

ANALIZA SENTIMENTA KOMENTARJEV HOTELOV Z UPORABO SLOVARJEV IN METODE NE NAIVNI BAYES

Nina Murks

Univerza v Mariboru,
Fakulteta za elektrotehniko, računalništvo
in informatiko,
Koroška cesta 46, 2000 Maribor, Slovenija
nina.murks@student.um.si

Anže Omerzu

Univerza v Mariboru,
Fakulteta za elektrotehniko, računalništvo
in informatiko,
Koroška cesta 46, 2000 Maribor, Slovenija
anze.omerzu@student.um.si

Borko Boškovič

Univerza v Mariboru,
Fakulteta za elektrotehniko, računalništvo
in informatiko,
Koroška cesta 46, 2000 Maribor, Slovenija
borko.boskovic@um.si

POVZETEK

V članku smo predstavili pristop k analizi sentimenta komentarjev hotelskih gostov s pomočjo slovarjev in metode Naivni Bayes. Najprej smo zgradili slovarja sentimenta, ki sta vsebovala n-grame, ter njihove verjetnosti, da pripadajo pozitivnemu ali negativnemu razredu. Nato smo s pomočjo zgrajenih slovarjev klasificirali komentarje hotelov, pri čemer smo uporabili metodo Naivni Bayes. Pri klasifikaciji komentarjev smo računali klasičniskanske vrednosti o z. verjetnosti, da so posamezni komentarji pozitivni ali negativni. Komentarje smo klasificirali s pomočjo unigramov in bigramov, ter rezultate primerjali z rezultati iz literature. Pri unigramih smo dosegli natančnost 0,92, pri bigramih je natančnost znašala 0,80. Klasičniskanske vrednosti posameznih komentarjev smo si shranili, pri čemer smo pri komentarjih, ki smo jih klasificirali kot negativne, dodali negativen predznak. Predznačene klasičniskanske vrednosti smo nato sešteli, za vsak hotel ter na tak način izračunali hotelom pripadajoče točke. Točke hotelov so v našem primeru pokazatelj splošnega zadovoljstva hotelskih gostov, ki ga najdemo v komentarjih. Glede na točke smo hotele uredili po vrsti in prišli do lestvice hotelov, pri katerih najdemo najbolj pozitivne komentarje.

Ključne besede analiza sentimenta, komentarji hotelskih gostov, slovar sentimenta, n-grami, Naivni Bayes

1 Uvod

Preden se odpravimo na potovanje, je ena izmed pomembnih odločitev izbira nastanitve. Pri določitvi kraja namestitve so nam pomembne namestitvene zmožnosti – ali ima hotel bazen, organizirano varstvo, brezplačno parkiranje itd. Več o kvaliteti storitev, ki jih ponuja izbrana nastanitev, lahko izvemo neposredno od gostov, ki

so storitve že koristili; pobrsamo po spletnih komentarjih, povezanih z mnenjem o nastanitvi.

Odločili smo se, da analizo sentimenta apliciramo na komentarje gostov hotelov. Sprva smo komentarje klasificirali kot pozitivne ali negativne. S pomočjo klasificiranih komentarjev smo ugotovili, ali je bil večini hotelskih gostov izbran hotel všeč ali ne. Cilj našega eksperimenta je bila aplikacija, ki omogoča takojšen vpogled v širše mnenje o hotelu, ki ga najdemo v komentarjih hotelskih gostov.

V članku smo predstavili različne pristope k analizi sentimenta, in sicer v poglavju Sorodna dela. V naslednjem poglavju sledi opis eksperimenta, ki smo ga izvedli. Znotraj tega smo najprej predstavili, na kakšen način smo pridobili podatke in kako smo jih predprocesirali. Nato smo predstavili način grajenja slovarjev, njihovo uporabo in klasifikacijo komentarjev hotelskih gostov. V zadnjem podpoglavju tega poglavja smo predstavili pristop računanja točk za posamezen hotel. Nazadnje podamo še zaključek in možnosti za nadaljnje delo.

