

VILNIAUS UNIVERSITETAS  
MATEMATIKOS IR INFORMATIKOS FAKULTETAS  
PROGRAMŲ SISTEMŲ STUDIJŲ PROGRAMA

**Smurtinio pobūdžio žinučių identifikavimas  
vykdant interneto portalų anoniminių nuomonių  
sentimentų analizę**

**Identifying Violent Messages Using Sentiment Analysis of  
Anonymous Internet Portal Comments**

Magistro baigiamasis darbas

Atliko: Matas Blagnys (parašas)

Darbo vadovas: afilijuotasis mokslininkas  
prof. habil. dr. Leonidas Sakalauskas (parašas)

Recenzentas: prof. dr. (HP) Romas Baronas (parašas)

Vilnius – 2021

## **Santrauka**

Darbe kuriami bei tiriama smurtinį turinį lietuviškuose interneto portalų komentaruose atpažįstančių sistemų metodų rinkiniai bei jais pagrįsti prototipai. Teksto klasifikavimui pasitelkiami atraminių vektorių, naivaus Bajeso bei FastText mašininio mokymosi algoritmai. Šiems algoritmams pateikiami tekstai apdorojami kamienavimo algoritmais, papildomi netekstiniais komentarų parametrais bei sentimentų žymėmis. Sentimentų žymės išgaunamos formuojant sentimentų analizės modelį naudojant teksto klasifikavimo algoritmus apmokytus lietuviškais prekių bei paslaugų internetiniais atsiliepimais. Lyginant su viešai prieinamais etaloniniais klasifikatoriais, darbe sukurti smurtinio turinio atpažinimo sistemų prototipai pasiekia geresnius rezultatus visų tiriamų statistinių matų atžvilgiu.

Darbo raktiniai žodžiai: sentimentų analizė, teksto klasifikavimas, interneto portalai, internetiniai komentarai.

## **Summary**

This master's thesis proposes and analyses a collection of methods and prototypes (based on the aforementioned methods) that are capable of detecting violent Lithuanian language comments in internet news websites. Support-vector machines, naive Bayes and FastText machine learning algorithms are used for text classification. These algorithms are provided with texts that are processed using stemming algorithms and complemented with non-text parameters from comments as well as sentiment markers. The sentiment markers are calculated by machine learning algorithms trained on internet-based reviews for goods and services. When compared to publicly available benchmark classifiers, the proposed violent content detection system prototypes have managed to achieve better results in all relevant statistical metrics.

**Keywords:** sentiment analysis, text classification, internet news websites, internet comments.

## Turinys

Įvadas.....	4
Tyrimo procesas.....	5
1. Literatūros apžvalga.....	7
1.1. Sentimentų analizė.....	7
1.2. Teksto klasifikavimas.....	10
1.3. Natūralios kalbos apdorojimas.....	13
1.4. Interneto svetainių komentarai.....	15
2. Nagrinėjami duomenys.....	17
2.1. Interneto portalų anoniminių nuomonės.....	17
2.2. Sentimentų analizės duomenys.....	19
3. Naudojami mašininio mokymosi algoritmai.....	22
3.1. Naivus Bajeso algoritmas.....	22
3.2. Atraminių vektorių algoritmas.....	22
3.3. FastText.....	23
3.4. Hibridinis klasifikatorius.....	23
4. Teksto klasifikavimo sistemos metodų rinkiniai.....	24
5. Eksperimentų eiga bei rezultatai.....	26
5.1. Eksperimentų su smurtinio turinio atpažinimo prototipais rezultatai.....	26
5.2. Sentimentų analizės įrankio parametų poveikis eksperimentų rezultatams.....	33
Rezultatai ir išvados.....	36
Šaltiniai.....	38
Sąvokų apibrėžimai.....	46
Santrumpos.....	47

## Ivadas

Didžiausios pasaulio internetinės svetainės kaip Youtube.com, Facebook.com bei Wikipedia.org pagrįstos tuo pačiu kertiniu principu - šių platformų turinys yra kuriamas ir įkeliamas jų lankytojų [Ale21, Fac21a, Goo21, Wik21]. Tokių svetainių populiarumas rodo, jog interneto vartotojai vertina gebėjimą išreikšti nuomonę, pasidalinti žiniomis ir / ar pademonstruoti savo kūrybiškumą. Nuo šių internetinių turinio platformų neatsilieka ir svetainės lietuvių kalba - dideli lietuviški portalai kaip 15min.lt bei Delfi.lt leidžia po jų publikuotais naujienų straipsniais palikti komentarus [Del20a, Min20a]. Šis interaktyvumas suteikia galimybę šių straipsnių skaitytojams ne tik sužinoti ką nors naujo, bet ir pasidalinti savo nuomone to straipsnio tema. Interaktyvumas, deja, turi ir neigiamų savybių - dalis publikuojamo turinio gali būti nepriimtinas nei svetainių savininkams, nei didžiajai daliai lankytojų. Viena iš neretai pastebimų tokio turinio kategorijų yra smurtinio pobūdžio tekstai.

Dideli interneto portalai kaip 15min.lt ir Delfi.lt draudžia smurtinio pobūdžio turinį straipsnių komentarų sekcijose [Del20a, Min20a] tad jas valdančios įmonės turi paskirti resursus samdydamos asmenis, kurie šį turinį ištrina. Augant portalų vartotojų skaičiui auga ir krūvis, kurį komentarų moderatoriai turi apimti. Įrankis gebantis automatiškai identifikuoti smurtinio pobūdžio turinį ne tik sumažintų iš verslo reikalaujamų resursų apimtį, bet ir leistų apdoroti didesnę kiekį komentarų (juos ištrinant ar perkeliant į moderatoriaus komentarų patikrinimo sąrašą) nei įmanoma rankiniais metodais. Nors tokią sistemą įmanomą realizuoti pasitelkiant vien tik taisyklėmis, jos galimybė aprėpti didžiąją dalį smurtinių išraiškų bei gebėjimas reaguoti į naujas tokio turinio išraiškos formas būtų ribota (t.y. reikalautų aktyvios programuotojų komandos, kuri nuolatos atnaujintų ir tobulintų sistemą pastebėjus naują smurtinio turinio išraiškos tipą). Siekiant sukurti įrankį, kuris gebėtų ne tik nesudėtingai aprėpti kuo įmanomą didesnę dalį smurtinių išraiškų, bet ir save tobulinti su turinio moderatoriaus pagalba reikia pasitelkti mašininio mokymosi technologijas. Su mašininio mokymosi technologijomis bendroje klasifikavimo sistemoje galima naudoti ne tik tekstą, bet ir papildomus su komentarų susijusius parametrus (pvz. komentaro sentimentą), kurie gali pagelbėti atpažinimo procesui.

Dėl šių priežasčių darbo tikslas – sukurti teksto klasifikavimo sistemos metodų rinkinį bei juo paremtą prototipą tikslumo atžvilgiu gebantį atpažinti lietuvių kalba parašytus anoniminius smurtinio pobūdžio komentarus interneto portaluose geriau nei šiuo metu viešai prieinamos teksto klasifikavimo ir sentimentų analizės priemonės. Šis tikslas siekiamas atliekant šiuos uždavinius:

1. Nustatyti lietuviškų anoniminių interneto portalų komentarų ypatybes teksto klasifikavimo bei sentimentų analizės kontekste.
2. Sukurti smurtinio turinio atpažinimui skirtą neformalaus teksto apdorojimo, papildymo bei klasifikavimo metodų rinkinį.
3. Realizuoti teksto klasifikavimo sistemos prototipą, kurie geba atpažinti lietuvių kalba parašytus anoniminius smurtinio pobūdžio komentarus interneto portaluose, rinkinį.
4. Identifikuoti sukurtų teksto klasifikavimo sistemos prototipų smurtinio turinio atpažinimo tikslumą, atpažintų smurtinių komentarų dalį, F1 balą, atpažinimo greitį, privalumus, trūkumus bei palyginti juos su viešai prieinamomis teksto klasifikavimo sistemomis pagal tuos pačius parametrus.
5. Nustatyti sentimentų analizės bei kitų teksto papildymo ir apdorojimo metodų bei algoritmų poveikį smurtinio turinio atpažinimo sistemos prototipo tikslumui, atpažintai smurtinių komentarų daliai bei F1 balui.

Smurtinio turinio atpažinimo įrankio kūrimui pasitelkiamas mašininis mokymusi pagrįstas teksto klasifikavimas bei sentimentų analizė nėra naujos idėjos, tačiau analizavimas lietuvių kalbos ypatybių bei susitelkimas į bandymą atpažinti sentimentus susijusius su anoniminėmis smurtinio (tiesioginio bei netiesioginio) pobūdžio interneto portalų žinutėmis išskiria temą kaip nagrinėjančią plačiai neištirtą sritį. Nors publikuotų darbų apie internetinių komentarų sentimentų analizę egzistuoja, šie darbai išleisti prieš 7 ar daugiau metų [Kav11, Skr12] arba juose atliekama bendra sentimentų analizė [Kav11, Skr12, Tam18], o ne specifinio sentimentų grupės identifikavimas. Šių darbų amžius taip pat turi įtakos galimų sprendimų kokybei - mašininis mokymusi pagrįstos natūralios kalbos apdorojimas [YHP+18] bei sentimentų analizės [MGK18] technologijos nuolat tobulėja.

## **Tyrimo procesas**

Tyrimo objektas yra trumpų nestruktūrizuotų lietuviškų tekstų sentimentų analizės bei klasifikavimo technologijos, jų tikslumas, mokymo ir atpažinimo efektyvumas bei jų stiprybės ir silpnybės. Darbo objekto bei temos analizė atliekama šia tvarka:

1. Anoniminių interneto portalų komentarų bei lietuvių kalbos sentimentų analizės ypatybių identifikavimas ir aprašymas.
2. Taisyklėmis bei mašininis mokymusi pagrįstų sentimentų analizės bei teksto klasifikavimo sistemų algoritmų ir metodų paieška.
3. Su parinktais metodais ir algoritmais susijusių šaltinių paieška ir turinio analizė.

4. Metodų rinkinių atliekančių teksto klasifikavimo bei sentimentų analizės užduotis kūrimas.
5. Teksto klasifikavimo sistemos prototipo (programos) kūrimas ir testavimas.
6. Tyrimo objekto, detalaus proceso, gautų rezultatų ir iš jų padarytų išvadų aprašymas.

Analizuojant bei tiriant darbo temą, magistro darbe naudojami šie tyrimo metodai:

- Mokslinių darbų ir kitų su sentimentų analize ar teksto klasifikavimu susijusių šaltinių turinio analizė.
- Eksperimentai su teksto klasifikavimo bei sentimentų analizės įrankiais (t.y. įrankių naudojimas vykdyti skirtingus teksto atpažinimo scenarijus bei šios veiklos ir rezultatų stebėjimas).
- Anoniminių komentarų sentimentų analizės bei teksto klasifikavimo sistemos prototipo (programos) kūrimas.

