



Laboratorij za analizu teksta i inženjerstvo znanja

Text Analysis and Knowledge Engineering Lab

Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva

Unska 3, 10000 Zagreb, Hrvatska



Zaštićeno licencijom

Creative Commons Imenovanje-Nekomercijalno-Bez prerada 3.0 Hrvatska

<https://creativecommons.org/licenses/by-nc-nd/3.0/hr/>

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 1532

**Modeli dubokog učenja za analizu
korisničkih komentara na
društvenim mrežama**

Tomislav Marinković

Zagreb, srpanj 2017.

Zagreb, 3. ožujka 2017.

Predmet: **Analiza i pretraživanje teksta**

DIPLOMSKI ZADATAK br. 1532

Pristupnik: **Tomislav Marinković (0036458968)**

Studij: Računarstvo

Profil: Računarska znanost

Zadatak: **Modeli dubokog učenja za analizu korisničkih komentara na društvenim mrežama**

Opis zadatka:

Analiza mišljenja korisnika proizvoda i usluga od presudne je važnosti za svaku tvrtku. Velik dio komunikacije tvrtke s korisnicima, koja se prije odvijala tradicionalnim kanalima korisničke podrške, danas se odvija na društvenim mrežama. Društvene se mreže odlikuju brzinom, interaktivnošću, visokim obimom, dostupnošću, ali i neformalnošću i izravnošću komunikacije. Kao takve, neprocjenjiv su izvor podataka za automatsku analizu mišljenja korisnika metodama strojnog učenja.

U okviru diplomskoga rada potrebno je proučiti modele dubokog učenja za klasifikaciju teksta, s naglaskom na modele temeljene na povratnim neuronskim mrežama i višezadačne modele. Oblikovati model dubokog učenja za analizu korisničkih komentara koji će se temeljiti na združenoj klasifikaciji nekoliko aspekata korisničkih komentara, uključivo sentimenta, emocija, govornog čina i teme razgovora, te koji će u obzir uzimati slijed rasprave. Razviti model u radnome okviru Tensorflow te ispitati rad modela na dostupnome skupu podataka korisničkih komentara na hrvatskome jeziku sa stranica telekom-operatera na Facebooku. Provesti detaljno eksperimentalno vrednovanje modela, uključivo analizu pogrešaka i statističku analizu rezultata. Radu priložiti izvorni i izvršni kod razvijenog sustava, skupove podataka i programsku dokumentaciju te citirati korištenu literaturu.

Zadatak uručen pristupniku: 10. ožujka 2017.

Rok za predaju rada: 29. lipnja 2017.

Mentor:

Predsjednik odbora za
diplomski rad profila:

Izv. prof. dr. sc. Jan Šnajder

Djelovođa:

Prof. dr. sc. Siniša Srblić

Doc. dr. sc. Tomislav Hrkać

SADRŽAJ

1. Uvod	1
2. Duboko učenje za klasifikaciju teksta	3
2.1. Potpuno povezane unaprijedne neuronske mreže	4
2.2. Konvolucijske neuronske mreže	7
2.3. Povratne neuronske mreže	9
2.3.1. Obične povratne neuronske mreže	11
2.3.2. Povratne neuronske mreže <i>LSTM</i>	12
2.3.3. Povratne neuronske mreže <i>GRU</i>	12
2.3.4. Bidirekionalne povratne neuronske mreže	13
2.4. <i>Word2vec</i>	13
3. Podaci i zadatak	14
3.1. <i>Dataset</i>	18
4. Model	21
4.1. Združeno učenje	24
4.2. Stroj s potpornim vektorima (SVM)	25
4.3. Osnovni duboki model	25
4.4. Poboľjšani osnovni duboki model	26
4.5. Model za sentiment	27
4.6. Model združenog učenja	27
4.7. Varijacije modela	27
4.8. Izgrađeni model	28
5. Eksperimenti	29
5.1. <i>SVM</i>	30
5.2. Osnovni modeli	30
5.3. Modeli združenog učenja	31

5.3.1.	Združeno učenja s više prolaza kroz ulazne podatke za svaku pojedinu ciljnu oznaku	31
5.3.2.	Združeno učenje s jednim prolazom kroz ulazne podatke . . .	35
5.3.3.	Združeno učenje s jednim prolazom kroz ulazne podatke i kratkim lancima ulaznih podataka	38
5.4.	Rezultati	39
6.	Zaključak	40
7.	Popis slika	42
	Literatura	43

1. Uvod

U zadnjih 10 godina svjedočimo velikom napretku tehnologije i načinu komuniciranja, kako između pojedinaca, tako i između poduzeća i klijenata. Prije razvoja društvenih mreža, komunikacija između poduzeća i klijenata se vršila osobno, uživo ili preko pisma i elektroničke pošte. Pisma se naravno ne mogu nikako iskoristiti za analizu, kako nisu u elektroničkom obliku, ali elektronička pošta ima potencijala za analizu. Međutim, elektronička pošta se ne šalje u dovoljno velikom obujmu kako bi se mogla iskoristiti za analizu, a i nije javno dostupna. Također, mada je slanje i primanje praktički trenutačno, elektronička pošta ostavlja dojam spore komunikacije, jer ne možemo komunicirati uživo.

Pojavom društvenih mreža sve se mijenja. Na samom početku društvenih mreža, korisnici su bili fizičke osobe, međutim vrlo brzo su poduzeća primijetila prednosti masovne komunikacije s klijentima. Također, za razliku od elektroničke pošte, nije potrebno pamtiti adresu, već se poduzeće vrlo lagano pronade po imenu, što je omogućilo da ljudi s manje informatičkog znanja mogu sudjelovati u komunikaciji preko društvenih mreža. Također, komunikacije se može odvijati "uživo", što znači da sudionici konverzacije imaju informaciju je li sugovornik ovdje i sudjeluje li u dijalogu. Vrlo velik broj fizičkih osoba, a i poduzeća trenutno ima profil na društvenoj mreži. Jedna od najvećih je *Facebook*. Komunikacija s poduzećem na *Facebooku* je vrlo jednostavna. Korisnik se prijavi na stranici, u tražilicu upiše ime poduzeća, i može ostaviti svoj komentar koji je javno vidljiv ili može pokrenuti privatni razgovor uživo s odabranim poduzećem. Na objavljeni komentar, drugi korisnici i poduzeće mogu također ostavljati svoje komentare ili odgovore na tuđi komentar. Vrlo brzo takva komunikacije je prerasla kapacitete poduzeća za ručnom analizom ostavljenih komentara i razgovora. U većini slučajeva na komentare se odgovori trenutačno nakon objave i više se ne obazire pažnja na njih, što je zapravo šteta jer se puno informacija o zadovoljstvu korisnika može iščitati iz ostavljenih komentara.

Razvoj tehnologije nije zahvatio samo grane komunikacije, već i strojnog učenja i umjetne inteligencije. Spajanjem tehnika umjetne inteligencije s načinom i količinom

komunikacije preko društvenih mreža omogućava nam automatiziranu analizu korisnika i njihovih stavova, pohvala i žalbi. Odjednom količina komentara nije problem, već je poželjno imati što više komentara kako bi algoritam strojnog učenja što bolje „naučio“ kako analizirati komentare.

U okviru ovog diplomskog rada fokus je na tehnikama dubokog učenja, koji se odlikuje načinom rada " od kraja do kraja" (eng. end-to-end). To znači da nije potrebno ručno izlučivanje značajki iz teksta koje se kasnije koriste kao značajke modela, već je samo potrebno odrediti ulaz i izlaz modela, a unutarnje ponašanje je prepušteno algoritmu koji je određen prije pokretanja učenja modela. Također, kako su ulazni podaci zapravo razgovor između korisnika i poduzeća očekivano je da trenutni komentar ovisi o toku razgovora, odnosno o prijašnjem komentaru. Upravo za takav problem koriste se povratne neuronske mreže koje modeliraju vremensku ovisnost ulaznih podataka. Zadatak projekta je klasifikacija teksta kroz četiri značajke: sentiment, emocije, tema komentara te govorni čin. Svaki od te četiri značajke ima određeni broj klasa, o kojima će se detaljno raspraviti u daljnjem tekstu. Nakon klasifikacije teksta, rezultati se mogu pohraniti u bazu i vrlo jednostavnom analizom se mogu pratiti trendovi razmišljanja korisnika, što je od presudne važnosti za svako poduzeće.

Rad je organiziran na sljedeći način. Na početku je dan pregled algoritama za duboko učenje za klasifikaciju teksta. Nabrojani su i objašnjeni neki od najpopularnijih algoritama dubokog učenja. Poglavlje broj 3 daje pregled dostupnih podataka te problema kojeg treba riješiti. Model koji je razvijen je detaljno objašnjen u poglavlju broj 4. U poglavlju broj 5 dani su rezultati eksperimenata i diskusija istih. Na kraju rada pod poglavljem broj 6 dan je zaključak.

2. Duboko učenje za klasifikaciju teksta

Duboko učenje za klasifikaciju teksta je dobilo zamaha u zadnjih nekoliko godina, sa krajnjim ciljem izrade umjetne inteligencije koja bi mogla u potpunosti razumjeti prirodni jezik.

Obrada prirodnog jezika je područje koje istražuje kako računala mogu biti iskorištena da razumiju i manipuliraju tekstem. Istraživači obrade prirodnog jezika imaju za cilj skupiti znanje kako ljudi koriste jezik kako bi mogli razviti odgovarajuće alate i tehnike kako bi računalo moglo razumjeti prirodni jezik.

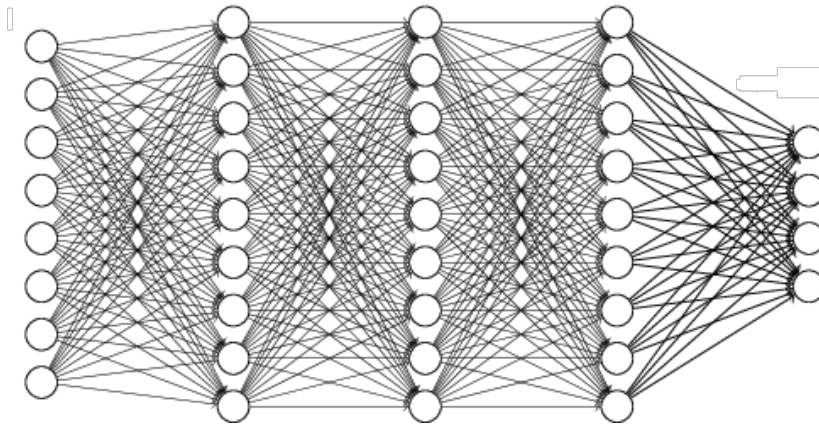
Algoritme dubokog učenja možemo podijeliti u tri skupine:

- Potpuno povezane unaprijedne neuronske mreže,
- Konvolucijske neuronske mreže,
- Povratne neuronske mreže.

U nastavku poglavlja dan je pregled sva tri gore navedena algoritma dubokog učenja.