2 Sorodna dela

Analiza sentimenta zajema računalniško analizo stališč govorca ali pisca. Stališče pisca, ki ga lahko prepoznamo v besedilu, je lahko pozitivno, negativno ali nevtravno. Danes je uporaba analize izjemno koristna pri spremljanju družbenih omrežij, saj nam omogoča vpogled v javno mnenje [2].

Uporaba analize sentimenta je dobro raziskano področje, kar kaže visoko število pojavitev znanstvenih in strokovnih člankov/prispevkov s tega področja. Znanih je več pristopov k analizi sentimenta. V nadaljevanju smo jih predstavili nekaj – po vzoru že objavljenih člankov [8][3].

Prvi pristop temelji na unigramih in vzorcih iz učne množice (ang. training set) [1][10]. Avtorji člankov so raziskovanje usmerili na vzorce komentarjev na družbenem omrežju Twitter. S pomočjo unigramov in vzorcev so razpoznavali, ali je komentar sovražen (žaljiv) ali čist (nev-



tralen) ali pozitiven [10]. V drugem članku so raziskovalci s pomočjo vzorcev iskali prisotnost sarkazma v komentarjih.

Tudi v naslednjem, za naše raziskovanje pomemben članku [11], so avtorji svoje raziskovanje usmerili na sentimente komentarjev na družbenih omrežjih. Njihov pristop uporablja utežene besedne vektorje, ki predstavljajo vhod v celico nevronske mreže (BiLSTM), ki zazna kontekstne informacije. Tako bolje predstavi vektorje komentarjev. Sentiment komentarjev se kasneje naprej določi s klasifikacijo nevronske mreže.

V članku [8] so uporabili ordinalno regresijo z uporabo tehnik učenja. Za omenjeno tehnologijo so uporabili javno bazo komentarjev na Twitterju, ki jih je bilo treba vnaprej procesirati z uporabo metode ekstrakcije lastnosti. Za klasifikacijo analize sentimenta so uporabili različne algoritme: Multinomijska logistična regresija (Multinomial logistic regression - SoftMax), podpora vektorski regresiji (Support Vector Regression - SVR), odločitvena drevesa (Decision Trees - DTs) in naključni gozd (Random Forest - RF).

V članku [7] so raziskovalci za analizo sentimenta uporabili in nadgradili pristop k ansamblu lastnosti (ang. feature ensemble), pri katerem so upoštevali različne elemente, ki jih drugi raziskovalci pri uporabi te metode zanemarijo. Upoštevali so besedoslovje, besedno vrsto, jezikovno semantiko in položaj besed.

Do zdaj omenjeni pristopi uporabljajo analizo sentimenta nad angleškim jezikom. Zanimalo nas je, kako se analize sentimenta lotevajo v tujih jezikih, kjer je sentiment manj jasen. Prav to so storili v članku [4], v katerem so se posvetili nejasnosti kitajskih fraz, ki so izraženi v sentimentu. Tradicionalni pristop s strojnimi učenjem ne more prikazati resničnega sentimenta, zato so predlagali uporabo multistrateške metode analize razpoloženja in prikazali, da hibridna analiza sentimenta dosega zadovoljive rezultate.

Članka [5] in [9] vsebujeta analizo sentimenta s pomočjo konvolucijskih nevronske mreže. Prvi naveden članek uporablja konvolucijske mreže za analizo sentimenta komentarjev na Twitterju, drugi pa za zaznavanje sarkazma na socialnih omrežjih. Konvolucijske nevronske mreže so sestavljene iz več slojev, kjer vsak sloj opravlja nalogo pripravljanja, pretvarjanja ali popravljanja podatkov.