Renkant papildomą aprašomąją informaciją naudojamosi tiriamų technologijų kūrėjų paruoštais techniniais ir funkciniais aprašais. Renkant dalykinę bei statistinę informaciją remiamasi publikuotais moksliniais tyrimais bei mokslinėmis monografijomis. Realizuojant tyrimui naudojamą programinį kodą naudojama Python programavimo kalba su Scikit-learn, FastText, Peewee, Lxml, Emot bei Pystemmer programinio kodo bibliotekomis. Surinkti bei analizuojami duomenys laikomi duomenų bazės sistemos SQLite rinkmenose.

## 1. Literatūros apžvalga

Šiame skyriuje apžvelgiama ir analizuojama publikuota literatūra, kuri yra aktuali darbo temai. Norint identifikuoti darbo temai aktualią literatūrą, reikia išskirti darbo temos potemes. Potemės apibrėžiamos kaip temos, iš kurių susideda magistro darbo tema. Šios potemės yra:

- Sentimentų analizė.
- Teksto klasifikavimas.
- Mašininis mokymasis.
- Natūralios kalbos apdorojimas.
- Interneto svetainių komentarai.
- Interneto portalai.
- Anonimiškumas internete.
- Smurtinio pobūdžio tekstai.
- Lietuvių kalba.

Pagal šias potemes buvo ieškoma literatūros šaltinių. Dalis potemių buvo identifikuotos kaip pagrindinės. Pagrindinės mokslo darbo potemės yra:

- Sentimentų analizė.
- Teksto klasifikavimas.
- Natūralios kalbos apdorojimas.
- Interneto svetainių komentarai.

Kiekvienai pagrindinei potemei paskirtas atskiras poskyris, sudarytas iš bendros ta poteme atliktų tyrimų apžvalgos, kurios metu išrenkami darbui aktualūs pastebėjimai. Šie pastebėjimai skirstomi į punktus pagal analizuojamą potemės sritį.

### 1.1. Sentimentų analizė

Kadangi viena iš kertinių tiriamojo mokslo darbo technologijų yra sentimentų analizė, yra svarbu identifikuoti kokios metodologijos, parametrai, silpnybės bei stiprybės jau yra aprašytos mokslinėje literatūroje.

#### 1.1.1. Mašininis mokymasis

Sentimentų analizė dažnai atliekama įvairiomis mašininio mokymosi technologijomis. 2016 metais publikuotas bei 75+ darbuose cituojamas [Goo20a] mokslinis straipsnis aprašo ir palygina šias skirtingas technologijas bei jų efektyvumą [DSG16]. Iš straipsnyje aprašomų sentimentų analizės mašininio mokymosi modelių, vienas jų yra naivus Bajeso metodas, kuris taip pat



naudojamas kaip bendro pobūdžio teksto klasifikatorius (pvz. atpažįstant brukalą elektroninio pašto laiškuose [Sch03]). Ši metodika taip pat yra matoma 2016 metais publikuotame ir 1790+ darbų cituojamame [Goo20b] moksliniame straipsnyje, kuriame su pristatomu FastText teksto klasifikatoriumi atliekami ir sentimentų analizės, ir pavadinimų bei antraščių (t.y. teksto) klasifikavimo bandymai [JGB+16].

Nors šie du straipsniai atliko anglų kalbos tekstų sentimentų analizę, ta pati metodika pritaikoma ir lietuvių kalbos tekstams. Tai galima matyti 2019 metais publikuotame moksliniame straipsnyje, kuris aprašo lietuviškų interneto komentarų sentimentų analizės procesą bei rezultatus šią analizę atliekant tradiciniais mašininio mokymosi bei giliojo mokymosi metodais [KDW19]. Tyrime naudojami tradicinio mašininio mokymosi metodai yra atraminių vektorių klasifikatorius bei daugialypis naivus Bajeso klasifikatorius. Šiems klasifikatoriams buvo pateikti leksinio, morfologinio bei simbolio lygio požymiai. Nors tyrimo rezultatai parodė, jog ir tradiciniai, ir giliojo mokymosi modeliai pasiekė gerus rezultatus, geriausius rezultatus dirbant su visa duomenų aibe pasiekė daugialypis Bajeso klasifikatorius (taip pat paminėtas 2016 metų sentimentų analizės metodus lyginančiame moksliniame darbe [DSG16]) su pakeistais jaustukais bei sugražintais diakritiniais ženklais. Šis mokslinis straipsnis nėra labai plačiai cituojamas lyginant su panašiais straipsniais atliekančiais anglų kalbos tekstų sentimentų analizę, tačiau jis yra vienas iš dažniau cituojamų darbų sentimentų analizės lietuvių kalba srityje [Goo20c].

### **1.1.2. Giliojo mokymosi technologijos**

Naivus Bajeso klasifikatorius nėra vienintelis mašininio mokymosi algoritmas naudojamas atliekant sentimentų analizę. 2018 metais publikuotame bei plačiai cituojamame [Goo20d] moksliniame straipsnyje pateikiami giliojo mokymosi pagrįstų sentimentų analizės technologijų bandymų rezultatai [YHP+18]. Bandymams atlikti buvo naudojamas „Stanford Sentiment Treebank“ duomenų rinkinys jo originalia bei binarine forma. Iš rezultatų galima matyti, jog tikslumas yra žymiai didesnis (skirtingų technologijų tikslumo skirtumai svyruoja tarp ~30% bei ~40%) naudojant binarinę duomenų rinkinio formą. Nors tikslumas naudojant binarinę duomenų rinkinio formą ganėtinai aukštas (+85%), tik vienas iš testuotų sprendimų pasiekė tikslumą aukštesnį nei 90%. Straipsnyje taip pat aprašomi ir rekursiniai neuroniniai tinklai bei paminimas 2013 metais publikuotas Socher et al. straipsnis [SPW+13], kuriame pateikiamas frazės lygio (t.y. leidžiantis identifikuoti specifinių frazių emocijas) sentimentų analizės modelis, kuris pagrįstas šia technologija. Mašininio mokymosi technologijų aukštas tikslumas atliekant sentimentų analizę yra

minimas ir 2016 metais publikuotame straipsnyje, kuriame aprašomi ir lyginami sentimentų analizės metodai [DSG16].

Giliojo mokymosi technologijos taip pat išbandytos atliekant lietuviškų tekstų sentimentų analizę 2019 metais publikuotame moksliniame darbe [KDW19]. Iš giliojo mokymosi metodų buvo pasirinkta ilgos trumpalaikės atminties neuroninio tinklo modelio bei konvoliucinio neuroninio tinklo technologijos. Su šiomis technologijomis buvo naudojami FastText bei Word2vec algoritmų pateikiami žodžių įterpimai. Nors dirbant su visa duomenų aibe šie metodai pasirodė prasčiau nei tradiciniai mašininio mokymosi metodai, darbe buvo identifikuota, jog jie geriau veikia su mažomis duomenų aibėmis. Dėl šios priežasties tikėtina, jog giliojo mokymosi sistemos gali tikti kaip pagalbinė priemonė renkant ar filtruojant pradinę anoniminių komentarų aibę kitų mašininio mokymosi algoritmų apmokymui.

### **1.1.3. Taisyklėmis bei žodynu pagrįstos sistemos**

Gerų rezultatų atliekant sentimentų analizę taip pat galima pasiekti taisyklėmis bei žodynu pagrįstomis sistemomis. Nors 2016 metų sentimentų analizės metodus lyginančiame moksliniame straipsnyje sentimentų analizės metodai priklausantys mašininio mokymosi kategorijai apibūdinami kaip aukšto klasifikavimo tikslumo, taisyklėmis pagrįstų metodų tikslumas bandymų metu buvo virš 85% [DSG16] (t.y. nedaug atsilieka nuo 2018 metais publikuotame giliojo mokymosi technologijas apžvelgiančiame straipsnyje ištestuotų mašininio mokymosi algoritmų [YHP+18]). Straipsnyje rašoma jog, šie metodai taip pat nereikalauja duomenų žymėjimo bei neturi algoritmo mokymo fazės, tačiau turi ganėtinai didelį trūkumą - reikalauja galimai ne visiems prieinamų leksinių priemonių bei resursų. Tyrimo metu gautas tikslumas taip pat nėra pasiekiamas be pastangų - tikslumas bei efektyvumas taisyklėmis pagrįstoje sistemoje reikalauja sistemos kūrėjo realizuoti ir / ar parinkti užduočiai tinkamą taisyklių aibę.

Nors vien tik taisyklėmis pagrįstos anglų kalbos teksto sentimentų analizės sistemos gali pasiekti aukštą tikslumą, gali kilti problemų toki patį tikslumą norint pasiekti atliekant lietuviškų tekstų sentimentų analizę. 2019 metų moksliniame darbe minima, jog lietuvių kalbos leksinių resursų trūkumas trukdo naudoti žodynu pagrįstus sentimentų analizės metodus [KDW19]. Net ir turint tokius resursus gali kilti problemų dirbant su nenorminiais tekstais (dėl diakritinių ženklų).

### **1.1.4. Hibridinės sistemos**

Taisyklėmis pagrįsti metodai taip pat gali būti naudojami kaip dalys platesnės hibridinės sentimentų analizės sistemos. Vienas iš tokių darbų pavyzdžių yra 2017 metais publikuotas bei 100+ darbų cituojamas [Goo20e] mokslinis straipsnis, kurio metu buvo atlikta socialinio tinklo Twitter

įrašų sentimentų analizė naudojant hibridinį metodą paremtą gegutės paieškos (angl. „cuckoo search“) algoritmu bei k-vidurkių klasterizavimo mašininio mokymosi technologija [PRS17]. Tyrimo išvadose identifikuota, jog k-vidurkių klasterizavimas pagerino gegutės paieška pagrįstos sistemos rezultatus.

## **1.2. Teksto klasifikavimas**

Norint identifikuoti specifinio pobūdžio tekstus reikia pasitelkti ne tik sentimentų analizę, bet ir panaudoti teksto klasifikavimo technologijas išfiltruoti sentimentą atitinkančius, bet ne smurtinio pobūdžio tekstus. Kadangi teksto klasifikavimo sritį sudaro skirtingos technologijos bei algoritmai, šiame poskyryje yra analizuojama literatūra publikuota šia tema.

### **1.2.1. Mašininis mokymasis**

Kaip ir sentimentų analizėje, bendro pobūdžio teksto klasifikavimas dažnai atliekamas mašininio mokymosi technologijomis [DZM+15, LD16, JGB+16, DWM+17]. Pavyzdžiui, 2015 metais publikuotas bei 280+ mokslinių darbų cituojamas straipsnis [Goo20f] aprašo autorių sukurtą neuroninės kalbos modelį skirtą atpažinti neapykantą skatinantį teksto turinį [DZM+15]. Straipsnyje aprašomas algoritmas susideda iš dviejų žingsnių: komentarų ir žodžių modeliavimo naudojant neuroninės kalbos modelį bei binarinio klasifikatoriaus naudojimo suskirstyti komentarus į tinkamus bei netinkamus. Mokslinio darbo gale yra atliekama sukurto algoritmo empirinė analizė, kurios metu žodžių maišu pagrįstų teksto klasifikavimo algoritmų tikslumas yra lyginamas su sukurto algoritmo klasifikavimo tikslumu. Sukurtas algoritmas pasiekia ~80% tikslumą, o iš kitų 2 testuotų algoritmų aukščiausias tikslumas yra 78,89%.