2.1. Potpuno povezane unaprijedne neuronske mreže

Potpuno povezane unaprijedne neuronske mreže, također poznate pod nazivom višeslojni perceptron, za cilj imaju aproksimaciju funkcije. Nazivaju se unaprijedne neuronske mreže jer informacija „struji“ od ulaza prema izlazu bez ikakvih povratnih petlji, što je slučaj s nekim drugim vrstama neuronskih mreža. Svaki neuron jednog sloja je povezan sa svim neuronima susjednog sloja, kao što možemo vidjeti na slici 2.1.1. Sama arhitektura mreže ima nekoliko parametara. Dubina mreže, često označavana sa L nam govori koliko slojeva imamo u mreži, a širina l , govori nam koliko neurona ima u sloju. Što su parametri L i l veći, to mreža može riješiti kompleksnije probleme, ali uz rizik od prenaučivosti.



Slika 2.1.1 Potpuno povezana unaprijedna neuronska mreža, preuzeto od [1]

Postoje linearni i nelinearni modeli. Linearni model : $f(\mathbf{w}, b) = \mathbf{w}^T x + b$ je najjednostavniji model i ima problem što realni problemi koje neuronska mreža treba razriješiti često nisu linearni po prirodi.

Rješenje ovog problema dobiva se uvođenjem nelinearne funkcije koja preslikava originalne značajke \mathbf{x} u drugi prostor u kojem klasifikaciju obavljamo linearnim modelom. Takva funkcija naziva se aktivacijska funkcija : $f(\mathbf{w}, b) = \Phi(x)^T \mathbf{w} + b$. Uobičajeno se danas koristi kao nelinernost:

$$g(x) = ReLU(x) = \max(0, x)$$

Prednosti su što u aktivnom stanju propušta signal unaprijed i gradijent unatrag. Nedostatak je što za $x = 0$, gradijent funkcije nije definiran, međutim to zapravo i nije velik problem. Mreže ionako ne treniramo do minimuma, a u implementaciji se jednostavno definira gradijent da bude jednak ili gradijentu slijeva (0) ili gradijentu sdesna (1). Također, nedostatak je što u neaktivnom stanju ne propušta signal unaprijed i gradijent unazad, međutim ulaz se može kondicionirati da srednja vrijednost bude 0 i varijanca 1, pa je vjerojatnost da je značajka u aktivnom stanju 0.5. Također, postoji generalizacija:

$$g(x, \alpha) = \max(0, x) + \alpha \min(0, x)$$

Postoje i druge aktivacijske funkcije koje se ponekad koriste:

- Sigmoida: $\sigma(x) = (1 + e^{-x})^{-1}$ ne propušta gradijent unatrag (učenje prestaje) kada uđe u zasićenje. (Problem nestajućeg gradijenta),
- Tangens hiberbolni: $\tanh(x) = \frac{e^{2x}-1}{e^{2x}+1}$ obično se ponaša bolje od sigmoide budući da sliči identitetu u dijelu oko $x = 0$, što osigurava jednostavan transfer gradijenta unatrag.

Općenito, bilo koja monotono rastuća funkcija je u uredu, ali ove tri su se u praksi pokazale najboljima. Učenje mreže se zapravo svodi na pronalazak parametara mreže za koje je definirana funkcija gubitaka najmanja. Postoji nekoliko popularnih funkcija gubitaka:

- 0-1 gubitak

$$l_{01}(\mathbf{y}, \hat{\mathbf{y}}) = \begin{cases} 0, & \text{ako } \mathbf{y} = \hat{\mathbf{y}}, \\ 1, & \text{inače.} \end{cases}$$

- Srednja kvadratna pogreška

$$l_{MSE}(y, \sigma(z)) = (y - \sigma(z))^2$$

- Negativna log-izglednost

$l_{MLE}(\mathbf{Y}, \hat{\mathbf{Y}}) = -\sum \log p(\hat{\mathbf{y}}_i = \mathbf{y}_i | f(\mathbf{x}, \Theta))$ – funkcija gubitka dobiva se ako pretpostavimo da imamo distribuciju vjerojatnosti izlaza modela.

Prednost negativne log izglednosti je općenitost: nema potrebe dizajnirati funkcije gubitaka specifične za svaki pojedini model. Također prednost negativne log izglednosti naspram srednje kvadratne pogreške je problem zasićenja. Ako pogledamo gradijent funkcije gubitka s obzirom na značajke u zadnjem sloju mreže:

$$\frac{\partial l_{MSE}(y, \sigma(z))}{\partial z} = 2(y - \sigma(z))(1 - \sigma(z))\sigma(z)$$

vidimo da kada je sigmoida u zasićenju, gradijent funkcije gubitaka je jako malen, pa stoga mreža ne može naučiti iz takvog primjera.

Učenje se vrši izračunom gradijenta prosljeđivanjem greške unazad. Prvi korak kod učenje mreže je prolaz unaprijed, te zatim računanje gradijenta funkcije gubitka s obzirom na parametre mreže. Prosljeđivanje greške unatrag je jednostavan i računski nezahitjevan način računanja gradijenta kompozicije funkcija. Računa se pravilom ulančavanja. To je recept za deriviranje kompozicije funkcija za koje su derivacije poznate. Na primjer: $y = g(x), z = f(y) = f(g(x))$

$$\frac{dz}{dx} = \frac{dz}{dy} \frac{dy}{dx} = \frac{df(y)}{dy} \frac{dg(x)}{dx}$$

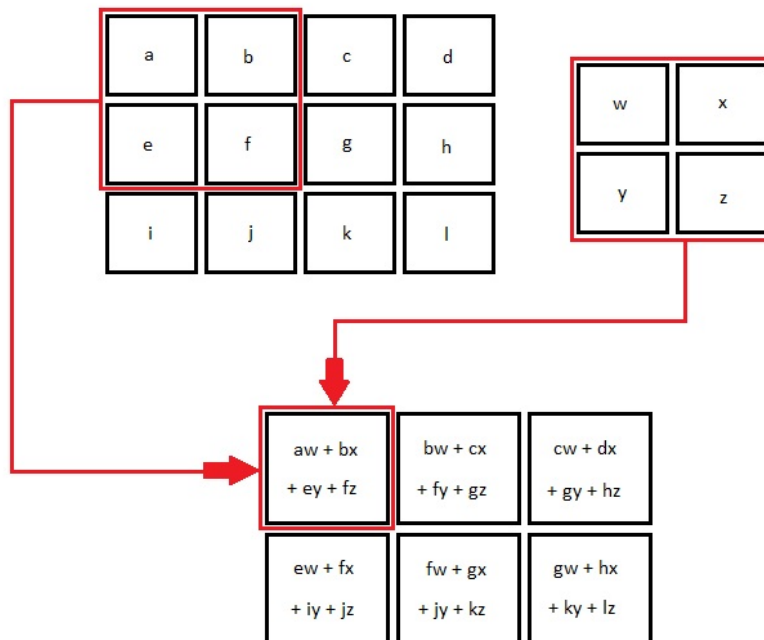
Kako bi izbjegli pojavu prenaučenosti mreže, uvodi se sloj odbacivanja neurona. Postavlja se vjerojatnost zadržavanja neurona, i u svakom prolazu kroz mrežu, sa tom vjerojatnošću će neuron sudjelovati u propagaciji. Ako ne sudjeluje, njegov izlaz je nula. Ovakvim načinom regularizacije mreže sprječavamo zajedničko učenje neurona, već svaki neuron mora što samostalnije odrađivati svoj posao. U praksi se pokazuju malo bolji rezultati nego bez sloja odbacivanje neurona.

2.2. Konvolucijske neuronske mreže

Konvolucijske neuronske mreže su specijalizirani tip mreža s topologijom rešetke. Konvolucijska neuronska mreža je mreža koja koristi najmanje jedan konvolucijski sloj umjesto potpuno povezanog sloja. Neki od tipičnih ulaza su: vremenski sljedovi i slike. Konvolucija je operacija definirana nad dvije funkcije realne varijable:

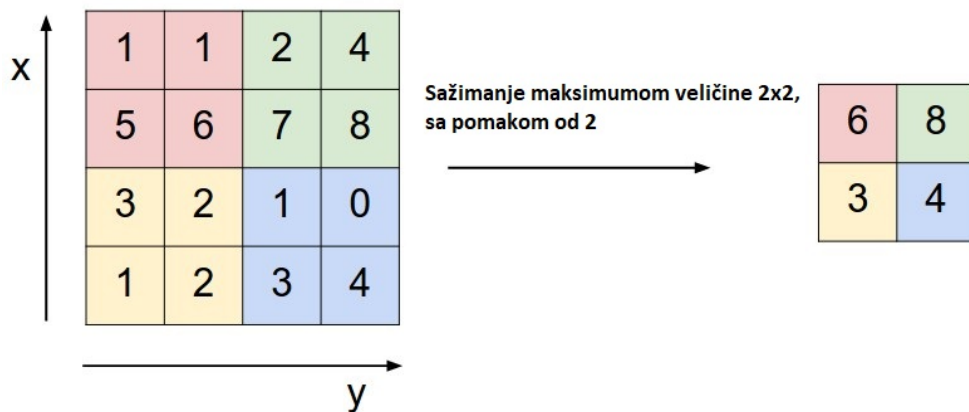
$$s(t) = \int_{-\infty}^{\infty} x(a)w(t - a)da$$

Računski primjer dan je na slici 2.2.1.



Slika 2.2.1 Konvolucija – računski prikaz konvolucije. Matrica a - l je prikaz ulaznih podataka, a matrica w - z je filter. Vidljivo je kako filter djeluje samo na dio ulaznih podataka, što modelira lokalne interackije, preuzeto od [2]

Konvolucija je slična potpuno povezanom sloju, samo što modelira lokalne interakcije. Kod potpuno povezanog sloja, svaki izlaz je povezan sa svim ulazima, a kod konvolucije samo s malim dijelom ulaza, što rezultira s puno manje parametara mreže. Nakon konvolucijskom sloja obično dolazi sloj sažimanja, koji preslikava skup prostorno bliskih značajki na ulazu u jednu značajku na izlazu. Funkcije koje se obično koriste su srednja vrijednost ili maksimalna vrijednost, kao što možemo vidjeti na slici 2.2.2.

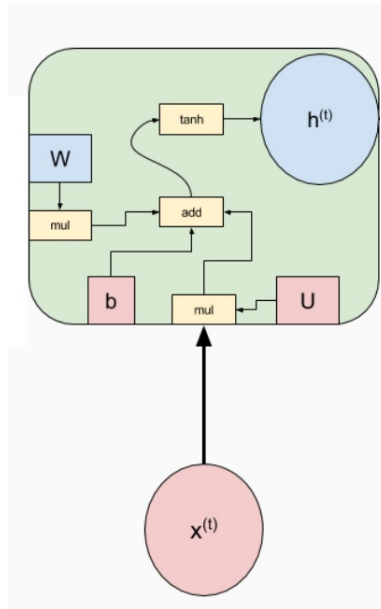


Slika 2.2.2 Sažimanje, preuzeto od [3]

Sažimanje se koristi zbog povećanja invarijantnosti na pomak. To nam je posebno važno ako pretpostavimo da nam je bitnije detektirati prisutnost određene značajke nego njezinu točnu lokaciju. Sažimanje nam također omogućava procesiranje ulaza različitih veličina (na primjer slike različite veličine). Još jedan bitan korak u konvolucijskim neuronskim mrežama je nadopuna (eng. padding). Bez nadopune reprezentacija podataka se smanjuje s dubinom modela. Za ulaz veličine m izlaz nakon nadopune je $m - k + 1$, gdje je k veličina jezgre. Nadopuna nulama na rubovima omogućava neograničenu dubinu mreže. Nedostatak nadopune je taj što rubovi ulaznih podataka manje utječu na izlaz nego elementi na sredini.