Analize sentimenta se lahko lotimo tudi s pomočjo slovarjev in metode Naivni Bayes, kot so to storili v članku [6]. V tem članku so analizirali sentiment komentarjev Danmaku¹ videov. Uporabili so slovar sentimenta, ki so ga razširili z emotikoni, saj so ti zelo pomembni pri komentarjih Danmaku videov. Pri analizi sentimenta pa niso samo klasificirali pozitivne in negativne komentarje, temveč so uporabili kar sedem razredov: gnus, žalost, všečnost, jeza, presenečenje, strah in veselje. Po tem, ko so generirali slovar, ki ustreza kontekstu (za komentarje Danmaku videov), so se lotili klasifikacije komentarjev s pomočjo metode Naivni Bayes. Pristop z uporabo slo-

¹Danmaku je Japonski izraz za sistem podnapisov, ki ga uporabljajo spletne video platforme. Omogočajo uporabniku objavljanje premikajočih se komentarjev na video, ki se predvaja.

varjev in metode Naivni Bayes je bil od vseh (prej omenjenih) najprimernejši, zato smo se odločili, da ga uporabimo pri implementaciji lastne ideje.

3 Predlagan pristop

V tem poglavju smo predstavili našo analizo sentimenta za klasificiranje hotelskih komentarjev in pridobivanje točk zadovoljstva nastanitve posameznih hotelov, ki se skrivajo v besedilu komentarjev. Sledi kratka predstavitev načina pridobivanja podatkov, ter načrtovanja in izvedbe eksperimenta.

3.1 Pridobivanje podatkov

Poiskali smo podatkovno bazo, ki je že vsebovala klasificirane komentarje hotelov. To bazo podatkov smo našli na spletni strani Kaggle. Sledi kratka predstavitev spletne strani.

Kaggle, podružnica podjetja Google LLC, je spletna skupnost podatkovnih znanstvenikov in izvajalcev strojnega učenja. Kaggle uporabnikom omogoča, da najdejo in objavijo nabore podatkov, raziskujejo in gradijo modele v spletnem okolju za znanost o podatkih, sodelujejo z drugimi znanstveniki in inženirji strojnega učenja ter se udeležujejo tekmovanj za reševanje izzivov na področju podatkov.

Izbrana baza podatkov je bila narejena s pomočjo spletne strani Booking.com. Vsebuje 515.000 komentarjev o 1493 različnih Evropskih hotelih. Podatki imajo naslednjo obliko: naslov hotela, datum komentarja, povprečen rezultat hotela (ta je izračunan s pomočjo zadnjega komentarja, ki se je pojavil v tekočem letu), ime hotela, nacionalnost pisca komentarja, negativen komentar, število besed v negativnem komentarju, pozitiven komentar, število besed v pozitivnem komentarju, točke pisca komentarja (točke, ki jih je pisec dodelil hotelu), število komentarjev, ki jih pisec podal, število komentarjev, ki jih ima posamezen hotel, značke (ki jih je dodelil pisec komentarja), koliko dni je minilo od zadnjega komentarja, dodatne točke k hotelu (nekateri so napisali samo točke) ter geografska širina in dolžina lokacije hotela.

Komentarji v podatkovni bazi so že imeli izločena vsa ločila in znake, ki jih ni v angleški abecedi (ASCII znaki). Ker je bila baza dobro pripravljena, nismo imeli veliko dela – odstranili smo številke in pretvorili besedilo komentarjev v male črke. Podatkovno bazo smo tudi razdelili na testno in učno množico, pri čemer je učna množica zajemala približno 80 % vseh podatkov, testna pa preostalih 20 %. Učno množico smo uporabili za grajenje slovarjev, testno pa za klasifikacijo komentarjev. Delitev podatkov v učno in testno množico je potekala za vsak hotel posebej. Zbrali smo vse komentarje o določenemu hotelu, nato pa smo le-te razdelili na učno in testno množico tako, da je učna množica vsebovala približno 80 % komentarjev.

