacima (engl. *statistical NLP*)
 - ▶ Daleko robusnije i fleksibilnije, ali zahtevaju odgovarajuće podatke, obično anotirane, koji se koriste za uočavanje obrazaca
 - ▶ (Nadgledano) mašinsko učenje, teorija verovatnoće


“

Every time I fire a linguist, the performance of our speech recognition system goes up.

”

Frederik Jelinek, istraživač automatskog prepoznavanja govora

- ▶ Ispravan lingvistički tretman nekog jezičkog fenomena ne mora nužno da dovede do željenih poboljšanja u smislu praktičnih efekata
- ▶ Sa druge strane, odsustvo lingvističkog znanja pri izradi rešenja ograničava obradu jezika na relativno rudimentarne/inženjerske zadatke



Dijagram faza u procesu razvoja statističkih rešenja za obradu prirodnih jezika

Slika preuzeta iz: V. Batanović, *Metodologija rešavanja semantičkih problema u obradi kratkih tekstova napisanih na prirodnim jezicima sa ograničenim resursima*, Elektrotehnički fakultet, Univerzitet u Beogradu, 2020.

Prikupljanje tekstualnog sadržaja

- ▶ Problem pronalaženja adekvatnih izvora tekstualnih podataka
 - ▶ Nekada je moguće iskoristiti digitalizovane kolekcije tekstova ili postojeće skupove podataka koji su razvijeni za rešavanje nekih srodnih problema
 - ▶ Češći slučaj za velike svetske jezike
 - ▶ Internet se često koristi kao izvor podataka
 - ▶ Treba voditi računa o tome da podaci nad kojima će se model kasnije primenjivati budu iste/slične prirode kao oni nad kojima se obučava
 - ▶ Tipično se koriste biblioteke za parsiranje i obradu HTML i *JavaScript* koda, kao što su: *JSoup*, *BeautifulSoup*, *Scrapy*, *HTMLUnit*,...
- ▶ Za manje jezike (poput srpskog) može biti teško pronaći dovoljne količine podataka
- ▶ Prikupljeni tekstovi se obično filtriraju na neki način pre dalje obrade

Anotacija podataka


- ▶ Obeležavanje prikupljenih podataka korišćenjem određenog sistema označavanja vezanog za problem koji se rešava
 - ▶ Za neke zadatke (npr. analizu sentimenta) anotaciju mogu da vrše i ljudi koji nisu domenski eksperti
 - ▶ Za druge zadatke (npr. parsiranje) sprovođenje anotacije zahteva ekspertsко lingvističko znanje
- ▶ U oba slučaja insistiranje na kvalitetu anotacije je izuzetno važno da bi primena statističkih modela imala smisla
 - ▶ Pravljenje dovoljno detaljnih i jasnih uputstava za anotaciju
 - ▶ Odabir kvalitetnih anotatora

Anotacija podataka

- ▶ Gornja granica za performanse bilo kog računarskog sistema je stepen slaganja anotatora
 - ▶ Ako ljudi ne mogu da se slože šta je tačan odgovor u X% slučajeva, onda nema smisla očekivati da računarski sistem performira preko tog nivoa
 - ▶ Slaganje anotatora sa samim sobom - provera konzistentnosti anotacije
- ▶ Česte metrike za merenje stepena saglasnosti anotatora
 - ▶ Procentualna saglasnost anotatora
 - ▶ Problem: ne uzima u obzir stepen slučajne saglasnosti anotatora
 - ▶ Koenov (*Cohen's*) *kappa* i Skotov (*Scott's*) *pi* koeficijent
 - ▶ Uzimaju u obzir stepen slučajne saglasnosti anotatora
 - ▶ Koriste se za merenje saglasnosti u obeležavanju kategorijskih oznaka tj. klase
 - ▶ Namjenjeni određivanju saglasnosti dva anotatora