2.3. Povratne neuronske mreže

Operacije koje radimo u svakom koraku možemo izolirati u ćeliju, koju u ovom slučaju zovemo povratnom ćelijom, koja je prikazana na slici 2.3.1.



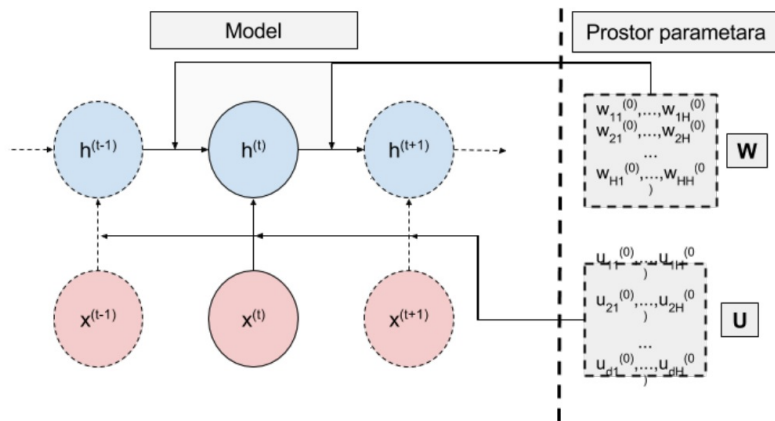
Slika 2.3.1 Povratna ćelija, preuzeto od [4]

Povratnu ćeliju možemo interpretirati kao jedan sloj neuronske mreže kojoj je prijenosna funkcija tangens hiperbolni. Vrijeme u povratnim neuronskim mrežama označava redoslijed kojim se podaci šalju na ulaz. Glavna ideja povratnih neuronskim mreža je dijeljenje parametara kao što je vidljivo na slici 2.3.2.

Za razliku od potpuno povezane unaprijedne neuronske mreže gdje je svaki neuron imao svoju težinu, u povratnim neuronskim mrežama koristimo istu matricu težina za svaki neuron. Također koristimo malo drugačiju vrstu neurona.

Svaki neuron u svakom koraku prima dva ulaza: vektor prethodnog stanja pomnožen s matricom W , te vektor novog ulaza pomnoženog s matricom U , što je vidljivo na slici 2.3.2.

$$\mathbf{h}^{(t)} = f(\mathbf{W}\mathbf{h}^{(t-1)} + \mathbf{U}\mathbf{x}^{(t)} + \mathbf{b})$$



Slika 2.3.2 Odgovarajuće matrice povratne ćelije, preuzeto od [5]

Pri računanju izlaza povratne neuronske mreže također uvodimo težinsku matricu V , te vektor pristranosti c :

$$\mathbf{o}^{(t)} = \mathbf{V}\mathbf{h}^{(t)} + \mathbf{c}$$

Hiperparametri u povratnoj neuronskoj mreži su veličina skrivenog sloja H , koja određuje kolika je reprezentativna moć mreže. Pravilo je: što je veći H , to bolje. Naravno, problem je ako je veličina skrivenog sloja veća od dimenzionalnosti podataka, te mreža počinje pamtili ulazne podatke. Međutim u praksi, ograničenje je količina dostupne memorije. Broj vremenskih koraka odmatanje mreže T je uvjetovan podacima, no u slučaju podatka varijabilne duljine možemo odrediti maksimalnu duljinu rečenice koju primamo. U tom slučaju podaci dulji od T se krate na duljinu T , a podaci kraći od T se nadopunjavaju na primjer nulama.

Povratne neuronske mreže imaju tri popularne implementacije:


- Obične povratne neuronske mreže,
- Povratne neuronske mreže *LSTM*,
- Povratne neuronske mreže *GRU*.

2.3.1. Obične povratne neuronske mreže

Obične povratne neuronske mreže su opisane u prethodnom poglavlju. To su neuronske mreže koje uzimaju u obzir vremenski slijed prema kojem ulazni podaci dolaze u mrežu i svaki sljedeći korak u izračunu ovisi o svim prijašnjim koracima izračuna.

Možemo reći da obične povratne neuronske mreže imaju "memoriju" koja zadržava informaciju što je do sada izračunato. U teoriji obične povratne neuronske mreže mogu koristiti bilo koliko dugačak slijed, ali u praksi su limitirane zapravo već s nekoliko koraka. Razlog tome leži u matematičkoj podlozi povratnih neuronskih mreža. Kod izračuna gradijenata kroz korake mreže, zapravo računamo potenciranje matrice, što znači da ako gradijenti po iznosu nisu vrlo blizu jedinice, u samo nekoliko koraka će nestati, ako su manji, ili naglo narasti ako su veći od jedan.

Problem koji se naziva *nestajući gradijent* (engl. *vanishing gradient*) kod običnih povratnih neuronskih mreža je što se gradijent teško vraća kroz vremenske korake mreže. Pojavu nestajućeg gradijenta možemo vidjeti na slici 2.3.1.1.

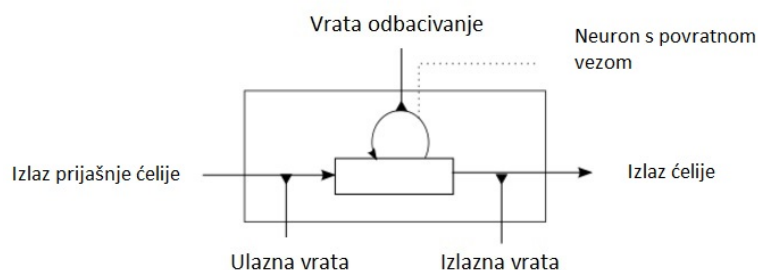


Slika 2.3.1.1 Nestajući gradijent: slika ilustrira gradijente kod obične povratne neuronske mreže i povratne neuronske mreže *LSTM*, gdje su točkice gradijenti, preuzeto od [6]

Problem nestajućih gradijenata se riješava uvođenjem povratne neuronske mreže *LSTM*.

2.3.2. Povratne neuronske mreže *LSTM*

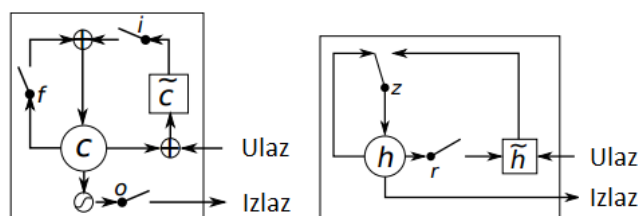
Povratna neuronska mreža *LSTM* uvodi novu strukturu, pod nazivom memorijska ćelija. Memorijska ćelija se sastoji od četiri glavna elementa: ulazna vrata, neuronom sa povratnom vezom na samog sebe, vrata za odbacivanje te izlazna vrata. Neuron sa povratnom vezom ima težinu veze 1 i osigurava da se stanje memorijske ćelije zapamti kroz korake. Vrata služe kako bi modulirala veze između memorije ćelije i okoline. Ulazna vrata određuju koliko ulazni podaci utječu na memoriju ćelije, dok vrata odbacivanja određuju koliko memorije treba odbaciti. Izlazna vrata određuju koliko će trenutno stanje memorije utjecati na sljedeće stanje. Ilustracija *LSTM* ćelije je na slici 2.3.2.1.



Slika 2.3.2.1 Povratna neuronska mreža *LSTM*, preuzeto od [7]

2.3.3. Povratne neuronske mreže *GRU*

Povratna neuronska mreža *GRU* je arhitekturom jako slična povratnoj neuronskoj mreži *LSTM*, jedino što neuronska mreža *GRU* nema memoriju kao *LSTM*. Ima dvoje vrata, umjesto troje kod *LSTM*a, te nema izlazna vrata nego reset vrata i ažuriraj vrata. Usporedba je dana na slici 2.3.3.1.



Slika 2.3.3.1 Usporedba *GRU* i *LSTM* povratnih neuronskih mreža, preuzeto od [8]

2.3.4. Bidirekcionalne povratne neuronske mreže

Bidirekcionalne povratne neuronske mreže su proširenje na povratne neuronske mreže nabrojane u ovom poglavlju. Za razliku od povratnih neuronskim mreža koje analiziraju ulazne podatke samo u $t + n$ koraka, gdje je t trenutni korak, a n broj slijedećih ulaznih podataka, bidirekcionalne povratne neuronske mreže također analiziraju i $t - m$ koraka, gdje je m broj prethodnih ulaznih podataka,

2.4. *Word2vec*

Podaci se tradicionalno prikazuju One-Hot vektorom, što znači da se svaka pojedina riječ u vokabularu pretvori u vektor veličine vokabulara gdje je pojedina riječ označena sa jedinicom, a svi ostali elementi su nula. To nas dovodi do slučaja gdje imamo jako dugačke vektore dužine veličine vokabulara popunjene svugdje nulom osim na mjestu gdje je određena riječ. Takva reprezentacija je valjana, međutim ima nekoliko problema. Prvi i najočitiiji je veliko zauzeće resursa za relativno malo informacija, a drugi je što nemamo nikakvo znanje o tekstu osim je li se riječ pojavila ili nije. Upravo zbog ovih problema, provodi se nisko dimenzionalno vektoriziranje riječi, gdje je svaka riječ predstavljena sa n riječi sličnog značaja. Takvim predstavljanjem riječi dobivamo puno više informacija nego s običnim One-Hot kodiranjem.

Model za treniranje je vrlo jednostavan. Treniramo jednostavnu unaprijednu neuronsku mrežu sa samo jednim skrivenim slojem. Trik je u tome, što ne koristimo izlaz mreže kao rezultat, nego težine u skrivenom sloju. Treniramo neuronsku mrežu da za danu riječ u sredini rečenice, uzme jednu riječ u blizini te riječi, najčešće do pet riječi udaljenosti. Mreža nam na izlazu daje vjerojatnost pojavljivanja te riječi u blizini odabrane riječi u cijelom vokabularu. Na kraju treniranja kao rezultat *word2vec* značajki, uzimamo redove skrivenog sloja, što predstavlja određenu riječ u vokabularu. Slične riječi u vokabularu će imati slične vektore u skrivenom stanju, čime smo efektivno dobili vektorski prostor gdje su slične riječi bliže jedna drugoj.