3.2 Grajenje slovarjev

Podatki so bili predhodno obdelani in lahko smo se lotili gradnje slovarjev. Odločili smo se, da bomo algoritem

izvedli na dva načina – s pomočjo unigramov in bigramov. Algoritem, ki upravlja z unigrami, se od algoritma z bigrami ne razlikuje preveč, le da slovarja temeljita enkrat na unigramih, drugič pa na bigramih. Tudi pri uporabi slovarjev in računanju klasifikacij s pomočjo metode Naivni Bayes je prišlo do razlike le pri predprocesiranju posameznih komentarjev, kjer smo pri unigramih vzeli unigrame, torej posamezne besede, pri bigramih, pa bigrame, torej dvojice besed.

Grajenja slovarjev smo se lotili tako, da smo najprej prebrali učno množico podatkov in si shranili vse komentarje posebej – razdelili smo jih na pozitivne in negativne. Pri vsaki različici algoritma (unigrami in bigrami) smo naredili dva slovarja. Prvi slovar je imel izračunane verjetnosti, da posamezen n-gram (kadar koli se sklicujemo na n-gram imamo v mislih unigram ali bigram) pripada pozitivnemu komentarju, drugi pa verjetnosti, da posamezen n-gram pripada negativnemu komentarju. Da smo verjetnosti pripadnosti n-gramov v posamezen razred lahko izračunali, smo najprej morali narediti še nekaj korakov. Če smo gradili slovar pozitivnih komentarjev, smo potrebovali vse n-grame, ki jih najdemo v besednjaku pozitivnih komentarjev. Potrebovali smo tudi seznam vseh n-gramov, ki se najdejo tako v pozitivnih komentarjih kot tudi v negativnih, in njihove frekvence pojavitve. Izračunali smo tudi velikost slovarja vseh n-gramov (koliko različnih n-gramov se nahaja v pozitivnih in negativnih komentarjih). Sedaj smo se lahko lotili računanja posameznih verjetnosti n-gramov, da le-ti pripadajo določenemu razredu (pozitivnemu ali negativnemu). Verjetnost, da n-gram pripada razredu smo izračunali po enačbi:

$$P(n\text{-gram}|\text{razred}) = \frac{\text{frekvenca}(n\text{-gram}, \text{razred}) + 1}{\text{frekvenca}(\text{razred}) + V} \quad (1)$$

Vsako verjetnost izračunamo tako, da vzamemo frekvenco pojavitve n-grama znotraj razreda, tej prištejemo ena (da se izognemo ničelnim vrednostim), nato pa dobljen rezultat delimo z vsoto frekvence razreda in velikostjo slovarja (V). Frekvenca razreda predstavlja število n-gramov, ki se pojavi znotraj posameznega razreda. Za vsak n-gram smo izračunali verjetnost za oba razreda (pozitivni in negativni razred) ter si na tak način ustvarili slovarja, ki smo ju shranili v datoteki. Ker se v testni množici, ki smo jo uporabili za klasifikacijo, lahko pojavi tudi takšen n-gram, ki ga v učni množici (s pomočjo te smo gradili slovarja) nismo imeli, smo v slovar na začetek dodali vrednost neznanega n-grama in ga označili kot "unknown_". Pri oznaki smo uporabili podčrtaj, saj bi se sam n-gram "unknown" lahko pojavil pri komentarjih, torej bi v tem primeru vzeli napačno verjetnost. Ker pa smo iz podatkovne zbirke že odstranili vsa ločila, smo tukaj lahko uporabili to lastnost in n-gramu dodali ločilo.

3.3 Klasifikacija komentarjev

Klasifikacija komentarjev iz testne množice je potekala tako, da smo najprej prebrali slovarja, ki smo si ju shanili v prejšnjem koraku. Ustvarili smo podatkovno strukturo Review, ki je vsebovala vsebino komentarjev, informacijo o tem ali je komentar pozitiven, informacijo o pravilnosti klasifikacije komentarjev in vrednost klasifikacije. Naredili smo tudi podatkovno strukturo HotelReviews. Ta

je vsebovala ime hotela, seznam komentarjev (s pomočjo prej definirane strukture Review) in vrednost klasifikacije. Naredili smo seznam podatkovnih struktur HotelReviews, kamor smo si shranili podatke, ki smo jih kasneje pridobili iz testne množice podatkovne baze.