Anotacija podataka

- ▶ Česte metrike za merenje stepena saglasnosti anotatora
 - ▶ Flajsov (*Fleiss'*) *kappa* koeficijent
 - ▶ Proširenje Skotovog *pi* koeficijenta na više anotatora
 - ▶ Pirsonov (*Pearson*)/Spirmanov (*Spearman*) koeficijent korelacije
 - ▶ Koriste se za određivanje korelacije između dva skupa realnih numeričkih oznaka
 - ▶ Pirsonov koeficijent definiše korelaciju između samih numeričkih vrednosti
 - ▶ Spirmanov koeficijent definiše korelaciju između rangova numeričkih vrednosti
 - ▶ Kripendorfov (*Krippendorff's*) *alpha* koeficijent
 - ▶ Opšta i preporučena metrika za izražavanje stepena (ne)saglasnosti anotatora
 - ▶ Primenjiv na proizvoljan broj anotatora
 - ▶ Primenjiv na širok spektar različitih tipova oznaka: binarne, kategoriske, ordinalne, intervalske,...



Dijagram koraka u fazi anotacije podataka

Slika preuzeta iz: V. Batanović, *Metodologija rešavanja semantičkih problema u obradi kratkih tekstova napisanih na prirodnim jezicima sa ograničenim resursima*, Elektrotehnički fakultet, Univerzitet u Beogradu, 2020.

Koraci u fazi anotacije podataka

- ▶ 1. Odabir oznaka za obeležavanje podataka, zajedno sa njihovim definicijama i interpretacijama
 - ▶ Korišćenje standardizovanih oznaka za posmatrani problem, ako postoje
 - ▶ Razvoj novog sistema označavanja
- ▶ 2. Formulisanje uputstava za anotaciju
 - ▶ Izgled i obim uputstava može primetno varirati u zavisnosti od konkretnog problema koji se razmatra, usvojenog sistema oznaka, i konceptualnih odluka vezanih za željeni nivo detaljnosti uputstava
 - ▶ Detaljnija uputstva najčešće omogućavaju viši stepen saglasnosti anotacionih odluka između anotatora, tj. veću konzistentnost anotacije
 - ▶ Podiže kvalitet anotiranih resursa, po cenu nešto sporijeg procesa anotacije

Koraci u fazi anotacije podataka

- ▶ 3. Obučavanje anotatora i kalibracija
 - ▶ Upoznavanje anotatora sa uputstvima (i alatom za anotaciju, ako se koristi)
 - ▶ Kalibracija - anotacija probnog podskupa prikupljenih podataka
 - ▶ Razrešavanje nedoumica anotatora i dorada uputstava
- ▶ 4. Sprovođenje anotacije
 - ▶ Anotatori obično rade individualno
 - ▶ Jednostruka vs. višestruka anotacija
 - ▶ Finalne oznake u višestrukoj anotaciji kod kategoričkih ili strukturiranih oznaka - proces razrešavanja neslaganja (engl. *curation*)
- ▶ 5. Analiza sprovedene anotacije
 - ▶ Razmatranje konzistentnosti anotacije
 - ▶ Statistička analiza anotiranih podataka

Koraci u fazi anotacije podataka

- ▶ U praksi neretko dolazi do preklapanja između nekih od koraka
 - ▶ Obično se dešava kod složenijih anotacionih projekata, gde je teško unapred, pre detaljnog uvida u podatke, dizajnirati sasvim adekvatan skup oznaka i dovoljno sveobuhvatan set uputstava za anotaciju
 - ▶ Može doći i do cikličnog povezivanja prva tri koraka
- ▶ Ponekad se anotacija podataka može preskočiti ili automatizovati
 - ▶ Postojeći indikatori u prikupljenom sadržaju se koriste kao oznake
 - ▶ Npr. numeričke ocene ili broj zvezdica u opisima/recenzijama se koriste kao oznake sentimenta
 - ▶ Ograničenja u pogledu fleksibilnosti oznaka - oznake u potpunosti određene prisutnim indikatorima
 - ▶ Automatizovane oznake mogu i da unesu šum u podatke

Formulisanje, obučavanje i evaluacija modela

- ▶ Statistički modeli zasnovani na nadgledanom mašinskom učenju
 - ▶ Ulaz modela: anotirani prikupljeni podaci
- ▶ Razmatranje različitih (varijanti) modela
- ▶ Razmatranje različitih tehnika pretprocesiranja podataka
- ▶ Tačan oblik modela zavisi od problema koji se razmatra, kao i od konceptualnog pristupa rešavanju tog problema