3. Podaci i zadatak

Podaci su dohvaćeni s javnog *Facebook* aplikacijskog sučelja. Za potrebe dohvaćanja javnih komentara potrebno je registrirati aplikaciju na *Facebook* stranici za programere. Nakon uspješne registracije dobiven je sigurnosni ključ i ključ aplikacijskog sučelja. Pomoću ta dva ključa moguće je dohvatiti javne komentare sa *Facebook* stranica telekom poduzeća. Za dohvaćanje komentara korišteno je *Facebook* javno aplikacijsko sučelje pod imenom *Graph API*. Nakon dohvaćanja i spremanja podataka, potrebno je ručno označivanje podataka u svrhu pripreme ulaznih podataka za algoritam dubokog učenja.

Podaci su ručno označeni prema sljedećim kriterijima:

- Sentiment – pogled ili mišljenje koje se izražava,
 - Negativno,
 - Neutralno,
 - Pozitivno.
- Emocija
 - Ljutnja,
 - Razočaranje,
 - Uzbuđenje,
 - Prijateljstvo,
 - Zahvalnost,
 - Bepomoćnost,
 - Nestrpljivost,
 - Zanimanje,
 - Iritacija.

– Tema komentara

- Mobilne usluge,
- Fiksne usluge,
- Brzina interneta,
- Zaposlenici,
- Rješavanje problema,
- Dijalog,
- Zadovoljstvo općenito,
- Promocija,
- Usluge,
- SIM kartica,
- Varanje,
- Signal,
- Kvar,
- Aplikacije,
- TV,
- Općenito,
- Paket,
- Tarifa,
- Općenito podrška,
- Proces,
- Uređaj (Sklopovlje),
- Račun,
- Prodajni kanali,
- Dugogodišnji korisnici,
- Odnos općenito,
- Pritužba,
- Raskid ugovora,
- obraćanja,
- WiFi,
- Promet u inozemstvu,
- Reklame.

- Govorni čin
 - Pitanje,
 - Vrijeđanje,
 - Navođenje,
 - Traženje,
 - Upozorenje,
 - Isprika,
 - Nada,
 - Hvaljenje,
 - Ostalo.

Nakon što su podaci označeni, spremaju se u obliku JSON, koji je čitak svim popularnim programskim jezicima. Na početku izvođenja algoritma, podaci se ipak još jednom transformiraju u običnu tekstnu datoteku radi ponovljivosti eksperimenata. Nakon svih obrada podaci izgledaju kao na slici 3.1:

```
Moze free sim kartica|SIM kartica,mobilne usluge||interest||praising, stating||neutral*|**|*
Postovani, kada cete ukinuti uspostavu poziva?! S stovanjem|None||interest||asking||negative*|**|*
```

Slika 3.1 Prikaz podataka nakon transformacije

Nakon analize ulaznih podataka vidljivo je da ima otprilike jednak broj negativnih i neutralnih komentara, dok je broj pozitivnih komentara malen, što će sigurno utjecati na rad algoritma dubokog učenja jer podaci nisu balansirani. Taj problem se može riješiti tako da stopimo neutralne i pozitivne komentare u jednu klasu, tako da imamo otprilike jednak broj negativnih i nenegativnih komentara, s tim da nismo puno izgubili na vjerodostojnosti modele jer pozitivnih komentara ionako nema puno. Ulazni podaci su organizirani u lančanoj strukturi zbog prirode dohvaćenih podataka. Glava lanca je komentar koji korisnik objavi na zidu *Facebook* profila određenog telekomunikacijskog poduzeća.

Nakon toga podaci se nastavljaju na jedan od dva načina:

- Sljedeći u nizu je komentar komentara ostavljenog na zidu, a nakon njega odgovor na komentar. Ako postoji još komentara i odgovora, oni se nanižu jedan na drugog, kao što je vidljivo na slici 3.2,
- Slično kao i prvi način, sljedeći u nizu je komentar komentara i odgovori na komentar, međutim to je ujedno i kraj lanca. Ako ima još komentara ili odgovora, stvara se novi lanac s istom glavom, ali sa sljedećim komentarom i odgovorom na komentar, kao na slici 3.3.



Slika 3.2 Prvi način slaganja podataka – lanac je dugačak koliko i cijeli razgovor¹



Slika 3.3 Drugi način slaganja podataka - lanac se prekida svakim novim komentatom²

¹Slika Facebook sučelja <https://www.facebook.com/>

²Slika Facebook sučelja <https://www.facebook.com/>

Kako bismo što efikasnije prikazali ulazne podatke, koristi se popularna metoda transformacije teksta u vektor pod nazivom word2vec. Takva metoda nam omogućava bolju reprezentaciju riječi grupirajući riječi sličnog značenja u n -dimenzionalnom prostoru. Za potrebe ovog rada koriste se *fastText*³ vektori dimenzija 300, koji su preuzeti već trenirani na neuronskoj mreži.

3.1. Dataset

Dataset se sastoji od 2714 lanaca podataka, od toga 1293 pozitivnih, 7798 neutralnih i 6601 negativnih. U tablicama 3.4 - 3.7 dana je statistika označavanje ulaznih podataka.

	G	A_1	A_2	A_3
G	1.00	0.94	0.94	0.95
A_1	0.94	1.00	0.83	0.84
A_2	0.94	0.83	1.00	0.85
A_3	0.95	0.84	0.85	1.00

Tablica 3.4 Pearsonov koeficijent korelacije na skupu svih označenih threadova

Emocija	A1 i A2	A1 i A3	A2 i A3	Prosjek
ljutnja	0.26	0.24	0.18	0.23
razočaranje	0.24	0.14	0.22	0.20
uzbuđenje	0.48	0.06	0.27	0.27
prijateljstvo	0.27	0.30	0.55	0.37
zahvalnost	0.61	0.57	0.57	0.58
bespomoćnost	0.13	0.05	0.21	0.13
nestrpljivost	0.20	0.50	0.24	0.31
zanimanje	0.78	0.79	0.83	0.80
iritacija	0.61	0.46	0.51	0.53

Tablica 3.5 Cohenova kappa između parova anotatora za pojedinu emociju

³<https://github.com/facebookresearch/fastText/blob/master/pretrained-vectors.md>

Govorni čin	A1 i A2	A1 i A3	A2 i A3	Prosjek
isprika	0.00	0.00	0.00	0.00
pitanje	0.86	0.77	0.76	0.80
nada	0.40	0.00	0.00	0.13
vrijeđanje	0.58	0.59	0.69	0.62
hvaljenje	0.61	0.46	0.65	0.57
traženje	0.61	0.46	0.56	0.54
navođenje	0.61	0.57	0.57	0.58
upozorenje	0.86	0.67	0.62	0.72

Tablica 3.6 Cohenova kappa između parova anotatora za pojedini govorni čin tijekom označavanja.

Tema	A1 i A2	A1 i A3	A2 i A3	Prosjek
aplikacije	0.71	0.55	0.57	0.61
brzina interneta	0.68	0.64	0.68	0.67
dijalog	0.73	0.66	0.67	0.69
dugogodišnji korisnici	0.65	0.57	0.51	0.58
fiksne usluge	0.68	0.55	0.54	0.59
kvar	0.69	0.48	0.38	0.52
mobilne usluge	0.68	0.54	0.56	0.59
način obraćanja	0.38	0.49	0.26	0.38
odnos općenito	0.30	0.11	0.08	0.16
općenito	0.36	0.44	0.33	0.38
općenito podrška	0.03	0.02	0.26	0.10
ostalo	1.00	0.03	0.03	0.35
paket	0.20	0.15	0.24	0.20
pritužba	0.33	0.56	0.38	0.42
proces	0.24	0.12	0.39	0.25
prodajni kanal	0.28	0.53	0.47	0.43
promocija	0.59	0.49	0.44	0.51
račun	0.53	0.48	0.62	0.54
raskid ugovora	0.66	0.67	0.74	0.69
reklame	0.86	0.33	0.40	0.53
rješavanje problema	0.53	0.42	0.38	0.44
roaming	0.41	0.41	0.80	0.54
signal	0.55	0.53	0.39	0.49
SIM kartica	0.73	0.76	0.80	0.76
tarifa	0.34	0.34	0.53	0.40
TV	0.61	0.74	0.70	0.68
uređaj (HW)	0.76	0.70	0.74	0.73
varanje	0.31	0.35	0.40	0.35
zadovoljstvo (općenito)	0.06	0.10	0.31	0.16
zaposlenici	0.32	0.50	0.27	0.36
WiFi	0.80	0.39	0.43	0.54

Tablica 3.7 Cohenova kappa između parova anotatora za pojedinu temu u skupu od 100 threadova iz ukupnog skupa za označavanje.

4. Model

Za odabrani problem odabran je model koji se može prikazati u tri velike cjeline, odnosno tri sloja kroz koje ulazni podaci moraju proći do klasifikacije.

- Konvolucijska neuronska mreža,
- Povratna neuronska mreža,
- Unaprijedna potpuno povezana neuronska mreže.

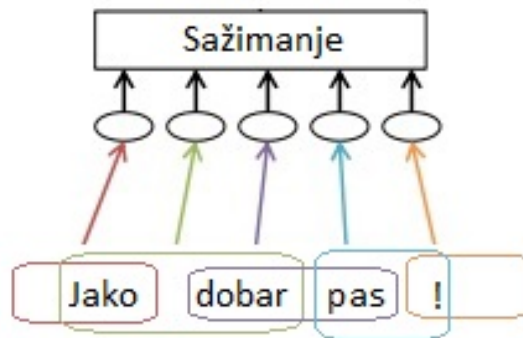
Model je implementiran pomoću programske biblioteke *Tensorflow*.¹ *Tensorflow* je jedan od najpopularnijih otvorenih programskih biblioteka za duboko učenje. Razvijen je od kompanije *Google*, te je veoma pouzdan i omogućava veliku slobodu u izgradnji modela.

Međutim, kako bismo uopće mogli koristiti model, svi podaci moraju biti jednake veličine, što naravno nije tako jer komentari mogu biti od bilo koliko riječi, a odgovora na komentara također može biti neodređeno. Zbog toga je potrebno upotrijebiti nadopunu. Prvo se odrede parametri L_{lanac} i $L_{komentar}$, koji označavaju željenu duljinu cijelog lanca komentara i željenu duljinu samog komentara. To su hiperparametri modela i bitno utječu na krajnju točnost modela. Nadopuna se vrši u dva koraka. Prvo se odredi duljina lanca. Ako je duljina lanca veća od L_{lanac} , tada se jednostavno odrežu svi komentari koji se u lancu pojavljuju nakon L_{lanac} . Ako je duljina lanca ipak manja, tada se lanac nadopunjuje sa nul-matricom dimenzija $L_{komentar} \times 300$, gdje je 300 veličina *word2vec* transformacije, dokle god duljina lanca nije L_{lanac} .