Prebrali smo testno množico podatkovne baze in si pri tem shranjevali za nas potrebne informacije – ime hotela in komentarje, ki smo jih že označili, ali so v podatkovni bazi bili prepoznani kot pozitivni ali negativni, saj nam je to kasneje pomagalo pri izračunu natančnosti klasifikacijskega modela. Podatke iz testne množice smo shranili v prej omenjene strukture. Ko smo imeli vse podatke shranjene v naših podatkovnih strukturah, smo se lotili klasifikacije komentarjev.

Za vsak komentar, ki je sestavljen iz sekvence n-gramov, smo vedno izračunali 2 vrednosti: klasifikacijsko vrednost, da komentar pripada pozitivnemu komentarju, in klasifikacijsko vrednost, da pripada negativnemu komentarju.

$$\text{komentar} = n\text{-gram}1, n\text{-gram}2, \dots, n\text{-gram}N \quad (2)$$

$$\begin{aligned} P(\text{komentar}|\text{pozitiven}) = & \\ & \log(P(\text{pozitiven})) \\ & + \log(P(n\text{-gram}1|\text{pozitiven})) \\ & + \log(P(n\text{-gram}2|\text{pozitiven})) \\ & \dots \\ & + \log(P(n\text{-gram}N|\text{pozitiven})) \end{aligned} \quad (3)$$

$$\begin{aligned} P(\text{komentar}|\text{negativen}) = & \\ & \log(P(\text{negativen})) \\ & + \log(P(n\text{-gram}1|\text{negativen})) \\ & + \log(P(n\text{-gram}2|\text{negativen})) \\ & \dots \\ & + \log(P(n\text{-gram}N|\text{negativen})) \end{aligned} \quad (4)$$

Če je bila pozitivna klasifikacijska vrednost večja od negativne, smo komentar klasificirali kot pozitiven, v nasprotnem primeru smo komentar klasificirali kot negativen.

Izračunano klasifikacijsko vrednost smo si shranili, pri čemer smo pri negativnem klasifikacijskem rezultatu dodali negativen predznak – to nam je pomagalo v prihodnjih korakih pri določanju splošnega zadovoljstva hotelskih gostov, ki ga najdemo v komentarjih s pomočjo računanja točk posameznih hotelov. Več o tem sledi v naslednjem poglavju.

3.4 Računanje točk zadovoljstva hotelskega bivanja

Ko smo klasificirali vse komentarje posameznih hotelov, smo se posvetili ocenjevanju splošnega zadovoljstva, ki ga najdemo v komentarjih. Prvotna ideja je bila, da bi prešteli pozitivne in negativne komentarje, ter izračunali njihov delež v primerjavi z vsemi komentarji za posamezen

hotel. Odločili smo se, da bomo naredili še en korak naprej in namesto štetja računali vrednosti klasifikacije, kar je točkam posameznih hotelov dodalo še dodatno težo. Ta teža se odraža pri komentarjih, ki smo jih klasificirali znotraj istega razreda – npr. 2 komentarja, ki sta klasificirana kot pozitivna se lahko razlikujeta v tem, da je eden bolj pozitiven kot drugi.

V prejšnjem koraku smo komentarjem, ki smo jih klasificirali za negativne, dodelili negativen predznak (ostali imajo pozitivnega, saj je verjetnost nečesa vedno pozitivna). Te klasifikacijske vrednosti smo nato seštelili za posamezen hotel in na tak način izračunali splošno zadovoljstvo glede hotela. Večja kot je bila vsota komentarjev posameznega hotela, bolj so bili gosti hotela, ki so komentarje napisali, zadovoljni. Za vsak hotel smo torej izračunali vrednost, ki predstavlja točke hotela, in v splošnem zajema zadovoljstvo. Nato smo hotele uredili glede na njihove izračunane točke ter na tak način dobili lestvico hotelov.

