



## SENTIMENT ANALIZA OBJAVA SA DRUŠTVENE MREŽE TWITTER O COVID-19 VAKCINAMA

### SENTIMENT ANALYSIS OF TWITTER POSTS ON COVID-19 VACCINES

Filip Zdelar, *Fakultet tehničkih nauka, Novi Sad*

#### Oblast – RAČUNARSTVO I AUTOMATIKA

**Kratak sadržaj** – U ovom radu predstavljen je razvoj sistema za analizu Twitter podataka o vakcinama protiv COVID-19 virusa u Srbiji. Analiza uključuje sistem za detekciju sentimenta i detekciju teme kojom se tvit bavi. Za potrebe izrade projekta, preuzet je označen skup engleskih twitova i prikupljen skup srpskih twitova koju su prevedeni na engleski jezik. Za detekciju sentimenta isprobana su dva pristupa obučavanje modela nadgledanog učenja na označenom skupu podataka engleskih twitova o COVID-19 virusu. Na zadatku detekcije sentimenta najbolje performanse ostvarene su kovolucione neuronske mreže metodom koja je postizala tačnost 59% i identifikovano da postoji ukupno je 38% pozitivnih, 37% negativnih i 25% neutralnih srpskih twitova. Model tema ostvario je koherenciju od 0.45 i identifikovano je petnaest tema.

**Ključne reči:** sentiment, topic , twitter, COVID-19, NLP, neuronske mreže

**Abstract** – This paper presents the development of a system for analyzing Twitter data about COVID-19 vaccines in Serbia. The analysis includes a sentiment detection system and a topic detection system related to the tweets. For the project's development, a labeled set of English tweets was used, along with a collection of Serbian tweets that were translated into English. Two approaches were tested for sentiment detection: supervised learning by training a model on a labeled dataset of English tweets about COVID-19. The best performance in sentiment detection was achieved using convolutional neural networks, which achieved an accuracy of 59%. It was identified that there are 38% positive, 37% negative, and 25% neutral Serbian tweets in the dataset. The topic model achieved a coherence score of 0.45, identifying fifteen topics.

**Keywords:** sentiment, topic, Twitter, COVID-19, NLP, neural networks

#### 1. UVOD

Planeta se suočila sa velikom pandemijom korona virusa krajem 2019. godine. Izbijanje bolesti korona virusa (COVID-19) u velikoj meri je uticalo na ljudski život. Zdravlje ljudi ugroženo je ne samo zbog vanredne situacije, već i zbog naknadnih društvenih ishoda kao što

#### NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Aleksandar Kovačević, red. prof.

su nezaposlenost, nedostatak resursa i finansijska kriza. U ovakvim okolnostima kao sredstvo za borbu javljaju se vakcine i od sve veće važnosti postaje politika javnog zdravlja. Svetska zdravstvena organizacija (SZO) navodi da je ravnopravan pristup sigurnim i efikasnim vakcinama ključan za okončavanje pandemije COVID-19 i neumorno radi sa partnerima na razvoju, proizvodnji i primeni bezbednih i efikasnih vakcina [1]. Do 13. aprila 2022. godine na listi SZO za hitnu upotrebu je odobreno 10 vakcina protiv COVID-19, dok je ukupno 37 vakcina koje su licencirane i odobrene za upotrebu u hitnim slučajevima u bar jednoj državi, a 195 vakcina je u procesu razvoja i odobravanja [2].

Prvi slučaj korona virusa u Srbiji potvrđen je 6. marta 2020. godine, nakon čega zemlju zahvata epidemija i uvode se mere za suzbijanje sirenja virusa. Država Srbija 19. januara 2021. godine predstavlja sistem za primenu, zakazivanje i praćenje vakcina i imunizacije stanovništva. Upućen je poziv građanima da se vakcinišu u što većem broju i započet je proces masovne vakcinacije [3]. U naporima za postizanjem imunizacije stanovništva, nadležnim organima postaje sve neophodniji uvid u stavove šire javnosti povodom vakcinacije. Uspešno sprovođenje imunizacije stanovništva podrazumeva pozitivan stav građana prema vakcinama, pa jedan od zadataka učesnika u javnom zdravlju predstavlja odgovor na stavove ljudi koji se protive imunizaciji.