Drugi korak je nadopuna komentara. Isto kao i nadopuna lanca, ako je broj riječi u komentaru veći od $L_{komentar}$, sve riječi iza $L_{komentar}$ se odbacuju, a ako je broj riječi u komentaru manji od $L_{komentar}$, nadopunjuje se sa nul-vektorom dimenzija 1×300 dokle god duljina nije $L_{komentar}$. O ovim postupkom smo osigurali da svaki ulazni podatak u mrežu ima jednake dimenzije. Naravno, što su $L_{komentar}$ i L_{lanac} manji, to odbacujemo više podataka kao višak, ali je treniranje modela puno brže. U petom poglavlju su prikazani rezultati s različitim veličinama $L_{komentar}$ i L_{lanac} .

¹<https://www.tensorflow.org/>

Konvolucijska neuronska mreža je mreža koja je vrlo slična potpuno povezanoj neuronskoj mreži. Obje su sačinjene od neurona koji imaju parametre koji se mogu naučiti. Svaki neuron dobije neki ulaz, radi matrični produkt i opcionalno provlači izlaz kroz aktivacijsku funkciju. Razlika je u tome što konvolucijska mreža eksplicitno pretpostavlja da je ulaz u 2D prostoru. Većinom se to radi o slikama, gdje visina i širina slika tvori 2D prostor, dok je u ovom slučaju tekst matrica visine jedan, a širine broj riječi u rečenici. Takva arhitektura nam omogućava da efikasno ugradimo određene značajke teksta. Takav način nam također omogućava da uvelike smanjimo dimenzionalnost problema. U konkretnom slučaju koristimo konvoluciju određene veličine prozora, gdje je veličina prozora zapravo broj riječi koje obuhvatimo u jednom koraku konvolucije, kao što možemo vidjeti na slici 4.1. Na taj način izvlačimo ključne značajke iz teksta, a ujedno smanjujemo dimenzije ulaznih podataka.

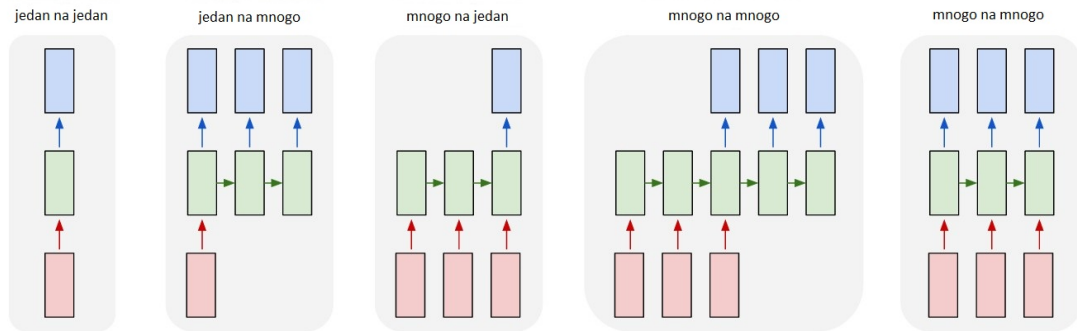


Slika 4.1 Sažimanje teksta

U ovom modelu koristi se trostruka konvolucija s različitim veličinama prozora, što znači da tri puta prolazimo kroz isti ulazni podatak, samo za različitih veličinama prozora. Na izlazu konvolucijskog sloja je zbrajalo, tj. spajaju se vektori svih 3 izlaza u jedan tenzor. Konvolucijska mreža nam u ovom obliku služi samo da izvuče bitne značajke iz teksta. Na izlazu nemamo potpuno povezanu unaprijednu mrežu koja bi služila za klasifikaciju. Umjesto toga na izlaz konvolucijske mreže spajamo povratnu neuronsku mrežu.

Povratne neuronske mreže su posebna vrsta neuronskih mreža, gdje se osim trenutnog ulaza u obzir uzimaju i prethodna stanja mreže. Struktura podsjeća na lanac, i ovaj dio mreže je namjerno odabran kako bi odgovarao strukturi podataka. Očekivano je da će komentar i odgovor na komentar međusobno biti povezani, i ova mreža je napravljena upravo za takvu vrstu obrade podataka.

Postoji nekoliko vrsti povratnih neuronskih mreža što je prikazano na slici 4.2:



Slika 4.2 Vrste povratnih neuronskih mreža, preuzeto od [10]

U našem slučaju koristimo arhitekturu "mnogo na mnogo"; gdje je prvi sloj izlaz konvolucijske mreže, drugi je skriveni sloj povratne mreže, a treći je izlaz potpuno povezana mreže koje služi za klasifikaciju.

Ulaz u konvolucijski sloj su ulazni podaci pretvoreni u *word2vec* vektore. Izlaz iz konvolucijske mreže su izvučene značajke kroz trostruku konvoluciju, a to je ujedno i ulaz u povratnu neuronsku mrežu. Povratnom neuronskom mrežom modeliramo vremensku ovisnost komentara i sa potpuno povezanom unaprijed neuronskom mrežom na izlaza iz povratne neuronske mreže klasificiramo ulazne podatke.

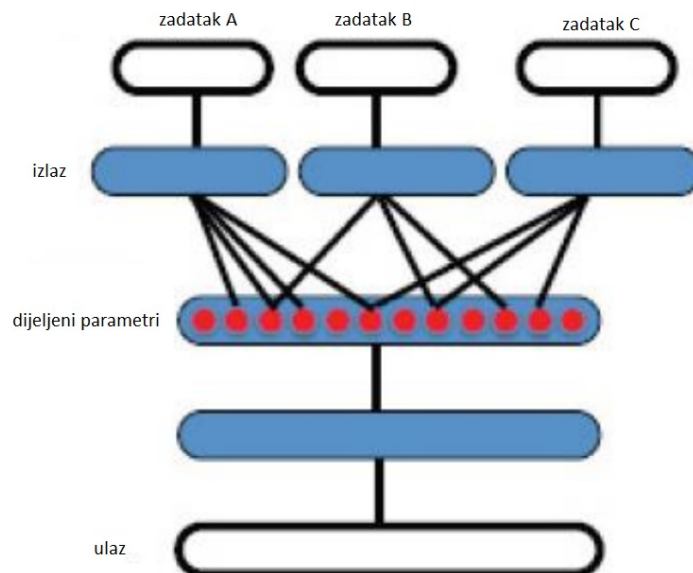
4.1. Združeno učenje

Ideja združenog učenja temelji se na povezanosti ciljnih oznaka. Primjerice, ako je sentiment negativan, očekivano je da emocija nije sreća. Pod pretpostavkom da to vrijedi, model može probati naučiti sve ili samo neke ciljne oznake zajednički, kao što je prikazano na slici 4.3 gdje su zadaci ciljne oznake, odnosno, predikcija sentimenta, emocija, teme komentara i govornog čina. U modelu izrađenom u ovom radu sve ciljne oznake se uče združeno.

Umjesto da imamo n mreža, gdje n označava broj različitih konfiguracija mreža, sa neuronskim mrežama odgovorajuće veličine za pojedinu ciljnu oznaku, izradili smo jedan model koji može naučiti sve ciljne oznake. U ovom radu ispitani su dva različita načina zajedničkog učenja.

Prvi način koristi četiri prolaza kroz podatke i četiri odvojene funkcije gubitaka, te za iste ulazne podatke n puta prilagođava parametre mreže, gdje je n broj različitih ciljnih oznaka.

Drugi način koristi jedan prolaz kroz podatke u koji se narinu svih n ciljnih oznaka, a funkcija gubitka je zbroj svih pojedinih gubitaka kroz jedan prolaz mreže, gdje je n opet broj različitih ciljnih oznaka.



Slika 4.3 Shema združenog učenja, preuzeto od [10]

4.2. Stroj s potpornim vektorima (SVM)

Osnovni model je stroj s potpornim vektorima (engl. Support Vector Machine) koji nam služi samo za usporedbu koliko je izgrađeni model bolji ili lošiji od klasičnog algoritma potpornih vektora. SVM je klasifikator definiran sa odvajajućom hiper-ravninom. Za dani problem u n dimenzijskom prostoru, algoritam pronalazi optimalnu hiper-ravninu kako bi što bolje odvojio ulazne podatke različitih klasa. Zapravo traži da je ravnina smještena na sredini dvoje najbližih ulaznih podataka različitih klasa. Ti ulazni podaci koji su na granici se nazivaju potporni vektori od kuda i dolazi naziv algoritma.

4.3. Osnovni duboki model

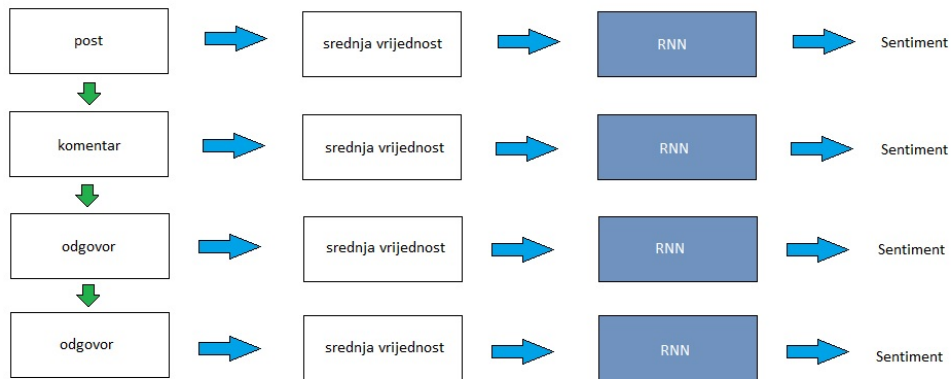
Osnovni duboki model sastoji se od pretvorbe prirodnog teksta u vektore *word2vec* vektore kao, što je opisano u prijašnjem poglavlju. Struktura lanaca je izrađena na 1. način – neprekinuti lanac cijelog razgovora. Značajke se računaju kao srednja vrijednost svakog komentara, što je prikazano na slici 4.4. Ovo je najjednostavniji mogući način izračuna značajki, a negativna strana je što gubimo puno informacija o samom razgovoru jer zapravo računamo prosjek svih riječi u komentaru.

Nakon toga takve značajke se daju kao ulaz u običnu povratnu neuronsku mrežu, koja na izlazu ima potpuno povezanu unaprijednu neuronsku mrežu koja služi kao klasifikator. Ovim modelom klasificira se samo sentiment, bez ostalih ciljnih oznaka, što podrazumijena da nema zajedničkog učenja. Zbog toga što je nadopunjavanje označeno neutralnom oznakom sentimenta, ovaj model se prenaučiti na neutralnu labelu i očekivano daje loše rezultate.

4.4. Poboljšani osnovni duboki model

Poboljšanje prijašnjeg modela dobiva se uvođenjem oznake duljine sekvence. To znači da kada nadopunjavamo lanac nulama, mi zapravo dodajemo nevažne podatke i time pogoršavamo rad modela. Uvođenjem oznake za duljinu sekvence riješavamo taj problem. Lanac i dalje nadopunjavamo nulama, ali u vrijeme treniranja mreže prestajemo učiti kada dođemo do oznake za duljinu sekvence, čimo smo efikasno riješili problem prenaučivosti na oznaku koju odaberemo za dodane nul-vektore, što je u ovom modelu bila neutralna oznaka.