Neapykantą skatinančio turinio (į kurį patenka ir dalis smurtinio pobūdžio turinio) atpažinimo užduotims panašų ar net aukštesnį tikslumą pasiekia ir kiti mašininio mokymosi algoritmai. 2017 metais publikuotame bei plačiai cituojamame [Goo20g] moksliniame straipsnyje aprašomas neapykantą kurstančio turinio atpažinimo modelio kūrimas, kurio metu stengiamasi išspręsti užgaulaus bei neapykantą kurstančio turinio panašumo problemą [DWM+17]. Autoriams atlikus bandymus su skirtingais metodais buvo pasirinktas loginės regresijos algoritmas formuojant modelį. Šis modelis pasiekė 91% atpažinimo tikslumą.

Be specifinių algoritmų, tam tikriems modeliams taip pat galima pasitelkti priešiško apmokymo metodiką norint pagerinti modelio kokybę. Tai galima matyti iš 2016 metais publikuoto bei 240+ moksliniuose darbuose cituojamo [Goo20h] mokslinio straipsnio, kuris aprašo darbo metu sukurtą priešiško mokymo metodą teksto klasifikavimo sistemoms [MDG16]. Įvade yra minimas priešiško modelio mokymo pagrindinis privalumas - geresni rezultatai atpažįstant ne tik koreguotus

priešiškus duomenis, bet ir realius duomenis. Atliekant bandymus buvo naudotas ilgos trumpalaikės atminties dirbtinio neuroninio tinklo modelis. Naudojant priešišką mokymą (bei virtualią priešiško mokymo variaciją) klaidingų IMDB interneto svetainės atsiliepimų apie filmus spėjimų procentas buvo sumažintas nuo 7.39% iki 5.91%. Be sumažinto klaidų procento, taip pat buvo pastebėta, jog pagerėjo žodžių įterpimų modelyje kokybė.

Panašūs rezultatai matomi ir apmokant teksto klasifikavimo modelį, kuris naudojamas kelioms užduotims (pvz. sentimentų analizei bei smurtinio turinio atpažinimui). 2017 metais publikuotas bei 220+ mokslinių darbų cituojamas [Goo20i] mokslinis straipsnis aprašo priešiško kelias užduotis aprėpiančio teksto klasifikavimo modelio apmokymo tyrimo rezultatus [LQH17]. Straipsnio įvade yra paminima vienas iš pagrindinių kelias užduotis aprėpiančio teksto klasifikavimo modelio trūkumų - privačių bei bendrų savybių maišymasis. Bandant spręsti šią problemą darbe naudojami ortogonalumo ribojimai bei priešiškas modelio apmokymas. Šie metodai yra taikomi kelioms užduotims pritaikyto ilgos trumpalaikės atminties neuroninio tinklo modeliui. Atlikus bandymus rasta, jog kelių užduočių modelis su priešišku apmokymu sugebėjo pasiekti 4,1% didesnę vidutinę tikslumo pagerėjimą lyginant su vienos užduoties modeliais, o paprastas kelių užduočių modelis – tik 1%. Tai rodo, jog priešiškas apmokymas pagerina kelių užduočių modelių tikslumą klasifikuojant tekstą.

Nors tyrimų rezultatai perspektyvūs, paprastesni mašininiai mokymusi pagrįsti algoritmai neretai turi didelių trūkumų. Pavyzdžiui, 2015 metais publikuotame straipsnyje paminima, jog autorių analizuotuose mokslinės literatūros šaltiniuose, kuriuose rašoma apie neapykantą skatinančio teksto turinio atpažinimą, yra minimi žodžių maišo (angl. „bag-of-words“) metodų apribojimai [DZM+15]. Apie žodžių maišo metodo trūkumus užsimenama ir 2017 metų moksliniame darbe, kuriame yra minima, jog žodynu pagrįsti metodai naudojami neapykantą skatinančio turinio atpažinimui neretai turi ganėtinai žemą tikslumą [DWM+17]. Viena iš priežasčių - negebėjimas atskirti tarp užgaulaus teksto bei tarp tikro neapykantos skatinimo. Skirtingose kultūrinėse terpėse neapykantą skatinančiam žodynui priskiriami žodžiai gali būti naudojami tik kaip užgaulios remarkos, neskirtos pažeminti, įžeisti ir / ar išniekinti žmogų dėl jo lyties, rasės, religijos ar seksualinės orientacijos. Autoriams analizuojant prieš tai atliktus tyrimus, identifikuota, jog žodžių maišo metodai atpažįsta didelę dalį duomenų aibėse esančių neapykantą skatinančių tekstų, tačiau taip pat dažnai neteisingai klasifikuoja paprastas žinutes kaip netinkamas dėl jau minėtų žodžių.

### **1.2.2. Giliojo mokymosi technologijos**

Norint pasiekti aukštesnį tikslumą bendro pobūdžio teksto klasifikavimo sistemose, kaip ir sentimentų analizėje, yra aktyviai tiriamos giliojo mokymosi sistemos. Vienas iš tokių tyrimų yra 2017 metais publikuotas bei 300+ darbų cituojamas [Goo20j] mokslinis straipsnis, kuris aprašo tyrimo metu vykdytus skirtingų giliojo mokymosi algoritmų testus bandant atpažinti neapykantą kurstantį turinį socialiniame tinkle Twitter [BGG+17]. Darbe atliekamuose bandymuose yra testuojami konvoliuciniai neuroniniai tinklai bei ilgos trumpalaikės atminties modeliai bandant klasifikuoti neapykantą skatinantį turinį. Be klasifikavimo vien giliaisiais neuroniniais tinklais, taip pat bandoma juos naudoti kartu su atraminių vektorių klasifikatoriumi bei gradiento didinimo sprendimų medžiu (naudojant giliųjų neuroninių tinklų žodžių įterpimus kaip klasifikatorių savybes). Lyginant tyrimo rezultatus, bandymai su giliaisiais neuroniniais tinklais pasirodė geriau nei bandymai su parinktais matematiniais algoritmais. Dar geresni rezultatai pasiekti su hibridinėmis sistemomis (naudojančiomis ir giliuosius neuroninius tinklus, ir papildomus klasifikatorius) iš kurių geriausiai pasirodė ilgos trumpalaikės atminties modelis (naudojant atsitiktinį inicializavimą) su gradiento didinimo sprendimų medžiu.

Giliojo mokymosi technologijos, kaip ir su sentimentų analize, pasižymi už tradicinius mašininio mokymosi metodus aukštesniu tikslumu apribojus duomenų, kuriais apmokomas modelis, kiekį. Vienas šių privalumų identifikavusių tyrimų yra 2016 metais publikuotas bei 250+ darbų cituojamas [Goo20k] mokslinis darbas, kuris aprašo teksto klasifikavimo modelį fokusuotą į trumpų vienas po kito einančių tekstų klasifikavimą [LD16]. Kuriant klasifikavimo modelį yra naudojami dviejų tipų dirbtiniai neuroniniai tinklai: rekurentiniai bei konvoliuciniai (specifiškai, ilgos trumpalaikės atminties modelio tipo). Atliekant modelių parametrų parinkimą, buvo atliekami bandymai kaitaliojant po vieną parametą ir tikrinant rezultatus. Atlikus bandymus gauta, jog du sukurti modeliai pasirodė geriau už visus kitus testuotus metodus. Šie rezultatai matomi atlikus bandymus su 3 skirtingomis duomenų aibėmis.

Gebėjimas apribojus duomenų kiekį išgauti už tradicinius mašininio mokymosi metodus geresnius rezultatus galima egzistuoja dirbant ir su lietuvių kalbos tekstais – 2019 metų straipsnyje identifiкуotas giliojo mokymosi technologijų pranašumas atliekant sentimentų analizę [KDW19] galėtų būti pritaikomas ir bendro pobūdžio teksto klasifikavimui, nes sentimentų analizė priklauso platesnei teksto klasifikavimo sričiai ir neretai naudoja tuos pačius įrankius.

Nors giliojo mokymosi technologijos remiasi dideliais klasifikavimo modelių sluoksnių skaičiais, per didelis sluoksnių kiekis daliai technologijų gali pakenkti. Vienas tokių atvejų pavyzdžių yra aprašytas 2016 metais publikuotame bei 460+ mokslinių darbų cituojamame [Goo20l]

moksliniame straipsnyje, kuriame yra apibūdinamas teksto klasifikavimo užduotims skirtas gilus konvoliucinio neuroninio tinklo modelis [CSB+16]. Straipsnyje kuriamas bei tiriamas mašininio mokymosi modelis yra didelio gilumo (nuo 9 iki 29 konvoliucinių sluoksnių) konvoliucinis neuroninis tinklas. Atliekant bandymus su skirtingais sluoksnių kiekiais buvo nustatyta, jog net ir su 9 konvoliuciniais sluoksniais jau yra gaunami geresni rezultatai su didelėmis duomenų aibėmis (lyginant su mažiau giliais konvoliuciniais neuroniniais tinklais iš kitų tyrimų). Didinant modelio gylį iki 29 konvoliucinių sluoksnių pastebimas didėjantis klasifikavimo tikslumas, tačiau didinant modelio gilumą virš 29 sluoksnių tikslumas krito.

Giliojo mokymosi technologijos taip pat nėra visada geresnės už tradicines mašininio mokymosi sistemas, ypač apmokymo bei klasifikavimo greičiu. FastText algoritmą aprašančiame moksliniame darbe galima matyti, jog bandymuose FastText gebėjimas tiksliai atpažinti tekstą yra panašus į kitus testuotus giliojo mokymosi algoritmus, tačiau šio įrankio greitis žymiai didesnis už testuotus įrankius [JGB+16]. Lyginant su kitais testuotais algoritmais, pagreitėjimas svyruoja nuo dešimt kartų apmokant sentimentų analizės bandymui iki kelių šimtų kartų klasifikuojant pavadinimus ir antraštes.

### **1.3. Natūralios kalbos apdorojimas**

Sentimentų analizei bei bendro pobūdžio teksto klasifikavimui neretai reikalinga struktūrizuota teksto reprezentacija. Šis nestruktūrizuoto turinio pavertimas į algoritmams suprantamus duomenis atliekamas natūralios kalbos apdorojimo įrankiais bei algoritmais, kurie yra analizuojami šiame poskyryje.