Za sistem javnog zdravlja može biti od značaja informacija o razlozima negativnog stava prema vakcinama, kako bi se kroz aktivnosti sistema javnog zdravlja moglo uticati na formiranje pozitivnog mišljenja javnosti. Dobra okolnost čini to što društvene mreže predstavljaju uobičajeno mesto za ljude da izraze svoje emocije i stavove, pa je velika dostupnost informacija o stavovima javnosti o značajnim temama, kao što je i milionski broj javno dostupnih objava na temu vakcina na društvenoj mreži kao što je Twitter. Analiza sentimenta može pružiti pravovremeni uvid u stav i mišljenje javnosti prema COVID-19 vakcinama i obezbediti smernice za kreiranje politike javnog zdravlja i dizajniranje prilagođenih programa edukacije o vakcinama.

Uz uvid u teme koje se javljaju u diskusijama koje sadrže negativan ili pozitivan stav prema vakcinaciji, moguće je poboljšati interakciju nadležnih organa sa širom javnošću i delovati u pravcu uspešne imunizacije stanovništva. U ovom radu će biti predstavljeno jedno rešenje za analizu podataka sa Twittera o COVID-19 vakcinama. Rešenje omogućava razumevanje stavova javnosti povodom vakcinacije i identifikaciju glavnih tema u objavama negativnog i pozitivnog sentimonta. Detaljniji opis

podataka, izazova i rešenja izložen je u ostatku rada. Naredno poglavlje se bavi srodnim istraživanjima na ovu temu. U trećem poglavlju će biti opisan skup podataka, način pripreme podataka za obučavanje i validaciju modela. Nakon toga, biće predstavljena metodologija koja je korišćena za rešavanje problema detekcije sentimenta i tema. Potom sledi prikaz rezultata i diskusija. Na samom kraju biće izvedeni zaključci samog rada.

## 2. METODOLOGIJA

U ovom poglavlju je predstavljeno preprocesiranje tвитова, implementacija sistema za analizu sentimenata i analizu tema. Moduli za sentiment analizu su opisani u dva podpoglavlja, jedno koje je zasnovano na nadgledanom učenju i drugo koje je zasnovano na nenadgledanom učenju.

Modeli za klasifikaciju imaju na ulazu *TF-IDF* i *BERT* vektore tвитова, a izlaz klasifikatora su tri moguće klase; tвит je za vakcinaciju, tвит je neutralan povodom vakcinacije ili ne može da se odredi, i tвит je protiv vakcinacije. Analizom tema bi se dinamički odredile teme koje postoje u skupu podataka i izvršilo bi se prebrojavanje broja tвитова koje pripadaju jednoj temi.

### 2.1. Preprocesiranje

Pre upotrebe podataka urađenu su sledeće transformacije, kako bi se skup podataka mogao koristiti u modelima i kako bi se odstranili uzorci koji nisu pogodni za obučavanje. U slučaju supa podataka za treniranje, kategorička obeležja *very negative* i *very positive* su prebačena kao *positive* i kao *negative*, što je odrđeno radi smanjenja kompleksnosti modela. Svim tвитovima su izbačeni simboli *hashtag*-a što je simbol @, dok je sama njegova vrednost ostavljena u tвитu. Izbačeni su svi linkovi koji sadrže https ili http prefiks. Emodži ikonice su prvo razdvojene razmakom kako bi se zatim pretvorile u svoje semantičko značenje korišćenjem biblioteke *emoji*. Izbačeni su svi znaci interpunkcije kao što su “.”, “,”, “?”, “!” i druge slične znakove. Nakon toga, izbačeni su specijalni znakovi koji ne pripadaju latiničnim slovima. Na samom kraju svi karakteri su prebačeni u mala slova latince kako se reči sa istim semantičkim značenjem ne bi razlikovale u modelu.