Sljedeći korak je uvođenje povratne mreže *LSTM*. Konfiguracija mreže ostaje ista, a samo promjenom tipa povratne neuronske mreže dobivaju se značajno bolji rezultati. Također, u ovom stadiju razvoja modela uči se samo sentiment.



Slika 4.4 Shema osnovnog modela

4.5. Model za sentiment

Trenutno najveći problem modela je neefikasno izlučivanje značajki teksta, koje se do sada radilo računanjem srednje vrijednosti vektora riječi *word2vec*. U ovom modelu uvodi se konvolucijska neuronska mreža. Sloj konvolucijske neuronske mreže se zapravo sastoji od tri dijela. Svaki dio ima različitu veličinu prozora, takozvano receptivno polje. Taj podatak nam govori koliko riječi odjednom algoritam proučava. U ovom modelu su podešene veličine 3, 4 i 5. Očekivano, ovaj model daje najbolje rezultate jer rješava problem lošeg izvlačenja značajki teksta.

4.6. Model združenog učenja

Izgrađena su dva modela združenog učenja, kao što je spomenuto u poglavlju 4.1.

- Model s četiri prolaza kroz podatke i četiri funkcije pogreške,
- Model s jednim prolazom kroz podatke i zbrojem funkcije pogreška.

Rezultati ova dva modela se neznatno razlikuju, s tim da malo bolje rezultate daje prvi model sa četiri prolaza kroz podatke i četiri funkcije pogreške

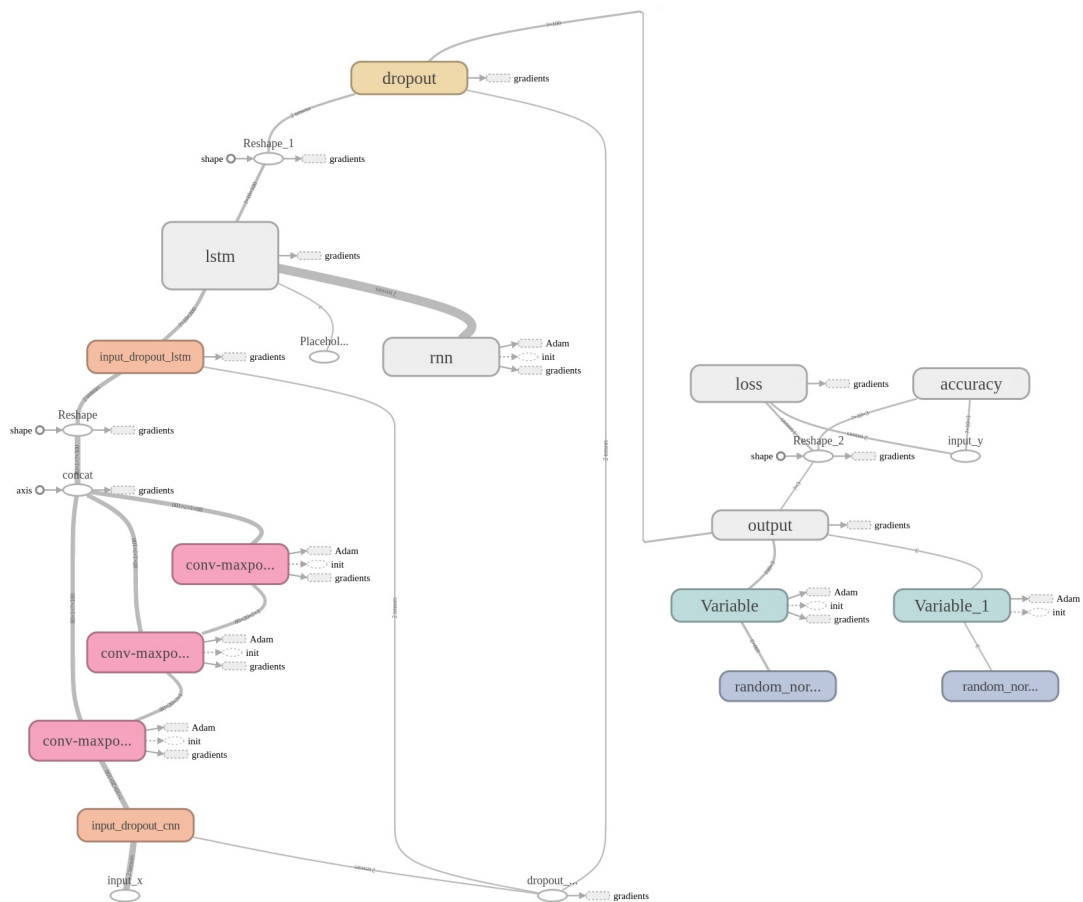
4.7. Varijacije modela

Model je izgrađen tako da se mogu mijenjati dodatni hiperparametri mreže, kao što je sloj povratne neuronske mreže. Omogućena je zamjena jednosmjerne povratne mreže a bidirekcionalnom povratnom neuronskom mrežom. Međutim, rezultati su znatno lošiji zamjenom povratne neuronske mreže.

Moguće je podatke za sentiment preoblikovati u binarne: negativne i ne-negativne, gdje je ne-negativna klasa spojena neutralna i pozitivna klasa. Očekivano točnost predikcija sentimenta raste svodenjem na binarne klase, a ne gubi se puno na vjerodostojnosti modela jer je broj pozitivnih komentara veoma malen.

4.8. Izgrađeni model

Schema izgrađenog modela je prikazana na slici 4.5. Na ulazu je odmah postavljen sloj odbacivanje neurona kako se mreža nebi prenaučila, a zatim slijedi trostruka konvolucija sa različitim veličinama prozora. Nakon prolaska kroz konvolucijski sloj, sva tri tensora se spoje u jedan i daju se na ulaz povratne neuronske mreže. Ispred ulaza u povratnu neuronsku mrežu je opet sloj odbacivanje neurona u svrhu regularizacije mreže. Na izlazu iz povratne neuronske mreže je još jedan sloj obacivanje neurona, te unaprijedna potpuno povezana neuronska mreža koja služi za klasifikaciju ciljnih oznaka.



Slika 4.5 Shema modela

5. Eksperimenti

U ovom poglavlju dan je pregled svih rezultata eksperimenata sprovedenih u ovom radu. Kao osnovica koristi se SVM model i svi ostali modeli se uspoređuju s rezultatom SVM modela. Prikazani su rezultati osnovnih modela, koji su zapravo osnovica dubokih modela, sa očekivano lošijim rezultatima. Nakon toga prikazani su rezultati sa konačnim modelom, s malim razlikama u arhitekturi, što je detaljno objašnjeno u slijedećim poglavljima. Također, različiti načini slaganja ulaznih podataka su testirani.

Za potrebe testiranja ulazni podaci su podjeljeni na skup za učenje i skup za testiranje, s tim da je skup za učenje osamdeset posto ulaznih podataka, a ostatak je skup za testiranje. Kada model uđe u stacionarno stanje (između pet epoha greška na skupu za testiranje se ne smanjuju), učenje se zaustavlja i kao rezultat testiranja uzima se najbolji rezultat na skupu za testiranje.

Parametri modela su odabrani metodom pretraživanja rešetke (engl. grid search). U radu su prikazana dva seta parametara, koji su davali najzanimljivije rezultate. Mjere uspješnosti korištene u ovim testovima su: točnost i F1-mjera. Točnost nam govori koliki je omjer točno klasificiranih primjera nasprad netočno klasificiranih primjera. F1-mjera, ili kraće samo $F1 = \frac{2 * P * R}{P + R}$, gdje je P omjer točno klasificiranih pozitivnih primjera naspram zbroju točno klasificiranih pozitivnih primjera i broju krivo klasificiranih pozitivnih primjera, a R je omjer točno klasificiranih pozitivnih primjera naspram zbroju točno klasificiranih pozitivnih primjera i broju krivo klasificiranih negativnih primjera. Ova formulacija vrijedi za binarne značajke, međutim jednostavnim modifikacija se može proširiti i za n dimenzionalne značajke. Za potrebe ovog rada koristi se makro verzija računanja F1-mjera. Makro verzija F1-mjere se računa tako da se izračuna prosjek P i R nad svim n binarnim značajkama.

5.1. SVM

SVM se koristi kao osnovica za usporedbu sa svim modelima. U tablici 5.1 dani su rezultati eksperimenata sa *SVM*om.

Sentiment		
Ciljna oznaka	Točnost	F1-mjera
Sentiment	0.66	0.66
Emocije	0.53	0.18
Tema	0.18	0.21
Govorni čin	0.35	0.44

Tablica 5.1. Rezultati modela *SVM*

5.2. Osnovni modeli

Osnovni modeli su modeli bez združenog učenja, samo s oznakama sentimenta. Rezultate možemo vidjeti u tablici 5.2.

Vrsta	Točnost	F1-mjera
<i>word2vec</i> srednja vrijednost, RNN ćelija	0.75	0.34
<i>word2vec</i> srednja vrijednost, RNN ćelija, duljina sekvence	0.45	0.25
<i>word2vec</i> srednja vrijednost, LSTM ćelija, duljina sekvence	0.69	0.61
<i>word2vec</i> , CNN, LSTM ćelija, učenje do duljine sekvence	0.71	0.62

Tablica 5.2. Rezultati osnovnih modela

Vidljivo je kako prvi model ima najbolju točnost, ali jako lošu F1-mjeru. To je tako zbog toga što su komentari koji su u lancu samo zbog nadopune označeni neutralnom klasom sentimenta. Zbog toga se model prenaučio na jednu klasu koja je daleko najviše zastupljena u ulaznim podacima.

Model koji prestaje učiti kada naiđe na nadopunu je suviše primitivan i ne može naučiti klasificirati sentiment, mada nema problem kao prvi model.

Sljedeći model daje najveće poboljšanje. Umjesto obične povratne ćelije, koristi se *LSTM* ćelija i takva mreža daje puno bolju točnost, a pogotovo puno bolju F1-mjeru.

Model koji umjesto srednje vrijednosti ima konvolucijsku mrežu daje najbolje performanse, iako nije veliki napredak od prethodnog modela. Umjesto srednje vrijednost svih *word2vec* vektora svakog komentara, uključena je konvolucijska neuronska mreža

koja služi za dohvaćanje bitnih značajki iz teksta. Zadnja dva modela su razmjerno dobra kao što je i *SVM* model, a očekivanje prva dva su dosta lošija jer je model prejednostavan.

5.3. Modeli združenog učenja

Modeli združenog učenja su modeli koji pokušavaju odjednom naučiti sve ciljne oznake, pod pretpostavkom da su te ciljne oznake povezane na neki način, što zapravo i nije teško zamislivo. U okviru ovog rada, testirana su tri različita modela.

- Združeno učenja s više prolaza za svaku pojedinu ciljnu oznaku,
- Združeno učenja s jednim prolazom,
- Združeno učenja s jednim prolazom, drugačiji način slaganja lanca ulaznih podataka.

U nastavku je dan prikaz rezultata eksperimenata.