4 Eksperiment

V eksperimentu smo klasifikacijo izvedli na dva načina – z uporabo unigramov in bigramov. Oba klasifikacijska načina smo primerjali med sabo z izračunom natančnosti modela, preciznosti, priklicem in mero F1. Pri izračunu natančnosti, preciznosti in priklicu smo uporabili parameter tp (ang. true positive), ki predstavlja število pravilno klasificiranih pozitivnih komentarjev, tn (ang. true negative), ki predstavlja število pravilno klasificiranih negativnih komentarjev, fp (ang. false positive), predstavlja število napačno klasificiranih negativnih komentarjev in fn (ang. false negative), ki pove število napačno klasificiranih pozitivnih komentarjev.

$$Natančnost = \frac{tp + tn}{tp + tn + fp + fn} \quad (5)$$

$$Preciznost = \frac{tp}{tp + fp} \quad (6)$$

$$Priklic = \frac{tp}{tp + fn} \quad (7)$$

$$F1 = \frac{2 * Preciznost * Priklic}{Preciznost + Priklic} \quad (8)$$

Pri računanju metrik uspešnosti klasifikacij smo vrednosti izračunali tako za unigrame kot za bigrame, ter prišli do rezultatov, ki so prikazani v tabeli 1. Zraven naših rezultatov, so prikazani tudi rezultati iz literature [6], po kateri smo se zgledovali pri implementaciji algoritma.

Iz tabele 1 lahko razberemo, da se unigrami v vseh metrikah uspešnosti bolje obnesejo od bigramov. Unigrami imajo namreč boljši rezultat pri natančnosti, preciznosti, priklicu in pri uglaseni meri F1. Največjo razliko med unigrami in bigrami vidimo pri izračunu priklica. Na podlagi tega lahko sklepamo, da smo pri bigramih imeli veliko število napačno klasificiranih pozitivnih komentarjev.

Tabela 1: Metrike uspešnosti klasifikatorjev.

	Unigrami	Bigrami	Članek [6]
Natančnost	0,92	0,80	0,75
Preciznost	0,94	0,93	/
Priklic	0,91	0,67	/
Mera F1	0,92	0,78	/

Če pa primerjamo priklic in preciznost bigramov, vidimo, da so bigrami bili pri preciznosti bolj uspešni kot pri priklicu. Iz slednjega lahko sklepamo, da je število napačno klasificiranih negativnih komentarjev bilo manjše kot število napačno klasificiranih pozitivnih komentarjev. Pri unigramih pa je razlika med priklicem in preciznostjo dokaj mala, zato lahko sklepamo, da je delež napačno klasificiranih komentarjev približno enako razporejen med napačno klasificiranimi pozitivnimi komentarji (fn) in napačno klasificiranimi negativnimi komentarji (fp).

V članku [6] so za klasifikacijo komentarjev videov Danmaku uporabili slovar sentimenta, ki ni temeljil zgolj na besedišču komentarjev. Pri klasifikaciji komentarjev so uporabili bigrame, torej lahko njihove rezultate primerjamo z našimi rezultati pri pristopu z bigrami. Dosegli smo boljše rezultate (tabela 1) zaradi uporabe slovarjev, ki so bolj domensko specifični.

Kot zanimivost smo ustvarili tudi vizualno predstavitev unigramov (besed), ki se najpogosteje pojavijo v pozitivnih in negativnih komentarjih. Vizualno predstavitev vidimo na sliki 1, pri čemer zelena slika predstavlja pogoste besede, ki jih najdemo v pozitivnih komentarjih, rdeča slika pa prikazuje pogoste besede znotraj negativnih komentarjev.