Posle obrade podataka koji je prvobitno bio u tekstualnom obliku, izvršava se tokenizacija teksta kako bi se reči unutar teksta normalizovale. Između procesa uzimanja osnove leksikografske forme (lemitizacije) i oduzimanje sufiksa (stematicizacije), odbrana je lemtizacije zbog toga što je poznatija po davanju boljih rezultata, uprkos tome što je sporija. Prilikom ovog procesa odbačene su zaustavne reči kao što su “the”, “is”, “as”, “to”, “a”, “that” i mnoge druge slične reči koje se često pojavljuju, a pri tome ne daju semantičko značenje.

Na kraju je za svaku reč određena njena vrsta reči i ostavljene su samo one koje su pridevi, imenice, glagoli i prilozi. Urađene su obe vrste ranije spomenutih tokenizacija; *TFIDF* i *BERT*. Za dužinu *TFIDF* vektora dobijena je vrednost 126575. *BERT* reprezentacije podataka dobijene su korišćenjem *DestilBert* prethodno obučenog modela, dok su podaci pripremljeni za model korišćenjem *DistilBertTokenizer*.

Preuzet je prvi vektor poslednjeg skrivenog stanja, koji predstavlja reprezentaciju CLS tokena dužine 73.

### 2.2. Skup podataka

Na Preuzet je označeni skup engleskih tвитова i prikupljen skup srpskih tвитova koji su prevedeni na engleski jezik. Označeni skup engleskih tвитova korišćen je za treniranje i optimizaciju modela nadgledanog učenja.

Stratifikovanom podelom 0.7 podataka je izdvojeno za obučavanje, a 0.3 za validaciju i optimizaciju modela. Nasumičan deo srpskih tвитova ručno je označen i predstavlja test skup podataka. Srpski tвитovi su odabrani nasumično kroz vreme zato što je primećeno da su određeni događaji uticali da se javi velika količina tвитova sa istim sentimentom u tom vremenskom periodu, npr. vest o otvaranju fabrika za proizvodnju vakcina povukla je veliki broj pozitivnih tвитova u tom vremenskom periodu. Na ručno označenim srpskim tвитovima, nakon što su prevedeni na engleski, biće testirani optimizovani modeli, kao i nenadgledani pristupi za određivanje sentimenta. Podaci na kojima se vrši obuka modela nadgledanog učenja su preuzeti u CSV formatu sa *openICPRs* repozitorijuma javno dostupnih podataka o društvenim, bihevioralnim i zdravstvenim istraživanjima.

Set podataka “*COVID-19 Twitter Dataset with Latent Topics, Sentiments and Emotions Attributes*” formiran je sa ciljem istraživanja javnih konverzacija na Triteru na temu pandemije COVID-19 virusa [4].

Set podataka sadrži preko 198 miliona Triter objava na engleskom jeziku prikupljenih u periodu od 28. januara 2020. do 1. septembra 2021. koristeći ključne reči “corona”, “wuhan”, “nCov” i “covid”. Podaci su označeni korišćenjem CrystalFeel [5], kolekcije pet unapred obučenih algoritama mašinskog učenja za ekstrakciju sentimenta i ocenu emocije, koji su trenirani na manuelno označenim tвитovima. Za potrebe projekta, preuzeti su CSV fajlovi sa tвитovima sa teritorija sa engleskim kao govornim jezikom, Australije i Velike Britanije. Najpre je prikupljeno 149186 australijskih tвитova (87819 negativnih, 37033 pozitivnih, 24334 neutralnih), a zatim je set podataka proširen tвитovima iz Velike Britanije kojih ima 477410 tвитova (148443 negativnih, 163884 pozitivnih, 165083 neutralnih).