#### **1.3.1. Giliojo mokymosi technologijos**

Kaip ir sentimentų analizės bei bendro pobūdžio teksto klasifikavime, giliojo mokymosi technologijos didelėje dalyje natūralios kalbos apdorojimo užduočių sugeba pasiekti geresnius rezultatus už negilius mašininio mokymosi sprendimus. Apie šį pranašumą yra rašoma 2018 metais publikuotame moksliniame straipsnyje [YHP+18]. Darbo autoriai straipsnyje pateikė priežastį kodėl buvo pasirinkta apžvelgti giliojo mokymosi natūralios kalbos apdorojimo technologijas, o ne atlikti bendrą šių technologijų apžvalgą - net ir paprasti giliojo mokymosi modeliai geriau atlieka dalį natūralios kalbos apdorojimo užduočių (pvz. semantinį vaidmenų žymėjimą bei kalbos dalies žymėjimą) nei negilūs mašininio mokymosi modeliai. Darbe taip pat pateikiama skirtingas natūralios kalbos apdorojimo užduotis sprendžiančių giliojo mokymosi technologijų evoliucija ir istorija iš kurios galima matyti, jog didelėje dalyje natūralios kalbos apdorojimo sričių yra judama (publikuojama literatūra, atliekamais tyrimais, sukuriamomis sistemomis) ties giliojo mokymosi

sprendimais. Konvoliuciniai neuroniniai tinklai buvo identifikuoti kaip viena iš efektyviausių technologijų išgaunant duomenų požymius, kurie vėliau yra naudojami atlikti įvairias natūralios kalbos apdorojimo užduotis (į kurių aibę patenka ir sentimentų analizė). Kita dirbtinių neuroninių tinklų klasė, kuri gali praversti modeliuojant kalbą (t.y. identifikuojant frazių kontekstą) yra rekurentiniai neuroniniai tinklai.

Panašias tendencijas galima išvelgti ir lietuvių kalbos turinio natūralios kalbos apdorojimo srityje. 2018 metais publikuotame moksliniame straipsnyje aprašoma lietuvių kalbos turinio žodžių įterpimų dirbtiniams neuroniniams tinklams formavimas [KD18]. Atliekant žodžių įterpimų modelio formavimą buvo naudojama DeepLearning4j giliojo mokymosi programinio kodo biblioteka bei Word2vec algoritmas su skirtingais apmokymo metodais bei parametrais. Vienas iš žodžių įterpimo modelių buvo paimtas iš Wikipedia.org internetinės svetainės pateikiamų paruoštų modelių, tačiau jame rasta perkėlimo į kitą eilutę ženklų (pvz. brūkšnių) bei diakritinių ženklų, neegzistuojančių lietuvių kalboje. Iš testuotų metodų, geriausias rezultatų pasiekė tęstiniu žodžių maišu pagrįsti Word2vec modeliai. Autoriams išanalizavus modelio padarytas klaidas buvo rasta, jog daug klaidingų spėjimų buvo teisingų žodžių išvestinės formos. Nors šis straipsnis nėra labai plačiai cituojamas, jis yra vienas iš plačiau cituojamų darbų aprėpiančių mašininio mokymosi, natūralios kalbos apdorojimo bei lietuvių kalbos sritis [Goo20m].

### **1.3.2. Taisyklėmis pagrįstos sistemos**

Giliojo mokymosi technologijos gali praversti atliekant sudėtingesnes natūralios kalbos apdorojimo užduotis, tačiau paprastos teksto apdorojimo užduotys vis dar sprendžiamos taisyklėmis pagrįstomis sistemomis. Pavyzdžiui, 2017 metų mokslinio darbo tyrimo aprašo pradžioje yra paminima, jog pirma buvo atliktas Twitter pritaikytas nereikalingų teksto dalių (pvz. URL bei vartotojo vardų) panaikinimas [PRS17]. Be šio išvalymo taip pat buvo taisomi smulkūs netikslumai (pvz. pasikartojantys tarpai tarp žodžių ar žodžiai su kelis kartus pakartojamomis raidėmis).

### **1.3.3. Žodynu pagrįstos sistemos**

Nors žodynu pagrįstos sistemos turi privalumų [DSG16], jos nėra plačiai naudojamos natūralios kalbos apdorojimui, neretai dėl reikalingų leksinių resursų trūkumo ar tokio pobūdžio metodų nelankstumo. 2017 metais publikuotame bei 290+ mokslinių darbų cituojamame [Goo20n] moksliniame straipsnyje yra pateikiama neapykantą skatinančių tekstų atpažinimo metodų bei modelių apžvalga [SW17]. Darbe tiriant žodyno naudojimą atpažinimo sistemose rasta, jog leksikos resursų neapykantos kurstyto turinio klasifikavimui sritis nėra plačiai iširta. Leksikos resursai šioje

srityje, anot straipsnio autorių, dažniau naudojami kaip pagalbinė priemonė hibridinei sistemai, o ne kaip pagrindinis įrankis atpažinimui / klasifikavimui.

Natūralios kalbos apdorojimo lietuvių kalbos tekstų srityje situacija nėra pati blogiausia – egzistuoja prieinami leksiniai resursai norminei kalbai apdoroti. Pavyzdys minėtų resursų yra 2016 metais publikuotame moksliniame straipsnyje aprašoma Lietuvių kalbos sintaksinės ir semantinės analizės informacinės sistemos (LKSSAIS) infrastruktūra [VUA+16]. Darbo įvade paminima LKSSAIS sukūrimo priežastys - nepakankami natūralios kalbos apdorojimo resursai lietuvių kalbai bei lietuvių kalbos aukštas sudėtingumas lyginant su anglų kalba. Ši sistema buvo kuriama remiantis tarptautiniais standartais tokių infrastruktūrų formavimui. LKSSAIS kaupia tekstinio turinio lietuvių kalba resursus bei pateikia natūralios kalbos apdorojimo įrankius (pvz. sintaksės apdorojimo, rašybos tikrinimo, leksinio apdorojimo). Įrankiai pateikiami API bei programos su grafine vartotojo sąsaja formomis. Nors straipsnis nėra labai plačiai cituojamas, jis yra vienas iš dažniau cituojamų darbų natūralios lietuvių kalbos apdorojimo srityje [Goo20o].

Nors ir natūralios kalbos apdorojimo resursų lietuvių kalbai yra, šių resursų naudingumas ribotas dėl kalbos sudėtingumo, ypač dirbant su nenorminės kalbos tekstais. Lietuvių kalbos sentimentų analizės metodus apžvelgiančiame 2019 metų moksliniame darbe aprašant analizuojamus duomenis paminima, jog lietuvių kalbos žodynas yra žymiai platesnis nei anglų kalbos [KDW19]. Be šio skirtumo taip pat aprašomas lietuvių kalbos žodžių sudėtingumas variacijų atžvilgiu (t.y. tas pats žodis gali būti užrašytas skirtingai priklausant nuo konteksto). Taip pat išskiriama tai, kad lietuvių kalba turi diakritinius ženklus bei kad nenorminė kalba turi intarpų iš užsienio kalbų.

## **1.4. Interneto svetainių komentarai**

Interneto svetainių komentarai, kaip ir bet kuri kita teksto publikacijos forma, turi savo specifinius požymius, kurie gali praversti bandant atpažinti tam tikrą tokių tekstų pogrupį. Šie požymiai ir susijusios metodikos yra analizuojami šiame poskyryje.

### **1.4.1. Bendri požymiai**

Interneto komentuose, kaip ir paprastuose tekstuose, galima rasti sarkazmo bei ironijos, kurie gali iškreipti sentimentų analizės rezultatus. 2017 metais publikuotame moksliniame darbe išvalius duomenis pradėtas požymių išgavimo procesas, kurio viena iš problemų apibrėžta kaip ironijos bei sarkazmo atpažinimas [PRS17]. Ši problema sprendžiama pasitelkiant įvairius kalbą (pvz. hiperbolės identifikavimas) bei nežodinį tekstą (pvz. susiejimas „emoji“ su specifinėmis emocijomis) analizuojančius metodus.



Nors internete publikuoti tekstai gali būti netaisyklingi, egzistuoja metodų, kurie gali padėti dirbti su tokio pobūdžio turiniu. 2017 metų moksliniame straipsnyje simbolio lygio požymiai minimi kaip galimas sprendimas dažnai pasitaikančiam netaisyklingų žodžių atpažinimui (pvz. su gramatinėmis klaidomis arba pakeitus raides į skaičius ar kitokius simbolius dėl stilistinių sumetimų) [SW17].

#### **1.4.2. Smurtinio pobūdžio tekstai**

Smurtinio pobūdžio turinį ne visada lengva atpažinti, ypač kai jo autoriai žino, jog automatizuotos sistemos nuolatos peržvelgia jų publikuojamą turinį. 2015 metais publikuotame darbe minimi žodžių maišo metodų apribojimai, anot autorių, ypač pastebimi bandant atpažinti neapykantą kurstantį turinį, nes tokį turinį publikuojantys asmenys neretai stengiasi maskuoti savo komentarus pakeisdami tam tikrus žodžius ar tam tikrų žodžių raides [DZM+15].

Vienas iš galimų sprendimų bandant atpažinti smurtinio pobūdžio turinį yra bandyti atmesti kuo daugiau šiai kategorijai nepriklausančių komentarų. 2017 metų straipsnyje analizuojant klasifikatoriaus rezultatus buvo identifikuota, jog teigiamo sentimentu bei aukšto skaitomumo (apskaičiuoto pagal algoritmą) tekstai yra labiau linkę nepriklausyti neapykantą skatinančių tekstų kategorijai, net jeigu juose randama neapykantą skatinantiems tekstams būdingų žodžių [DWM+17]. Būtent dėl šių žodžių klasifikatorius neteisingai tyrime klasifikavo priimtinius tekstus kaip neapykantą skatinančius.

Nors moksliniuose darbuose yra identifikuoti įvairūs neapykantą kurstančio turinio (kurio vienas iš pogrupių yra smurtinis turinys) požymiai bei jų atpažinimo metodikos, jų kiekis bei duomenys apie jų tikslumą yra riboti. 2017 metų moksliniame darbe, kuris apžvelgė neapykantą skatinančio turinio atpažinimo metodus, rašoma, jog didelė dalis tyrėjų duomenis savo ar kitų algoritmų testavimui surenka patys [SW17]. Šie surinkti duomenys neretai yra ir iš skirtingų interneto svetainių su savo ypatybėmis. Tai nulemia ir neapykantą kurstančio turinio atpažinimo metodologiją. Autoriai taip pat išsako nuomonę, jog praverstų duomenų aibės etalonas, kuriuo būtų galima tikrinti ir lyginti skirtingus algoritmus. Darbe taip pat minima, jog neskaitant vokiečių ir olandų kalbų, straipsnio autoriams nepavyko rasti išsamesnių neapykantą skatinančio turinio atpažinimo tyrimų ne anglų kalbos tekstams.