Slika 1: Vizualna predstavitev najpogostejših besed v komentarjih

5 Zaključek

V okviru naše naloge smo uporabili analizo sentimenta nad komentarji hotelskih gostov. Klasifikacijo komentarjev smo izvedli s pomočjo slovarjev in metode Naivni Bayes, pri čemer smo eksperiment izvedli s pomočjo unigramov in bigramov. Končni rezultati so pokazali, da je klasifikacija s pomočjo unigramov uspešnejša, kot pa z bigrami. Pri klasifikaciji s pomočjo unigramov smo dosegli 92 % natančnost, pri bigramih pa 80 %. V članku [6] so dosegli 75 % natančnost, torej so bili manj uspešni

pri klasifikaciji. Boljše rezultate napram primerjalnega članka smo dosegli zaradi uporabe slovarjev sentimenta, ki temeljijo zgolj na besedišču, ki ga najdemo v komentarjih, med tem ko so v [6] uporabljali bolj splošen slovar.

Klasifikacijo komentarjev smo v našem članku uporabili za raziskavo splošnega zadovoljstva hotelskih gostov, ki so napisali komentarje za določen hotel. Eksperiment bi lahko v nadaljnjem delu razširili z upoštevanjem nacionalnosti piscev komentarjev pri sami klasifikaciji. Na tak način bi lahko ugotovili korelacijo med nacionalnostjo piscev komentarjev in zadovoljstva glede določenega hotela, ki se skriva v komentarjih. Posameznim komentarjem bi v bodoče lahko dodali tudi številčno oceno (npr. od 1 do 5), ki bi jo pridobili s pomočjo razširitve trenutnega eksperimenta.

Literatura

- [1] BOUAZIZI, M., AND OTSUKI OHTSUKI, T. A pattern-based approach for sarcasm detection on twitter. *IEEE Access* 4 (2016), 5477–5488.
- [2] BRANDWATCH, K. B. Understanding sentiment analysis: What it is & why it's used.
- [3] CAI, R., QIN, B., CHEN, Y., ZHANG, L., YANG, R., CHEN, S., AND WANG, W. Sentiment analysis about investors and consumers in energy market based on bert-bilstm. *IEEE Access* 8 (2020), 171408–171415.
- [4] FANG, Y., TAN, H., AND ZHANG, J. Multi-strategy sentiment analysis of consumer reviews based on semantic fuzziness. *IEEE Access* 6 (2018), 20625–20631.
- [5] JIANQIANG, Z., XIAOLIN, G., AND XUEJUN, Z. Deep convolution neural networks for twitter sentiment analysis. *IEEE Access* 6 (2018), 23253–23260.
- [6] LI, Z., LI, R., AND JIN, G. Sentiment analysis of danmaku videos based on naïve bayes and sentiment dictionary. *IEEE Access* 8 (2020), 75073–75084.
- [7] PHAN, H. T., TRAN, V. C., NGUYEN, N. T., AND HWANG, D. Improving the performance of sentiment analysis of tweets containing fuzzy sentiment using the feature ensemble model. *IEEE Access* 8 (2020), 14630–14641.
- [8] SAAD, S. E., AND YANG, J. Twitter sentiment analysis based on ordinal regression. *IEEE Access* 7 (2019), 163677–163685.
- [9] SON, L. H., KUMAR, A., SANGWAN, S. R., ARORA, A., NAYYAR, A., AND ABDEL-BASSET, M. Sarcasm detection using soft attention-based bidirectional long short-term memory model with convolution network. *IEEE Access* 7 (2019), 23319–23328.
- [10] WATANABE, H., BOUAZIZI, M., AND OHTSUKI, T. Hate speech on twitter: A pragmatic approach to collect hateful and offensive expressions and perform hate speech detection. *IEEE Access* 6 (2018), 13825–13835.
- [11] XU, G., MENG, Y., QIU, X., YU, Z., AND WU, X. Sentiment analysis of comment texts based on bilstm. *IEEE Access* 7 (2019), 51522–51532.