Konačan balansiran skup podataka cini 420000 tвитова, pri čemu nije uključen celokupan skup za obučavanje zbog ograničenih resursa. Svaki tвит u setu podataka označen je sa sedamnaest semantičkih atributa, ali pošto je obim ovog projekta ograničen na detekciju sentimenta i ne uključuje detekciju konkretnih emocija, za potrebe obučavanja modela korišćen je samo kvalitativni atribut koji ukazuje na kategoriju sentimenta (*very negative*, *negative*, *neutral or mixed*, *positive*, *very positive*). Takođe, model je obučavan da detektuje sentiment samo na teksta objave, odnosno nije obučavan na atributima koji sadrže informaciju o korisniku, njegovoj lokaciji, vremenu postavljanja tвитa i interakcijama (broj retvitova, lajkova). Preuzeti skup podataka sadrži jedinstven ID tвитa na osnovu kog je korišćenjem Triter API-ja dobavljen tekst tвитa. Modeli su trenirani da prepozna kategoriju, ali ne i intenzitet sentimenta, pa su tвитovi označeni sa *very positive* i *very negative* prilikom pripreme podataka

za treniranje modela označeni kao *positive* i *negative*, respektivno.

Cilj projekta jeste analiza sentimenta srpskih twitova, pa priprema podataka uključuje prikupljanje Twiter objava o vakcinama na srpskom jeziku. Twitovi su prikupljeni korišćenjem Twiter API-ja koristeći *academic research* pristup, koji omogućava pristup istorijski javnim podacima uz dodatne funkcionalnosti koje podržavaju prikupljanje preciznijih i potpunijih skupova podataka [6]. Prikupljeni su twitovi na srpskom jeziku postavljeni u periodu od 31. januara 2021. do 31. januara 2022. godine, koristeći kombinaciju svih morfoloških oblika ključnih reči vakcina, vakcinisati i kovid, na cirilici i latinici.

Zbog ograničenja dužine upita koji se prosleđuje Twiter API-ju inicijalni upit koji sadrži kombinacije svih morfoloških oblika ključnih reči izdelen je na četiri kraća upita. Konačan skup podataka dobijen je spajanjem prikupljenih podataka različitih upita, pri čemu je vođeno računa da se jedna objava prikupi samo jedanput. Izostavljeni su twitovi koji *repost-uju* originalnu objavu (*retweets, quotes*), kao i twitovi koji predstavljaju *reply*, nakon sto je analizom utvrđeno da su ovi twitovi često kratkog teksta i da je njihov sentiment zavistan od konteksta samog twita na koji odgovaraju. Prikupljeno je 93435 twitova, koji su zatim prevedeni sa srpskog na engleski jezik korišćenjem *GOOGLETRANSLATE* koji je dostupan u *google sheets* aplikaciji u kojoj su podaci čuvani. Nasumičnim izborom izdvojeno je 6000 twitova koji su manuelno anotirani sistemom trostrukog glasanja – svakom twitu su dve osobe nezavisno davale ocenu sentimenta i u slučaju neslaganja je treća osoba dodeljivala konačnu ocenu sentimenta.

### 2.3. Sentiment analiza i analiza tema

U ovom poglavљу su grupisani modeli svih klasifikacionih sistema za dobijanje sentimenta. Ulaz u sistem su engleski twitovi koji su korišteni kao skup podataka za obučavanje. Skup podataka koji je zasnovan na srpskim twitovima se koristi za validaciju modela istreniranih na obučavajućem engleskom skupu podataka. Sakupljen skup podataka se prevodi na engleski jezik gde se dalje preprocesira na isti način na koje se preprocesiraju twitovi koji su sačinjeni od engleskog skupa podataka. Izvršava se tokenizacija korišćenjem *TF-IDF* i *BERT* modela. Svaki od ovih modela su istrenirani na modelima mašinskog učenja: naivni Bajes, metod nasumične šume, višeslojne neuronske mreže i mašine na bazi vektora nosača. Kod nadgledane sentiment analize, izlaz je isti kao kod nadgledane analize, sa tim da kod nadgledane analize nema skupa podataka koji je sačinjen od engleskih twitova. Takođe na ulaz su dovedeni preobučeni modeli *TextBlob*, *Vader* i model leksičkih osobina. Ulaz za analizu tema čini skup podataka sačinjen od srpskih twitova, dok je izlaz sačinjen od tema, koje će biti dobijene metodom lakta i izlaz će biti obučeni klasifikacioni model. Sama analiza tema će biti urađena sa dva moguća pristupa: *LDA* i *NMF*.