## 2. Nagrinėjami duomenys

Prieš pradėdant atlikti eksperimentus su skirtingais smurtinio pobūdžio žinučių identifikavimo sistemų prototipais reikia pasirinkti iš kur bus renkami duomenys šiems prototipams bei koks šių duomenų šaltinių pobūdis. Tyrimo metu naudotus duomenų šaltinius galima suskirstyti į 2 kategorijas: interneto portalų anoniminės nuomonės bei sentimentų analizės duomenys. Šiame skyriuje yra aprašomos šių duomenų šaltinių kategorijų ypatybės.

### 2.1. Interneto portalų anoniminių nuomonės

Interneto portalų komentarai buvo renkami tyrimo metu realizuotais automatiniais turinio surinkimo įrankiais ir išsaugomi reliacinės duomenų bazės lentelėje. Išsaugant komentarą duomenų bazėje įrašomi šie jo parametrai:

- Komentaro autoriaus vardas ar slapyvardis.
- Komentaro tekstas.
- Komentaro teigiamų bei neigiamų įvertinimų skaičiai (išsaugomi atskirai).
- Nuoroda į interneto portalo straipsnį, kuriame rastas komentaras.
- Ar komentaro autorius yra registruotas portalo vartotojas. Autorius laikomas registruotu tada kai komentaras paliekamas pasitelkiant interneto portalo svetainės funkcija, kuri reikalauja prisijungti (pvz. įvedant teisingą slapyvardį ir slaptažodį) prie portalo ar kitos internetinės svetainės sistemos sąskaitos.

Dėl į smurtinius ir nesmurtinius suskirstytų iš portalų surinktų neformalios lietuvių kalbos komentarų rinkinių bei tyrimui prieinamų žmogiškųjų ir finansinių resursų trūkumo, komentarai į smurtinius ir nesmurtinius buvo skirstomi (t.y. žymimi) ranka tyrimo autoriaus. Smurtiniams komentarams buvo priskiriami visi komentarai, kurių komentaro autoriaus vardo ar slapyvardžio tekste ir / ar komentaro tekste rasta lietuvių ir / ar anglų kalba turinys išreiškiantis teigiamą emociją apie neteisėtus fizinio smurto veiksmus. Identifikavus neteisėto fizinio smurto veiksmus esančius Lietuvos Respublikos baudžiamajame kodekse bei susiejus šiuos veiksmus su surinktuose komentaruose pastebimomis teigiamų emocijų išraiškų formomis gautos bendro smurtinio turinio apibrėžimo subkategorijos [Lie20]. Šios subkategorijos sudarytos iš šių išraiškos formų:

1. Išreiškiamas noras, siūlymas, skatinimas, rekomendavimas, grasinimas, tikėjimasis, linkėjimas ir / ar ketinimas:

- 1.1. fiziškai sužaloti, suluošinti ir / ar nužudyti kitą asmenį ar asmenų grupę,

- 1.2. apriboti kito asmens ar asmenų grupės laisvę neteisėtomis priemonėmis (pvz. priverstinai uždaryti psichiatrijos ligoninėje).
2. Siūloma, skatinama, rekomenduojama, linkima ir / ar tikimasi, jog kitas asmuo save sužalos ar nusižudys.

Nors prototipų verifikavimas ir validavimas buvo atliktas pasitelkiant ranka tyrimo autoriaus surinktais duomenimis, realioje smurtinių komentarų analizės sistemoje mokomosios komentarų aibės suskirstymas į smurtinius ir nesmurtinius turėtų būti atliekamas specialisto turinčio atitinkamą kalbos kompiuterinės analizės žinių.

Ieškant lietuviškų interneto portalų, kuriuose yra galimybė publikuoti komentarus pagrindinis iškeltas kriterijus - aukštas vidutinis komentarų per straipsnį skaičius (lyginant su kitais lietuviškais interneto portalais). Šis kriterijus iškeltas norint surinkti kuo įmanomą platesnio pobūdžio komentarų. Pagal šį kriterijų parinkti 5 interneto portalai:

1. Delfi.lt [Del20b].
  - 1.1. Delfi.lt portalo skaitytojai gali įvertinti komentarus „reakcijomis“ - 7 smulkiais paveikslėliais reprezentuojančiais skirtingas emocijas. Be kitų visiems komentarams išsaugomų parametru, Delfi.lt komentarams taip pat išsaugomi šie „reakcijų“ skaičiai.
  - 1.2. Teigiamų įvertinimų skaičius skaičiuojamas sumuojant „Like“ ir „Love“ „reakcijų“ skaičius, o neigiamų įvertinimų skaičius atitinka „Dislike“ „reakcijų“ skaičių.
  - 1.3. Portale leidžiama palikti komentarus ir kaip registruotu vartotoju, ir anonimiškai [Del20a].
  - 1.4. Viso iš Delfi.lt surinkti ir sužymėti 5524 komentarai.
2. 15min.lt [Min20b].
  - 2.1. Portale komentarus galima palikti tik užsiregistravus [Min20a].
  - 2.2. 15min.lt komentarams teigiamų ir neigiamų komentaro įvertinimų skaičiai nustatomi pagal vieną šalia komentaro pateiktą įvertinimą. Jei šis komentaro įvertinimų skaičius yra teigiamas – teigiamo įvertinimo parametras lygus šiam skaičiui, o neigiamas įvertinimo parametras lygus 0. Jei įvertinimų skaičius neigiamas – neigiamo įvertinimo parametras lygus šio skaičiaus moduliui, o teigiamas įvertinimo parametras lygus 0.
  - 2.3. Viso iš 15min.lt surinkti ir sužymėti 187 komentarai.
3. Lrytas.lt [Lry20a].
  - 3.1. Portale komentarai paliekami tik neregistruotų vartotojų [Lry20b].
  - 3.2. Viso iš Lrytas.lt surinkti ir sužymėti 1483 komentarai.
4. Diena.lt [Die20a].

- 4.1. Portale komentarus įmanoma palikti neužsiregistravus [Die20b]. Nors portale įmanoma užregistruoti sąskaitą [Die20c], komentarų puslapių HTML kode nerasta žymių identifikuojančių ar komentaro autorius yra registruotas vartotojas. Dėl šios priežasties visi komentarai žymimi kaip neregistruotų vartotojų.
- 4.2. Viso iš Diena.lt surinkti ir sužymėti 280 komentarai.
5. Respublika.lt [Res20a].
  - 5.1. Komentarai portale paliekami anonimiškai (t.y. neužsiregistravus) [Res20b].
  - 5.2. Viso iš Respublika.lt surinkti ir sužymėti 1066 komentarų.

Iš viso surinkti ir sužymėti 8540 komentarų, iš kurių 734 pažymėti kaip smurtiniai.

## **2.2. Sentimentų analizės duomenys**

Vienas iš kuriamų komentarų teksto papildymo metodų yra komentaro sentimentų žymės įterpimas į komentaro tekstą. Šis metodas reikalauja sentimentų analizės įrankio. Sentimentų analizės užduočiai atlikti tyrime naudojami mašininio mokymosi algoritmai, kurie pasitelkdami sužymėtais duomenimis gali bandyti nuspėti algoritmui nematyto teksto sentimentą. Tyrimo metu bandoma atpažinti smurtinį turinį neformalios lietuvių kalbos tekstuose surinktuose iš internetinių svetainių, tačiau šiuose tekstuose nėra kategorine forma išreiškiamas sentimentas. Dėl šios priežasties apmokant sentimentų analizės įrankį buvo nuspręsta naudoti panašaus, tačiau ne to pačio pobūdžio duomenų šaltinį – internetinius atsiliepimus apie prekes, paslaugas ir / ar organizacijas. Šio sentimentų analizės duomenų šaltinio pagrindinis privalumas - duomenų (t.y. atsiliepimų tekstų) sentimentai yra sužymėti pačių šių tekstų autorių. Ši savybė leidžia išvengti subjektyvių vertinimų bandant identifikuoti tam tikro teksto sentimentą bei palengvina sentimentų analizei naudojamų duomenų rinkimą dideliu mastu.

Atsiliepimai buvo renkami tyrimo metu realizuotais automatiniiais internetinių svetainių turinio surinkimo bei formatavimo įrankiais (angl. „scraping“) ir išsaugomi reliacinės duomenų bazės lentelėje. Išsaugant atsiliepimą duomenų bazėje įrašomi šie parametrai:

1. Atsiliepimo autoriaus vardas ar slapyvardis. Puslapiuose, kuriuose informacija apie autorių neprieinama, šis parametras pakeičiamas į šalia esantį su atsiliepimu susijusį trumpą tekstą.
2. Atsiliepimo tekstas.
3. Kitų vartotojų pačio atsiliepimo teigiamų bei neigiamų įvertinimų skaičiai (išsaugomi atskirai). Jei svetainėje nėra galimybės teigiamai ir / ar neigiamai įvertinti atsiliepimo, šis (ar šie) parametrai išsaugomi su numatyta reikšme 0.

4. Atsiliepimo žvaigždžių skaičius (nuo 1 iki 5). Jei svetainės atsiliepimuose nėra nurodomas įvertinimas žvaigždėmis, šis parametras nustatomas pagal kitas internetiniame puslapyje nurodytas atsiliepimo sentimentų žymes (t.y. teigiami atsiliepimai lygus 5 žvaigždėms, neutralūs – 3 žvaigždėms, neigiami – 1 žvaigždei).

5. Nuoroda į internetinės svetainės puslapį, kuriame rastas atsiliepimas.

Identifikavus kaupiamų duomenų struktūrą, nuspręsta iš kurių internetinių šaltinių renkami atsiliepimai. Norint išsaugoti kuo daugiau bei kuo įmanoma platesnio pobūdžio tekstų, juos nuspręsta rinkti iš 6 skirtingų internetinių svetainių. Šios svetainės yra:

1. Bendro pobūdžio prekių internetinė parduotuvė Pigu.lt [Pig20a].

1.1. Atsiliepimai svetainėje renkami iš dviejų šaltinių: atsiliepimų apie prekes šių prekių puslapiuose bei atsiliepimų apie Pigu.lt internetinę parduotuvę.

1.2. Kiekvienai prekei atsiliepimai apie ją renkami iš prekės atsiliepimų puslapių, kurių pavadinimas prasideda tekstu „Atsiliepimai apie prekę“. Atsiliepimai apie internetinę parduotuvę renkami iš puslapių su pavadinimu „Atsiliepimai | pigu.lt“ [Pig20b].

1.2.1. Kadangi numatyta atsiliepimų tvarka yra pateikiama tik dalis visų egzistuojančių atsiliepimų apie internetinę parduotuvę, atsiliepimai apie Pigu.lt buvo renkami iš visų prieinamų 50 puslapių su 3 skirtingoms atsiliepimų tvarkomis, panaikinant pasikartojančius atsiliepimus.

1.3. Viso surinkti 89175 atsiliepimai apie Pigu.lt prekes ir 5359 atsiliepimai apie internetinę parduotuvę Pigu.lt. Surinktų prekių atsiliepimų teksto ilgio mediana yra 35 simboliai, o atsiliepimų apie pačią Pigu.lt parduotuvę - 42 simboliai.