5.3.1. Združeno učenja s više prolaza kroz ulazne podatke za svaku pojedinu ciljnu oznaku

Prvi pokus je za manji model. Kako je i navedeno u uvodu ovog poglavlja, parametri modela su određeni pretraživanjem po rešetci i ovaj set parametara je pokazao najbolje rezultate. Lanac se nadopunjava do dužine 10, a komentar se nadopunjava do dužine 20. Skriveni sloj povratne neuronske mreže je veličine 200. Konvolucijski sloj koristi 100 filtra. P_n označava vjerojatnost zadržavanja neurona.

Sentiment

Povratna mreža	P_n	Bidirekcionalnost	Binarni sentiment	Točnost	F1-mjera
RNN	0.8	Da	Ne	0.38	0.33
RNN	0.8	Da	Da	0.50	0.41
RNN	0.8	Ne	Ne	0.65	0.55
RNN	0.8	Ne	Da	0.69	0.64
GRU	0.8	Da	Ne	0.46	0.32
GRU	0.8	Da	Da	0.49	0.38
GRU	0.8	Ne	Ne	0.69	0.59
GRU	0.8	Ne	Da	0.71	0.65
LSTM	0.8	Da	Ne	0.45	0.34
LSTM	0.8	Da	Da	0.53	0.54
LSTM	0.8	Ne	Ne	0.69	0.61
LSTM	0.8	Ne	Da	0.72	0.71

Tablica 5.3. Rezultati združenog učenja za sentiment

Ovaj eksperiment počinje od najjednostavnijeg modela, do najzloženijeg modela i vidi se trend rasta performansi modela. Binarni sentiment očekivano dodatno poboljšava rezultate.

Tema komentara

Povratna mreža	P_n	Bidirekcionalnost	Binarni sentiment	Točnost
RNN	0.8	Da	Ne	0.04
RNN	0.8	Da	Da	0.05
RNN	0.8	Ne	Ne	0.22
RNN	0.8	Ne	Da	0.25
GRU	0.8	Da	Ne	0.04
GRU	0.8	Da	Da	0.05
GRU	0.8	Ne	Ne	0.29
GRU	0.8	Ne	Da	0.30
LSTM	0.8	Da	Ne	0.03
LSTM	0.8	Da	Da	0.31
LSTM	0.8	Ne	Ne	0.31
LSTM	0.8	Ne	Da	0.30

Tablica 5.4. Rezultati združenog učenja za temu komentara

Emocije

Povratna mreža	P_n	Bidirekcionalnost	Binarni sentiment	Točnost
RNN	0.8	Da	Ne	0.03
RNN	0.8	Da	Da	0.09
RNN	0.8	Ne	Ne	0.24
RNN	0.8	Ne	Da	0.25
GRU	0.8	Da	Ne	0.06
GRU	0.8	Da	Da	0.07
GRU	0.8	Ne	Ne	0.31
GRU	0.8	Ne	Da	0.31
LSTM	0.8	Da	Ne	0.06
LSTM	0.8	Da	Da	0.07
LSTM	0.8	Ne	Ne	0.27
LSTM	0.8	Ne	Da	0.24

Tablica 5.5. Rezultati združenog učenja za emocije

Govorni čin

Povratna mreža	P_n	Bidirekcionalnost	Binarni sentiment	Točnost
RNN	0.8	Da	Ne	0.14
RNN	0.8	Da	Da	0.13
RNN	0.8	Ne	Ne	0.42
RNN	0.8	Ne	Da	0.41
GRU	0.8	Da	Ne	0.17
GRU	0.8	Da	Da	0.16
GRU	0.8	Ne	Ne	0.43
GRU	0.8	Ne	Da	0.43
LSTM	0.8	Da	Ne	0.14
LSTM	0.8	Da	Da	0.15
LSTM	0.8	Ne	Ne	0.47
LSTM	0.8	Ne	Da	0.47

Tablica 5.6. Rezultati združenog učenja za govorni čin

Vidljivo je da bidirekcionalnost zapravo spušta performanse modela, te se u sljedećim eksperimentima ne koristi. Također, možemo zaključiti kako binarni sentiment ima malo ili nimalo utjecaja na točnost ostalih značajki, ali daje poprilično veliki skok točnosti predikcije sentimenta. Sentiment, govorni čin i tema komentara daju bolje rezultate nego *SVM*, dok emocije imaju bolje rezultate sa *SVMom*.

Drugi pokus je s modelom s drugačijim setom parametara. Parametri su također određeni pretraživanjem po rešetci. Kao što je navedeno, ne koristi se bidirekcionalnost. Lanac se nadopunjava do dužine 30, a komentar se nadopunjava do dužine 60. Skriveni sloj povratne neuronske mreže je veličine 200. Konvolucijski sloj koristi 150 filtra. P_n označava vjerojatnost zadržavanja neurona.

Sentiment

Povratna mreža	P_n	Binarni sentiment	Točnost	F1-mjera
RNN	0.7	Ne	0.66	0.55
GRU	0.7	Ne	0.68	0.58
LSTM	0.7	Ne	0.68	0.58
LSTM	0.7	Da	0.73	0.74

Tablica 5.7. Rezultati združenog učenja za sentiment

Tema komentara

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.7	Ne	0.19
GRU	0.7	Ne	0.31
LSTM	0.7	Ne	0.27
LSTM	0.7	Da	0.34

Tablica 5.8. Rezultati združenog učenja za temu komentara

Emocije

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.7	Ne	0.24
GRU	0.7	Ne	0.25
LSTM	0.7	Ne	0.22
LSTM	0.7	Da	0.29

Tablica 5.9. Rezultati združenog učenja za emocije

Govorni čin

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.7	Ne	0.42
GRU	0.7	Ne	0.41
LSTM	0.7	Ne	0.36
LSTM	0.7	Da	0.42

Tablica 5.10. Rezultati združenog učenja za govorni čin

Analizom rezultata vidljivo je da, iako je ovaj model ekspresivniji od prošlog, rezultati su vrlo bliski, a vrijeme učenje ja 10 puta dulje, stoga povećavanje ekspresivnosti nije opravdano. Sentiment, govorni čin i tema komentara daju bolje rezultate nego *SVM*, dok emocije imaju bolje rezultate sa *SVM*om.

5.3.2. Združeno učenje s jednim prolazom kroz ulazne podatke

Ovaj model je drugačiji od prijašnjih jer koristi samo jedan prolaz kroz ulazne podatke za sve ciljne oznake, a funkcija gubitaka je zbroj svake pojedine funkcije gubitaka svih ciljnih oznaka modela. Kao i u prijašnjem modelu imamo dva pokusa: jednostavniji i ekspresivniji model, parametri su odabrani kao i u modelu s više prolaza kroz ulazne podatke. Lanac se nadopunjava do dužine 10, a komentar se nadopunjava do dužine 20. Skriveni sloj povratne neuronske mreže je veličine 100. Konvolucijski sloj koristi 100 filtra. Bidirekcionalnost se ne koristi, jer kao i u prijašnjim modelima, spušta performanse modela. P_n označava vjerojatnost zadržavanja neurona.

Sentiment

Povratna mreža	P_n	Binarni sentiment	Točnost	F1-mjera
RNN	0.8	Ne	0.64	0.54
RNN	0.8	Da	0.70	0.70
GRU	0.8	Ne	0.68	0.60
GRU	0.8	Da	0.71	0.69
LSTM	0.8	Ne	0.67	0.58
LSTM	0.8	Da	0.72	0.68

Tablica 5.11. Rezultati združenog učenja za sentiment

Tema komentara

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.8	Ne	0.13
RNN	0.8	Da	0.13
GRU	0.8	Ne	0.18
GRU	0.8	Da	0.19
LSTM	0.8	Ne	0.21
LSTM	0.8	Da	0.20

Tablica 5.12. Rezultati združenog učenja za temu komentara

Emocije

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.8	Ne	0.23
RNN	0.8	Da	0.19
GRU	0.8	Ne	0.21
GRU	0.8	Da	0.22
LSTM	0.8	Ne	0.28
LSTM	0.8	Da	0.26

Tablica 5.13. Rezultati združenog učenja za emocije

Govorni čin

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.8	Ne	0.35
RNN	0.8	Da	0.36
GRU	0.8	Ne	0.37
GRU	0.8	Da	0.37
LSTM	0.8	Ne	0.42
LSTM	0.8	Da	0.44

Tablica 5.14. Rezultati združenog učenja za govorni čin

Drugi pokus je sa modelom sa drugim setom parametara. Lanac se nadopunjava do dužine 30, a komentar se nadopunjava do dužine 60. Skriveni sloj povratne neuronske mreže je veličine 200. Konvolucijski sloj koristi 150 filtra. P_n označava vjerojatnost zadržavanja neurona.

Sentiment

Povratna mreža	P_n	Binarni sentiment	Točnost	F1-mjera
RNN	0.7	Ne	0.69	0.65
GRU	0.7	Ne	0.67	0.60
LSTM	0.7	Ne	0.69	0.60
LSTM	0.7	Da	0.73	0.75

Tablica 5.15. Rezultati združenog učenja za sentiment

Tema komentara

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.7	Ne	0.22
GRU	0.7	Ne	0.16
LSTM	0.7	Ne	0.27
LSTM	0.7	Da	0.25

Tablica 5.16. Rezultati združenog učenja za temu komentara

Emocije

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.7	Ne	0.17
GRU	0.7	Ne	0.15
LSTM	0.7	Ne	0.23
LSTM	0.7	Da	0.19

Tablica 5.17. Rezultati združenog učenja za emocije

Govorni čin

Povratna mreža	P_n	Binarni sentiment	Točnost
RNN	0.7	Ne	0.33
GRU	0.7	Ne	0.29
LSTM	0.7	Ne	0.38
LSTM	0.7	Da	0.36

Tablica 5.18. Rezultati združenog učenja za govorni čin

Model s jednim prolazom kroz ulazne podatke i zajedničkom funkcijom gubitaka ne daje poboljšanje s obzirom na model sa više prolaza kroz ulazne podatke i zasebnim funkcijama gubitaka. Treniranje je brže jer algoritam nemora prolaziti četiri puta kroz podatke za svaki ulazni parametar. Sentiment, govorni čin i tema komentara daju bolje rezultate nego SVM, dok emocije imaju bolje rezultate sa SVMom.

5.3.3. Združeno učenje s jednim prolazom kroz ulazne podatke i kratkim lancima ulaznih podataka

Model je isti kao u prošlom pokusu, međutim lanci podataka su izgrađeni na drugi način kao što je opisano u poglavlju tri. Lanci se prekidaju svakim novim komentarom. Na taj način imamo ponavljanje dijelova lanca, ali kako je skup podataka za učenje dosta malen, model će imati više ulaznih podataka za naučiti. Lanac se nadopunjava do dužine 15, a komentar se nadopunjava do dužine 30. Skriveni sloj povratne neuronske mreže je veličine 100. Konvolucijski sloj koristi 100 filtra. Bidirekcionalnost se ne koristi, jer, kao i u prijašnjim modelima, spušta performanse modela. Parametri su odabrani pretragom po rešetki. P_n označava vjerojatnost zadržavanja neurona.