### 2.4. Rezultati

Konvolucione neuronske mreže su se pokazale kao tačniji i najprecizniji model za dobijanje sentimenta twita vrednosti tačnosti od 52.3% sa TF-IDF teoknizatorom i 50,7% sa BERT tokenizatorom. Vrednosti tačnosti mo-

dela naivnog Bajesa, nasumične šume, višeslojne neuronske mreže i konvolucione neuronske mreže su prikazani u tabeli 1, gde su sve vrednosti kolona vrste tokenizatora. U tabli 2 su zadate vrednosti tačnosti i preciznosti TextBlob-a i leksičke analize osobina. Za nenedgledano obučavanje, najbolje se pokazao model leksičke analize osobina (Afinn) koji je ostvario tačnost od 39,4% i preciznost od 44%. U tabeli 3 dati su rezultati metrika konvolucione neuronske mreže obučene sa BERT tokenima. Na osnovu visoke preciznosti za klasu neutralnih sentimenata, može da se zaključi da model generalno predviđa više predikcija za neutralnu klasu. Najveći odziv je ostvarila negativna klasa sa vrednosti od 65.7%, dok je za vrednost F-mere klasa neutralnih sentimenata ostvarila najbolju vrednost koja je 61,7%

Tabela 1. Tačnost za svaki nadgledani klasifikacioni model upotrebom TFIDF i LDA tokenizatora

	Tačnost modela upotrebom TF-IDF	Tačnost modela upotrebom BERT
Mašine na bazi vektora nosača	0.346	0.346
Naivni Bajes	0.333	0.333
Nasumične šume	0.447	0.485
Višeslojne neuronske mreže	0.448	0.587
Konvolucione neuronske mreže	0.523	0.597

Tabela 2. Vrednost tačnosti i preciznosti za modele TextBlob, Vader i leksičke analize

	Tačnost	Preciznost
TextBlob	0.376	0.380
Vader	0.371	0.374
Afinn	0.395	0.440

Tabela 3. Vrednost preciznosti, odziva i F-mere za svaki sentiment dobijen upotrebom modela konvolucione neuronske mreže

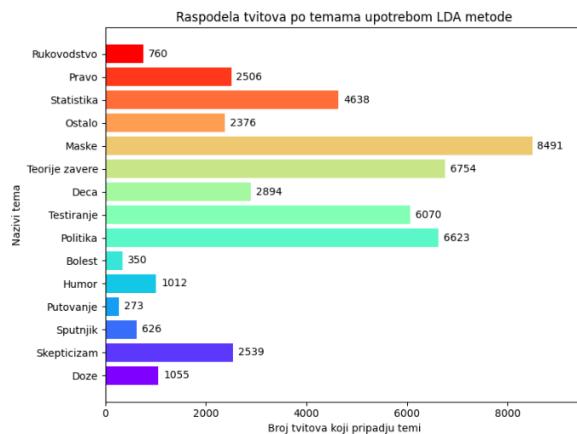
	Preciznost	Odziv	F-mera
Negativni sentiment	0.553	0.657	0.601
Neutralni sentiment	0.692	0.558	0.617
Pozitivni sentiment	0.544	0.607	0.574
Prosek	0.596	0.607	0.597

U radu [7] dobijeni su rezultati sa većom tačnosti i sa većom preciznosti. Razlog je u tome što su radili

detaljnije filtriranje relevantnih tвитова i što su kombinovali pristupe tokenizacije. Primenom modela dobijeni rezultati ukazuju da je 38% pozitivnih, 37% negativnih i 25% neutralnih srpskih tвитova.

Za dobijanje tema, odabiran je model *LDA* nad *TF-IDF* tвитovima, koji je imao najveći skor koherencije u odnosu na druge modele.

Odabran je model koji ima petnaest tema. Dobijene su reči svake teme modela i zatim su imenovane od strane male grupe ljudi. Teme su: doze, politika, putovanje, sputnjik, humor, bolest, skepticizam, testiranje, deca, teorije zavere, maske, ostalo, statistika, pravo i rukovodstvo.



Slika 1. Raspodela tвитова po temama upotrebom LDA metode nad celokupnim skupom podataka srpskih tвитova.