2. Knygų internetinė parduotuvė Knygos.lt [Bal20].

2.1. Atsiliepimai svetainėje renkami iš prekių puslapių.

2.2. Viso apie Knygos.lt prekes surinkta 19371 atsiliepimas, kurių teksto ilgio mediana yra 68 simboliai.

3. Elektronikos bei buitinių technikos internetinė parduotuvė Varle.lt [Var20a].

3.1. Atsiliepimai apie prekes renkami iš puslapių su pavadinimu „Vartotojų atsiliepimai | Varle.lt“ skyriaus „Atsiliepimai apie prekę“ [Var20b]. Kadangi dalis atsiliepimų puslapių buvo nepasiekiami (t.y. pateikus užklausą gražinamas HTTP 500 atsakymo kodas), iš jų atsiliepimai nebuvo surinkti.

3.2. Viso apie Varle.lt prekes surinkti 14463 atsiliepimai, kurių teksto ilgio mediana yra 34 simboliai.

4. Verslo paieškos sistema Imones.lt [Fcr20a].
    - 4.1. Atsiliepimai apie įmones renkami iš puslapių su pavadinimu „Atsiliepimai, Skundai | www.imones.lt“ [Fcr20b].
    - 4.2. Kiekvieno atsiliepimo autoriaus parametrai priskiriamas įmonės apie kurią paliekamas atsiliepimas pavadinimas, nes puslapiuose iš kurių renkami atsiliepimai informacija apie atsiliepimų autorius nėra pateikiama.
    - 4.3. Atsiliepimo sentimentas įrašomas kaip 5 žvaigždžių kai sentimentų HTML elementas turi klasę „callout-positive“ bei kaip 1 žvaigždės kai šios klasės neturi. Žymių nurodančių kitokius žvaigždžių kiekius / sentimentus internetinėje svetainėje nerasta.
    - 4.4. Viso surinkti 12934 atsiliepimai iš Imones.lt interneto svetainės puslapių. Surinktų Imones.lt atsiliepimų teksto ilgio mediana yra 208 simboliai.
  5. Atsiliepimų apie prekes, paslaugas bei organizacijas kaupimo sistema Atsiliepimai.lt [Ats20].
    - 5.1. Atsiliepimai renkami iš prekių, paslaugų bei įmonių puslapių.
    - 5.2. Viso surinkta 7140 atsiliepimų iš Atsiliepimai.lt prekių, paslaugų bei įmonių puslapių. Surinktų Atsiliepimai.lt atsiliepimų teksto ilgio mediana yra 292 simboliai.
  6. Laisvalaikio prekių parduotuvė Geradovana.lt [Ger20].
    - 6.1. Atsiliepimai renkami iš prekių ir paslaugų puslapių.
    - 6.2. Viso surinkta 2780 atsiliepimų iš Geradovana.lt prekių ir paslaugų puslapių. Surinktų Geradovana.lt atsiliepimų teksto ilgio mediana yra 43 simboliai.
- Iš visų internetinių parduotuvių bei atsiliepimų svetainių surinkta 151222 atsiliepimų.

### 3. Naudojami mašininio mokymosi algoritmai

Surinkus atsiliepiamus naudojamus sentimentų analizei bei surinkus ir sužymėjus interneto portalų komentarus, kitas žingsnis yra mašininio mokymosi algoritmų, kurie naudoja šiuos duomenis, parinkimas, apmokymas bei testavimas. Šiame skyriuje aprašomos tyrimo metu naudotų mašininio mokymosi algoritmų konfigūracijos bei kaip jie paruošiami užduoties atlikimui.

#### 3.1. Naivus Bajeso algoritmas

Tyrimo nuspręsta atlikti eksperimentus su naivaus Bajeso algoritmu dėl jo plataus naudojimo teksto klasifikavimo užduotims [Sch03, DSG16, KDW19]. Eksperimentams naudojamas papildytas naivus Bajeso algoritmas pasitelkiant Python programavimo kalbos Scikit-learn bibliotekos Pipeline, CountVectorizer (klasė paverčianti tekstus į masyvus su skaičiais nurodančiais kiek kartų kiekvienas žodis pasikartoja tekste [Sci20a]), TfidfTransformer (klasė sumažinanti svarbą žodžių, kurie pasikartoja daugelyje tekstų pasitelkiant TF-IDF formulę [SB88, Sci20b]) bei ComplementNB klases [PVG+11, Sci21a]. Šiam tyrimui pasirinktas papildytas naivaus Bajeso algoritmas dėl šio naivaus Bajeso algoritmo atmainos gebėjimo pasiekti geresnius už kitas atmainas rezultatus dirbant su duomenų aibėmis, kurių klasių pasiskirstymas yra nesubalansuotas [RST+03].

Siekiant pritaikyti mašininio mokymosi algoritmą tyrimo metu vykdomoms užduotims atliekamas hiperparametrų optimizavimas pasitelkiant GridSearchCV programinio kodo klase [FH19, Sci21b]. Šiuo metodu optimizuojamas teksto pavertimo į skaičių masyvus parametras „ngram\_range“ (parametras nurodantis ar atsižvelgiama į žodžių tekste tvarką) bei mašininio mokymosi algoritmo Laplaso išlyginimo parametras „alpha“ (koreguojantis algoritmo apmokyme naudojamos formulės parametro reikšmę) [CT94, MRS09]. Parenkant geriausiai pasirodžiusią algoritmo konfigūraciją naudojamas F1 balas, kuris nurodo klasifikatoriaus gebėjimą išlaikyti aukštą preciziškumą atpažįstant kuo įmanomą didesnę dalį smurtinio turinio (atpažinto smurtinio turinio dalies reikšmė yra lygi atšaukimo statistikos reikšmei) [MRS09].

#### 3.2. Atraminių vektorių algoritmas

Atraminių vektorių klasifikatoriai, kaip ir naivaus Bajeso algoritmas, neretai pasitelkiami spręsti teksto klasifikavimo užduotis [DSG16, KDW19, KMH+19]. Dėl šios priežasties nuspręsta atlikti eksperimentus ir su šiuo algoritmu. Eksperimentams naudojamos visos tos pačios programinio kodo klasės kaip ir 3.1 poskyryje išskyrus ComplementNB. Vietoj jos naudojama Scikit-learn bibliotekos SGDClassifier klasė realizuojanti atraminių vektorių algoritmą apmokomą stochastinio gradiento principu [PVG+11, Sci20c]. Šiai klasei taip pat pateikiamas

„class\_weight='balanced'“ parametras siekiant išvengti klasių nesubalansavimo, kuris gali pakenkti atraminių vektorių klasifikatoriaus kokybei [BP13, Sci20c]. Algoritmo hiperparametrų optimizavimas atliekamas 3.1 poskyryje aprašytais metodais bei įrankiais.

### **3.3. FastText**

Su FastText įrankiu nuspręsta atlikti eksperimentus norint palyginti tradicinius teksto klasifikatorius su algoritmų rinkiniu, kuris tikslumu geba prilygti giliesioms mokymosi technologijoms, bet išlaiko už šias technologijas aukštesnę klasifikavimo greitį [JGB+16]. Šis greitis leidžia ištestuoti plačią aibę skirtingų turinio apdorojimo įrankių bei algoritmų konfigūracijų. Eksperimentams naudojama Python programavimo kalbos Fasttext bibliotekos „train\_supervised“ metodas formuojant teksto klasifikavimo modelį [Fac21b]. Šis metodas naudojamas kartu su tos pačios bibliotekos pateikiamu automatiniu hiperparametrų optimizavimo įrankiu [Fac21c].

### **3.4. Hibridinis klasifikatorius**

Dalis tyrimų teksto klasifikavimo srityje sugebėjo pasiekti geresnių rezultatų sujungus keletą skirtingų algoritmų į hibridines sistemas [BGG+17, PRS17]. Dėl šios priežasties nuspręsta atlikti eksperimentus su hibridiniu teksto klasifikavimo sistemos prototipu sudarytu iš visų kitų tyrime naudojamų teksto klasifikavimo įrankių bei algoritmų (t.y. naivaus Bajeso algoritmo, atraminių vektorių klasifikatoriaus bei FastText).

Šie algoritmai sujungiami į vieną klasifikatorių pasitelkiant Python programavimo kalbos Scikit-learn bibliotekos VotingClassifier klase, kuris parenka rezultatą pagal individualių teksto klasifikavimo įrankių spėjimus daugumos balsavimo principu [PVG+11, Sci20d]. Šiai klasei pateikiamos tos pačios teksto klasifikavimo įrankių klasės bei jų konfigūracijos kaip ir poskyriuose 3.1, 3.2 bei 3.3. Atliekant hiperparametrų optimizavimą, optimizuojamos visos klasifikatoriuje esančios klasės atskirai (t.y. įrankiais ir metodais aprašytais 3.1, 3.2 bei 3.3 poskyriuose).



## 4. Teksto klasifikavimo sistemos metodų rinkiniai

Paruošus teksto klasifikavimo algoritmus bei surinkus prototipų naudojamus duomenis, kitas tyrimo žingsnis yra smurtinio turinio atpažinimo metodų rinkinio kūrimas. Siekiant patikrinti skirtingų metodų poveikį bendram rinkinio tikslumui bei kitiems statistiniams matams, nuspręsta realizuoti teksto klasifikavimo prototipo metodus, kurie suteikia (t.y. prideda naujų žodžių) arba panaikina informaciją (t.y. koreguoja jau tekste esančius žodžius) iš klasifikuojamų tekstų. Sujungus šiuos tekstą apdorojančius bei papildančius metodus su teksto klasifikavimui naudojamais algoritmais gauti šie metodai, kurie naudojami kurti smurtinio turinio atpažinimo metodų rinkinius:

1. **Komentarams klasifikuoti į smurtinius ir nesmurtinius naudojamas mašininio mokymosi algoritmas.** Šis algoritmas parenkamas iš algoritmų išvardintų 3 skyriuje.
2. **Komentaro netekstinių parametru įterpimas į komentaro tekstą.** Šie parametrai yra komentaro teigiamų bei neigiamų įvertinimų skaičiai ir komentaro autoriaus pobūdis (anoniminis ar registruotas portalo vartotojas). Interneto portalui Delfi.lt prie šių parametru taip pat priskiriami komentaro „reakcijų“ skaičiai (aprašyti 2.1 poskyryje). Kiekvienas iš šių parametru į tekstą įterpiami kaip tam parametru unikalūs žodžiai. Parametrai išreiškiami natūraliaisiais skaičiais įterpiami tokį kiekį kartų, kuris lygus skaitiniam parametru (pvz. komentarui turinčiam 5 neigiamus įvertinimus neigiamo įvertinimo žodis įterpiamas 5 kartus). Šis parametru įterpimas atliekamas norint nustatyti ar netekstinė su komentaru susijusi informaciją padeda atpažinti smurtinį turinį.
3. **Komentaro teksto kamienavimas.** Žodžių maišo metodu pagrįsti mašininio mokymosi algoritmai pasitelkia tų pačių terminų naudojimu skirtinguose tekstuose bandydami sugrupuoti šiuos tekstus į tam tikras klases (pvz. komentarus į smurtinius ir nesmurtinius). Šio metodo trūkumas - panašios reikšmės žodžiai, kurie rašomi skirtingai (pvz. “dirbti” ir “dirbo”), yra interpretuojami kaip skirtingi žodžiai. Kamienavimo tikslas yra suvienodinti šiuos terminus panaikinant visas žodžio dalis išskyrus kamieną. Šio metodo teigiamas poveikis F1 balui bei tikslumui pastebėtas kitame moksliniame darbe, kurio metu taip pat buvo bandoma suklasifikuoti neformalios lietuvių kalbos tekstus [KVD+12]. Kamienavimo procesas magistrinio darbo metu buvo atliekamas pasitelkiant Snowball kamienavimo algoritmą bei PyStemmer programinio kodo biblioteką [Por01, Bou21].
4. **Komentaro teksto diakritinių ženklų panaikinimas.** Lietuvių kalbos abėcėlėje yra raidžių, kurios turi diakritinius ženklus (pvz. raidės „š“ ir „ę“). Kadangi tyrimo metu atliekamas neformalių tekstų klasifikavimas, dalis komentatorių nenaudoja lietuviškų raidžių savo

komentaruose (pvz. vietoj raidės „š“ yra naudojama raidė „s“). Dėl šios priežasties, tas pats žodis gali būti mašininio mokymosi algoritmo interpretuojamas kaip keli skirtingi žodžiai jei dalis žodyje esančių lietuviškų raidžių yra pakeičiamos jų lotyniškos abėcėlės ekvivalentais. Panaikinus tekste esančius diakritinius ženklus visos žodžio versijos lietuviškų raidžių naudojimo atžvilgiu tampa vienodos (t.y. visos naudoja tik lotyniškos abėcėlės raides). Šis ženklų panaikinimas atliekamas siekiant patikrinti ar diakritinių ženklų suteikiama informacija yra naudingesnė už tų pačių žodžių identifikavimą kai šie žodžiai nenaudoja ar naudoja tik dalį juose esančių lietuviškų raidžių.

5. **Komentaro tekste esančių „emoji“ ir „emoticon“ žymių pavertimas žodžiais.** Kai kurie komentatoriai norėdami išreikšti ar pabrėžti tam tikrą emociją naudoja „emoji“ žymes ar jų senesnę atmainą „emoticon“. Įtraukiant šias žymes į klasifikatoriaus formavimo procesą siekiama suteikti mašininio mokymosi algoritmui daugiau duomenų iš kurių bandoma nustatyti smurtinį turinį. Šis „emoji“ ir „emoticon“ žymių pavertimas žodžiais atliekamas tuo pačiu principu kaip ir komentaro netekstinių parametrų įterpimas į komentaro tekstą.
6. **Komentaro sentimentų žymės į komentaro tekstą įterpimas.** Pasitelkiant 2.2 poskyryje aprašytus duomenis bei 3 skyriuje aprašytus algoritmus sukurtas sentimentų analizės įrankis. Naudojant šį įrankį visiems interneto portalų komentarams identifikuojamas sentimentas. Dėl surinktų sentimentų analizės įrankiui naudojamų duomenų pobūdžio, sentimentas apibūdinamas kaip natūralusis skaičius nuo 1 (labai negatyvus) iki 5 (labai pozityvus). Šis sentimentas įterpiamas į tekstą kaip sentimentų žymei unikalus žodis (t.y. žodis, kuris neegzistuoja nė viename iš surinktų komentarų). Šis metodas realizuojamas norint patikrinti ar egzistuoja sąsaja tarp teksto sentimentų bei to teksto buvimo smurtiniu (pvz. smurtiniai tekstai yra negatyvesni už nesmurtinius).
  - 6.1. Kuriant sentimentų analizės įrankį pasitelkiamas teksto klasifikatorius, kuris apmokomas neformalios lietuvių kalbos tekstais (atsiliepimais). Dėl šios priežasties šio sąrašo 1 – 5 punktuose apibūdinti teksto apdorojimo, papildymo ir klasifikavimo metodai taikomi ir sentimentų analizei sukurtam teksto klasifikatoriui.
  - 6.2. Metodai aprašyti šio sąrašo 1 – 5 punktuose yra taikomi atsiliepimams, kuriais apmokomas sentimentų analizės įrankis. Netekstiniais atsiliepimo parametrais yra laikomi sentimentų teigiami ir neigiami įvertinimų skaičiai bei internetinė svetainė, kurioje rastas atsiliepimas.

Pasitelkiant išvardintus metodus sukurti visi įmanomi metodų rinkiniai (t.y. metodų naudojimo bei nenaudojimo kombinacijos). Iš sugeneruotų metodų rinkinių viso suformuota 4160 prototipų.

## 5. Eksperimentų eiga bei rezultatai

Visi 4160 sukurti prototipai buvo testuojami ant Azure debesų kompiuterijos platformos F4s tipo virtualių kompiuterių [Mic20]. Prototipų aibė buvo suskirstyta į 8 dalis bei šios dalys buvo išskirstytos 8 F4s tipo virtualiems kompiuteriams.

Eksperimentuose surinkti bei sužymėti interneto portalų komentarai atsitiktine tvarka paskirstomi į naudojamus apmokymui bei naudojamus apmokytų algoritmų testavimui. Šis paskirstymas atliekamas Python programavimo bibliotekos Scikit-learn „train\_test\_split“ funkcija su numatytais duomenų aibių dydžių santykiais (25% visų komentarų naudojamų testavimui, likę - apmokymui) naudojant „stratify“ (siekiant, jog apmokymo bei testavimo aibėse išliktų panaši smurtinių bei nesmurtinių komentarų proporcija), „random\_state“ (siekiant, jog apmokymo bei testavimo duomenų aibės būtų kiekvienam eksperimentui paskirstomos identišškai) bei „shuffle=True“ parametrus [Sci20e].

Prieš atliekant eksperimentus identifikuoti 4 statistiniai matai – tikslumas, atpažintų smurtinių komentarų dalis bei F1 balas. Kadangi smurtiniai komentarai sudaro nedidelę dalį (~8.594848%) visų komentarų, tikslumas nurodo klasifikatoriaus gebėjimą išfiltruoti nesmurtinius komentarus (t.y. nepažymėti nesmurtinių komentarų smurtiniais). Norint identifikuoti algoritmo gebėjimą vykdyti užduotį (t.y. identifikuoti smurtinio pobūdžio turinį komentuose) įvestas tyrimui pritaikytas matas – atpažintų smurtinių komentarų dalis. Šis dydis apskaičiuojamas padalinant algoritmo atpažintų smurtinių komentarų skaičių iš visų smurtinio pobūdžio komentarų, kurie buvo pateikti algoritmui atpažinti. Paskutinis eksperimento metu apskaičiuojamas matas – F1 balas. Šio statistinio dydžio tikslas yra nurodyti klasifikatoriaus bendrą kokybę, nes šis dydis apskaičiuojamas kaip harmoninis vidurkis tarp algoritmo preciziškumo bei atšaukimo statistikos (atšaukimo statistikos matas lygus atpažintų smurtinių komentarų daliai).

### 5.1. Eksperimentų su smurtinio turinio atpažinimo prototipais rezultatai

Norint nustatyti ar tyrimo metu sukurti metodų rinkiniai sugeba pasiekti geresnių statistinių rezultatų už viešai prieinamus klasifikatorius, dalis testuojamų klasifikatorių yra etaloniniai. Eksperimentų metu testuojama 12 etaloninių smurtinio turinio atpažinimo sistemų – atraminių vektorių, naivaus Bajeso bei FastText algoritmus naudojančios klasifikatoriai, dalis iš jų įterpiančios sentimentų žymes į komentaro tekstą. Be sentimentų žymės įterpimo su įrankiu naudojančiu tik mašininio mokymosi algoritmu (t.y. su viešai prieinamu sentimentų analizės įrankiu), šie klasifikatoriai nenaudoja kitų tyrimo metų sukurtų teksto papildymo ar apdorojimo metodų (t.y. aprašytų 4 skyriuje).

Pasitelkiant eksperimentų metu skaičiuojamus statistinius matus identifikuoti tyrimui aktualiausi klasifikatoriai. Šie klasifikatoriai yra:

- Prototipas „Aukščiausias tikslumas“ - prototipas pasižymintis tikslumu, aukštesniu už visus kitus eksperimentų metu testuotus klasifikatorius.
- Prototipas „Aukščiausia atpažintų smurtinių komentarų dalis“ - prototipas atpažįstantis didžiausią dalį smurtinių komentarų lyginant su visais kitais eksperimentų metu testuotais klasifikatoriais.
- Prototipas „Aukščiausias F1 balas“ - prototipas su aukščiausiu F1 balu iš visų eksperimentų metu testuotų prototipų.
- Prototipas „Geresnis už etaloninius klasifikatorius“ - prototipas, kurio tikslumas, atpažintų smurtinių komentarų dalis bei F1 balas yra aukštesni už visus testuotus etaloninius klasifikatorius. Jei šių prototipų yra daugiau nei vienas, parenkamas klasifikatorius su aukščiausiu tikslumu.
- Etaloninis klasifikatorius su aukščiausiu tikslumu.
- Etaloninis klasifikatorius su aukščiausiu atpažintų smurtinių komentarų dalimi.
- Etaloninis klasifikatorius su aukščiausiu F1 balu.

1 lentelė. Eksperimentų, kurie atlikti su tyrimo metu sukurtais smurtinio turinio atpažinimo prototipais bei etaloniniais klasifikatoriais, rezultatai (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio). Etaloniniai klasifikatoriai išskirti pilka lentelės langelių spalva

<b>Klasifikatorius</b>	<b>Tikslumas</b>	<b>Atpažintų smurtinių komentarų dalis</b>	<b>F1 balas</b>
Prototipas „Aukščiausias tikslumas“	0.945	0.486	0.603
Prototipas „Aukščiausia atpažintų smurtinių komentarų dalis“	0.795	0.667	0.358
Prototipas „Aukščiausias F1 balas“	0.944	0.508	0.608
Prototipas „Geresnis už etaloninius klasifikatorius“	0.933	0.579	0.597
Etaloninis klasifikatorius su aukščiausiu tikslumu	0.931	0.557	0.580
Etaloninis klasifikatorius su aukščiausia atpažintų smurtinių komentarų dalimi bei F1 balu	0.929	0.574	0.582
Pavyzdinis klasifikatorius spėjantis, jog visi komentarai nesmurtiniai	0.914	0	0

Atlikus eksperimentus, nustatyti šie tyrimui aktualiausių klasifikatorių metodų rinkiniai:

- Prototipas „Aukščiausias tikslumas“ - atraminių vektorių algoritmą naudojantis klasifikatorius, kuris „emoji“ ir „emoticon“ žymes laiko žodžiais, panaikina komentuose esančius diakritinius

ženklus bei įterpia komentaro sentimentų žymę į tekstą. Sentimentų žymė gaunama atliekant sentimentų analizę pasitelkiant atraminių vektorių algoritmą apmokomą atsiliepimais, kurių tekstui atliekamas diakritinių ženklų panaikinimas.