Sentiment

Povratna mreža	P_n	Binarni sentiment	Točnost	F1-mjera
GRU	0.6	Ne	0.63	0.55

Tablica 5.19. Rezultati združenog učenja za sentiment

Tema komentara

Povratna mreža	P_n	Binarni sentiment	Točnost
GRU	0.6	Ne	0.13

Tablica 5.20. Rezultati združenog učenja za temu komentara

Emocije

Povratna mreža	P_n	Binarni sentiment	Točnost
GRU	0.6	Ne	0.18

Tablica 5.21. Rezultati združenog učenja za emocije

Govorni čin

Povratna mreža	P_n	Binarni sentiment	Točnost
GRU	0.6	Ne	0.29

Tablica 5.22. Rezultati združenog učenja za govorni čin

Drugi pokus je s modelom identičnim kao u prijašnjem pokusu, jedino je vjerojatnost zadržavanja neurona drugačija. P_n označava vjerojatnost zadržavanja neurona.

Sentiment

Povratna mreža	P_n	Binarni sentiment	Točnost	F1-mjera
GRU	0.7	Ne	0.63	0.57

Tablica 5.23. Rezultati združenog učenja za sentiment

Tema komentara

Povratna mreža	P_n	Binarni sentiment	Točnost
GRU	0.7	Ne	0.15

Tablica 5.24. Rezultati združenog učenja za temu komentara

Emocije

Povratna mreža	P_n	Binarni sentiment	Točnost
GRU	0.7	Ne	0.20

Tablica 5.25. Rezultati združenog učenja za emocije

Govorni čin

Povratna mreža	P_n	Binarni sentiment	Točnost
GRU	0.7	Ne	0.32

Tablica 5.26. Rezultati združenog učenja za govorni čin

Vidljivo je da rezultati nisu bolji od prijašnjih modela. Problem ovog modela je što je treniranje vrlo sporo, pa nisu izvedeni svi testovi kao na prijašnjim modelima. Finim ugađanjem parametara i mjenjanjem dijelova mreža vjerojatno bi se dobili bolji rezultati od trenutno prikazanih.

5.4. Rezultati

Testirane su razne kombinacije povratnih neuronskih mreža, sa raznim kombinacija parametara i načina slaganja ulaznih podataka. Tema komentara i emocije imaju najbolji rezultat, što je i očekivano s obzirom da imaju najviše različitih klasa. Sentiment i govorni čin imaju prihvatljive rezultate. Svođenjem sentimenta na samo dvije klase, dobiju se bolji rezultati. Uvođenje kratkih lanaca nije dalo bolje rezultate, međutim ti modeli se jako dugo treniraju i nisu ispitani do kraja, tako da je moguće da sa nekim drugim setom parametara daju bolje rezultate od dugačkim lanaca.

6. Zaključak

Ovaj rad proučava primjenu dubokog učenja za klasifikaciju teksta. Cilj rada je bio istražiti je li moguće dobiti bolji rezultate primjenom algoritama dubokog učenja, ili su ipak klasični algoritmi strojnog učenja još uvijek bolji. Također, istražena je mogućnost zajedničkog učenja ciljnih oznaka, pod pretpostavkom da su ciljne oznake ovisne jedna o drugoj. Ovo područje je od iznimnog značaja jer započinje razvoj strojeva koji razumiju i odgovaraju na prirodni jezik, što je najviše korišteni način komunikacije ljudi. Kroz rad istražene su neke arhitekture dubokih neuronskim mreža koje imaju obećavajuće rezultate u obradi prirodnog teksta. Izrađeno je nekoliko različitih arhitektura mreža te dva načina prikaza podataka. Kako su ulazni podaci zapravo tekstni razgovor, odabrana je lančana struktura podataka kako bi modelirali vremensku ovisnost između komentara. Prvi način prikaza je lanac koji obuhvaća cijeli razgovor, a drugi je lanac koje se prekida nakon svakog novog komentara. Izrađena je osnovna arhitektura dubokih neuronskim mreža koja klasificira samo sentiment. Nakon toga izrađeno je više arhitektura za združeno učenje svih značajki. Pretpostavljeno je da su značajke međusobno ovisne, pa se očekuje da združeno učenje daje bolje rezultate. Prvi model prolazi četiri puta kroz iste podatke, dok drugi model prolazi samo jednom, a funkcija pogreške na zbroj svih funkcija pogreške svake značajke.

Nakon izrade modela, pokrenuti su testovi. Mjeri se točnosti i F1-mjera za sentiment i točnost za temu komentara, emocije i govorni čin. Rezultati su zadovoljavajući, ali nisu dobri. Točnost oko 0.7 nije rezultat koji bi polučio većem napretku u polju obrade prirodnog jezika metodama dubokog učenja.

Za budući rad postoji niz nadogradnji koje bi trebalo istražiti. Jedan od većih problema kod ovog rada je nedovoljno velik uzorak ulaznih podataka. Duboko učenje počiva na temeljima velikih podataka, kojima netrebaju ručno izrađena pravila kako bi model mogao generalizirati. Međutim, takav način zahtjeva puno veći skup ulaznih podataka nego što je bilo dostupno za ovaj rad. Također, kod modela s većim iznosima parametara treniranje traje dugo. Zanimljivo bi bilo pustiti model sa većim iznosima parametara da se trenira na nekom distribuiranom *GPU* okruženju, gdje bi

treniranje bilo dosta ubrzano. Što se tiče same arhitekture, ima nekoliko zanimljivih mogućnosti nadogradnje. U modelu s jednim prolazom kroz ulazne podatke i funkcijom gubitaka definiranoj kao zbroj svih funkcija gubitaka, bilo bi zanimljivo istražiti težinsku sumu tih funkcija gubitaka i ustvrditi je li moguće na taj način poboljšati performanse modela. Također, zamjenom konvolucijske neuronske mreže s još jednom povratnom neuronskom mrežom mogli bismo potencionalno dobiti drugačije performanse modela. Također, moguće su i kombinacije s višeslojnim povratnim neuronskim mrežama kako sa konvolucijskim slojem tako i bez njega kada imamo dvije povratne neuronske mreže.

7. Popis slika

1	Deep learning	Michael Nielsen, 2017	http://neuralnetworksanddeeplearning.com/chap6.html
2	Konvolucijske neuronske mreže	Šegvić, 2017	http://www.zemris.fer.hr/~ssegvic/du/du2convnet.pdf
3	CS231n Convolutional Neural Networks for Visual Recognition		http://cs231n.github.io/convolutional-networks/
4	Povratne neuronske mreže	Tutek, 2017	http://www.zemris.fer.hr/~ssegvic/du/du5recurrent.pdf
5	Povratne neuronske mreže	Tutek, 2017	http://www.zemris.fer.hr/~ssegvic/du/du5recurrent.pdf
6	Problem nestajućeg gradijenta		http://imgur.com/gallery/vaNahKE
7	<i>LSTM</i>	deeplearning	http://deeplearning.net/tutorial/lstm.html
8	<i>LSTM</i> i <i>GRU</i>	deeplearning	https://deeplearning4j.org/lstm.html
9	The Unreasonable Effectiveness of Recurrent Neural Networks	Karpathy, 2015	http://karpathy.github.io/2015/05/21/rnn-effectiveness/
10	Joint Deep Learning	Dong Wang, 2015	http://cs1t.riit.tsinghua.edu.cn/mediawiki/images/d/d6/Joint_Deep_Learning.pdf

LITERATURA

- G. Chowdhury. *Natural language processing. Annual Review of Information Science and Technology*, 37. pp. 51-89. URL <http://strathprints.strath.ac.uk/2611/1/strathprints002611.pdf>.
- C. Cortes and V. Vapnik. *Support Vector Machine*. URL <http://mlab.cb.k.u-tokyo.ac.jp/~moris/lecture/cb-mining/4-svm.pdf>.
- Stanford University CS231n. *CS231n Convolutional Neural Networks for Visual Recognition*. URL <http://cs231n.github.io/convolutional-networks/>.
- deeplearning4j.org. *A Beginner's Guide to Recurrent Networks and LSTMs*. URL <https://deeplearning4j.org/lstm.html>.
- deeplearning.net. *LSTM Networks for Sentiment Analysis*. URL <http://deeplearning.net/tutorial/lstm.html>.
- Yoav Goldberg and Omer Levy. *word2vec Explained: Deriving Mikolov et al.'s Negative-Sampling Word-Embedding Method*. URL <https://arxiv.org/pdf/1402.3722.pdf>.
- Andrej Karpathy. *The Unreasonable Effectiveness of Recurrent Neural Networks*. URL <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>.
- Josip Krapac. *Duboke unaprijedne mreže*. URL <http://www.zemris.fer.hr/~ssegvic/du/dulfeedforward.pdf>.
- Jurgen Schmidhuber. *Deep Learning in Neural Networks: An Overview*. URL <https://arxiv.org/pdf/1404.7828.pdf>.
- Martin Tutek. *Povratne neuronske mreže*. URL <http://www.zemris.fer.hr/~ssegvic/du/du5recurrent.pdf>.

Dong Wang. *Joint Deep Learning*. URL http://cs1t.riit.tsinghua.edu.cn/mediawiki/images/d/d6/Joint_Deep_Learning.pdf.

WILDML. *RECURRENT NEURAL NETWORKS TUTORIAL*. URL <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>.

Rie Johnson. Tong Zhang. *Convolutional Neural Networks for Text Categorization: Shallow Word-level vs. Deep Character-level*. URL <https://arxiv.org/pdf/1609.00718.pdf>.

Siniša Šegvić. *Konvolucijske neuronske mreže*. URL <http://www.zemris.fer.hr/~ssegvic/du/du2convnet.pdf>.

Modeli dubokog učenja za analizu korisničkih komentara na društvenim mrežama

Sažetak

U zadnje vrijeme duboko učenje polako uzima maha i postavlja se kao način za izradu umjetne inteligencije. Jedan od važnih segmenta umjetne inteligencije je razumjevanje prirodnog jezika. U ovom radu dan je pregled nekih algoritama s kojim je moguće odrediti sentiment, emociju, temu i govorni čin iz komentara sa *Facebook* stranica hrvatskih telekomunikacijskih kompanija.

Ključne riječi: Duboko učenje, obrada prirodnog jezika, analiza korisničkih komentara, neuronske mreže, *word2vec*, *Facebook*, sentiment, emocije, komentari, govorni čin

Deep Learning Models for the Analysis of User Comments on Social Networks

Abstract

In recent years deep learning is starting to take off in the world of artificial intelligence, and is starting to be the default approach of machine learning. One of the most important parts of artificial intelligence is understanding natural language. In this thesis, some promising algorithms are looked into. Those algorithms can determine sentiment, emotion, topic, and speech act of users comments posted on Facebook.

Keywords: Deep learning, natural language processing, user comments analysis, neural network, *word2vec*, Facebook, sentiment, emotions, comments, speech acts