### 3. ZAKLJUČAK

Ovaj rad se bavio problemom analize Tвiter podataka vezanih na temu COVID-19 vakcinaciju. Analiza je bila usmerena na dobijanje sentimeta pojedinačnih tвитова kao i grupisanje tвитova po leksičkom značenju i pridodavanje značenja grupama. Rezultati ovakve analize bi mogli biti iskorišćeni u zdravstvu kao mera mišljenja javnog mnjenja. Uz dodatnu analizu nadležni bi mogli imati dublji uvid u formiranje i praćenje stavova ljudi na društvenoj mreži Tвiter. Za ovu analizu prikupljeni su tвитovi koji su sadržali ključne reči vezane za vakcinaciju u periodu od 31. Januara 2021. Go 21. Januara 2022. godine. Isprobana su dva pristupa mašinskog učenja za dobijanje sentimeta.

Jedan pristup je vezan za nadgledano, gde su se obučavali modeli na skupu engleskih tвитова i zatim primenjivali na srpske tвитove, dok drugi pristup vezan nenadgledano učenje uz upotrebu semantičke analize pojedinačnih tвитova.

Za dobijanje sentimenata najbolje rezultate ostvario je konvolucionna neuronska mreža sa tačnosti od 0,597 i sa preciznosti od 0,596. Za dobijanje tema, korišćena su dva modela, NMF i LDA. Krajnja analiza tema je izvršena sa modelom LDA koja je ostvarila koherentnost modela od 0,44. Tвитovi su podeljeni u 15 tema i svaka tema je imenovana zasebno.

Dobijene grupe su: doze, politika, putovanje, humor, bolest, testiranje, skepticizam, deca, maske, statistika, pravo, rukovodstvo, teorija zavere, sputnjik i ostalo. Potencijalni pravci za dalji rad na ovu temu bi bili: proširenje skupa podataka, filtriranje skupa podataka, predprocesiranje, detekcija sarkazma i odabir modela.

### 4. LITERATURA

- [1] <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/covid-19-vaccines> (pogledano 3. 10. 2023.)
- [2] <https://covid19.trackvaccines.org/agency/who/> (pogledano 15. 4. 2022.)
- [3] <https://www.srbija.gov.rs/vest/en/166398/mass-vaccination-in-serbia-starts-today.php> (pogledano 15. 4. 2022.)
- [4] Raj Kumar Gupta, Ajay Vishwanath i Yinping Yang. "COVID-19 Twitter Dataset with Latent Topics, Sentiments and Emotions Attributes". CoRR abs/2007.06954 (2020.)
- [5] CrystalFeel. Multidimensional Emotion Intensity Analysis from Natural Language. Institute of High Performance Computing, A\*STAR. URL: <https://socialanalyticsplus.net/crystalfeel> (pogledano 30. 8. 2022.)
- [6] <https://developer.twitter.com/en/products/twitter-api/academic-research> (pogledano 15. 4. 2022.).
- [7] Alaa Khudhair Abbas i dr. "Twitter sentiment analysis using an ensemble majority vote classifier". en. Xi'an Jiaotong Daxue xuebao

### Kratka biografija:



**Filip Zdelar** rođen je u Sremskoj Mitrovici 1998. god. Filip Zdelar rođen je 23. novembra 1998. godine u Sremskoj Mitrovici, Republika Srbija. Osnovnu školu pohadao je u selu Šašinci, dok je srednju školu završio u Novom Sadu, gde je bio član odeljenja za darovite matematičare. Tokom školovanja isticao se na takmičenjima iz matematike, fizike i programiranja, plasirajući se na republičkom nivou. Godine 2017. upisao je Fakultet tehničkih nauka na Univerzitetu u Novom Sadu, sa smerom informacionog inženjeringu. Filip je takođe dobitnik Dositejeve nagrade. Na fakultetu je postigao izuzetne rezultate i diplomirao je sa prosekom ocena od 9,67. Master rad na Fakultetu tehničkih nauka iz oblasti Elektrotehnike i računarstva Inteligentni sistemi odbranio je 2023.god. kontakt: filipzdelar@gmail.com