- Prototipas „Aukščiausia atpažintų smurtinių komentarų dalis“ - atraminių vektorių algoritmą naudojantis klasifikatorius, kuris panaikina komentaruose esančius diakritinius ženklus bei įterpia komentaro netekstinius parametrus ir sentimentų žymę į tekstą. Sentimentų žymė gaunama atliekant sentimentų analizę pasitelkiant atraminių vektorių algoritmą apmokomą atsiliepimais, kuriuose „emoji“ ir „emoticon“ žymės paverčiamos žodžiais.
- Prototipas „Aukščiausias F1 balas“ - atraminių vektorių algoritmą naudojantis klasifikatorius, kuris „emoji“ ir „emoticon“ žymes laiko žodžiais, panaikina komentaruose esančius diakritinius ženklus bei įterpia komentaro sentimentų žymę į tekstą. Sentimentų žymė gaunama atliekant sentimentų analizę pasitelkiant naivaus Bajeso algoritmą apmokomą atsiliepimais, kurių tekstui atliekamas kamienavimas bei diakritinių ženklų panaikinimas.
- Prototipas „Geresnis už etaloninį klasifikatorių“ - atraminių vektorių algoritmą naudojantis klasifikatorius įterpiantis komentaro sentimentų žymę į tekstą. Sentimentų žymė gaunama atliekant sentimentų analizę pasitelkiant FastText algoritmą apmokomą atsiliepimais, kuriuose „emoji“ ir „emoticon“ žymės laikomos žodžiais.
- Etaloninis klasifikatorius su aukščiausiu tikslumu – atraminių vektorių algoritmą naudojantis klasifikatorius įterpiantis komentaro sentimentų žymę į tekstą. Sentimentų žymė gaunama atliekant sentimentų analizę pasitelkiant atraminių vektorių algoritmą apmokomą tyrimo metu surinktais atsiliepimais.
- Etaloninis klasifikatorius su aukščiausia atpažintų smurtinių komentarų dalimi bei F1 balu – atraminių vektorių algoritmą naudojantis klasifikatorius įterpiantis komentaro sentimentų žymę į tekstą. Sentimentų žymė gaunama atliekant sentimentų analizę pasitelkiant naivaus Bajeso algoritmą apmokomą atsiliepimais.

Šių klasifikatorių statistinius rezultatus galima matyti 1 lentelėje. Iš 12 testuotų etaloninių klasifikatorių, vienas iš jų atpažintų smurtinių komentarų dalies bei F1 balo atžvilgiu sugebėjo pasiekti aukštesnius rezultatus už kitus klasifikatorius. Dėl šios priežasties 1 lentelėje matomi tik 2 etaloniniai klasifikatoriai. Siekiant palyginti kiek aukštas yra prototipų bei etaloninių klasifikatorių tikslumas taip pat pridėtas pavyzdinis / teorinis klasifikatorius, kuris spėja, jog visi testuojamoje aibėje esantys komentarai yra nesmurtiniai.

Lyginant su tikslumo atžvilgiu geriausiai pasirodžiusiu etaloniniu klasifikatoriumi, prototipas „Aukščiausias tikslumas“ sugebėjo pasiekti 1.4 procentiniais punktais aukštesnį tikslumą bei 2.3 procentiniais punktais aukštesnį F1 balą. Šį prototipą etaloninis klasifikatorius sugebėjo aplenkti tik atpažintų smurtinių komentarų dalimi (aplenkė 7.1 procentiniais punktais). Atsižvelgiant į rezultatus, praktikoje šis prototipas tinkamiausias siekiant kiek įmanoma daugiau sumažinti asmens, kuris atsakingas už smurtinio turinio moderavimą, krūvį. Nors atpažintų smurtinių komentarų dalis yra žemesnė už etaloninį klasifikatorių bei kitus tyrimo metu sukurtus prototipus, prototipo aukštas tikslumas gali sumažinti moderatoriumi pateikiamą kiekį komentarų, kurie netinkamai būtų pažymėti kaip smurtiniai.

Prototipas „Aukščiausia atpažintų smurtinių komentarų dalis“ lyginant su atitinkamu etaloniniu klasifikatoriumi pasiekia 9.3 procentinių punktų aukštesnę atpažintų smurtinių komentarų dalį, tačiau kenčia nuo 22.4 procentinių punktų žemesnio F1 balo bei 13.4 procentinių punktų žemesnio tikslumo. Dėl prototipo agresyvaus fokusavimo į atpažintų smurtinių komentarų dalį, šis prototipas vienintelis pasiekė žemesnį tikslumą nei pavyzdinis klasifikatorius, kuris žymi visus komentarus kaip nesmurtinius. Atsižvelgiant į šiuos rezultatus galima matyti, jog praktikoje šis prototipas vertingas tik siekiant maksimizuoti atpažinto smurtinio turinio dalį bei suprantant, jog dėl to yra aukojamas tikslumas bei bendra prototipo klasifikatoriaus kokybė.

Aukščiausią F1 balą pasiekęs etaloninis klasifikatorius nusileido prototipui „Aukščiausias F1 balas“ dviejuose matuose – tikslume (1.5 procentiniais punktais) bei F1 bale (2.6 procentiniais punktais). Kaip ir prototipas „Aukščiausias tikslumas“, šį klasifikatorių aukščiausio F1 balo etaloninė sistema sugebėjo aplenkti tik atpažintų smurtinių komentarų dalimi (6.6 procentiniais punktais). Klasifikatorius nuo prototipo „Aukščiausias tikslumas“ išsiskiria tuo, jog paaukojęs nedidelę dalį tikslumo (0.1 procentinio punkto) sugeba atpažinti 2.2 procentiniais punktais didesnę smurtinių komentarų dalį. Dėl šių savybių prototipas praktikoje tinkamiausias siekiant sumažinti smurtinio turinio moderatoriaus krūvį, bet siekiant atpažinti daugiau smurtinių komentarų nei prototipu „Aukščiausias tikslumas“.

Nors kiti tyrimo metu realizuoti prototipai nusileidžia etaloniniams klasifikatoriams bent vienu statistiniu matu, prototipas „Geresnis už etaloninius klasifikatorius“ pasiekia geresnius rezultatus už etaloninius klasifikatorius visais statistiniais matais. Šis prototipas etaloninius klasifikatorius lenkia 0.2 procentinio punkto tikslume, 0.5 procentinio punkto atpažinta smurtinių komentarų dalimi bei 1.5 procentiniais punktais F1 bale. Šio klasifikatoriaus praktinė paskirtis paprasta – pakeisti

etaloninį klasifikatorių įrankiu atliekančiu smurtinio turinio atpažinimą bei nesmurtinio turinio filtravimą geriau visais statistiniais rezultatais.

2 lentelė. Smurtinio turinio atpažinimo eksperimentuose naudotų mašininio mokymosi algoritmų tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo rezultatai (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio)

Mašininio mokymosi algoritmas	Tikslumas		Atpažintų smurtinių komentarų dalis		F1 balas	
	Aukščiausias	Mediana	Aukščiausia	Mediana	Aukščiausias	Mediana
Naivaus Bajeso	0.924	0.913	0.464	0.421	0.495	0.441
Atraminių vektorių	0.945	0.930	0.667	0.514	0.608	0.562
FastText	0.933	0.924	0.383	0.235	0.493	0.345
Hibridinis	0.945	0.937	0.508	0.404	0.595	0.524

Iš 2 lentelės duomenų galima matyti, jog iš visų eksperimentuose naudotų mašininio mokymosi algoritmų, aukščiausius rezultatus tikslumo, atpažintų komentarų dalimi bei F1 balo atžvilgiu sugebėjo pasiekti atraminius vektorius naudojančys prototipai (aukščiausiu tikslumu šiam algoritmui sugebėjo prilygti hibridinis algoritmas). Šis atraminių vektorių klasifikatorių gebėjimas pasiekti aukščiausius rezultatus visuose testuotose statistiniuose rezultatuose rodo šio algoritmo gebėjimą prisitaikyti prie specifinių užduočių (pvz. siekiant tik aukščiausio tikslumo ar F1 balo) koreguojant jam pateikiamus duomenis (t.y. kaip papildomas ar apdorojamas tekstas). Atraminius vektorius naudojančys prototipai taip pat sugebėjo aplenkti kitus testuotus algoritmus beveik visose statistinių rezultatų medianose. Už šį algoritmą aukštesnę medianą pasiekė tik hibridinis klasifikatorius tikslumo atžvilgiu. Iš šių rezultatų galima spręsti, jog siekiant aukščiausios smurtinio turinio atpažinimo sistemos kokybės turėtų būti naudojamas atraminių vektorių mašininio mokymosi algoritmas.

3 lentelė. Smurtinio turinio atpažinimo eksperimentuose naudotų mašininio mokymosi algoritmų klasifikavimo užduočių atlikimo trukmės sekundėmis (skaičiai suapvalinti iki 3 skaičių po kablelio)

Mašininio mokymosi algoritmas	Komentarų smurtinio turinio atpažinimo trukmės mediana (sek.)	Komentarų sentimentų analizės trukmės mediana (sek.)
Naivaus Bajeso	0.133	0.554
Atraminių vektorių	0.088	0.526
FastText	0.028	0.136
Hibridinis	0.279	1.213

Nors atraminių vektorių algoritmu pagrįsti klasifikatoriai jau pasiekė aukštus tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo rezultatus, šie klasifikatoriai taip pat sugebėjo pralenkti didžiąją dalį testuotų algoritmų teksto klasifikavimo greičio atžvilgiu. Iš 3 lentelės duomenų galima pastebėti, jog šiuo algoritmu pagrįsti klasifikatoriai smurtinio turinio atpažinimo bei sentimentų analizės vykdymo trukmės atžvilgiu yra antroje vietoje (t.y. užduočių vykdymo trukmė yra aukštesnė tik už vieno algoritmo). Greičiausiai teksto klasifikavimo užduotis atliko FastText įrankis, tačiau dėl jo prastų rezultatų atpažintų smurtinių komentarų dalies bei F1 balo kategorijose (matomose 2 lentelėje), šio algoritmo panaudojimas panašaus pobūdžio užduotims ribotas (t.y. tik kai pagrindinis tikslas – kuo greitesnis teksto klasifikavimo greitis).

4 lentelė. Smurtinio turinio atpažinimo eksperimentuose naudotų komentarų teksto papildymo ir koregavimo metodų aukščiausias pasiekiamas tikslumas, atpažintų smurtinių komentarų dalis bei F1 balas (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio)

Komentarų teksto apdorojimo metodas	Aukščiausias tikslumas		Aukščiausia atpažintų smurtinių komentarų dalis		Aukščiausias F1 balas	
	Su metodu	Be metodo	Su metodu	Be metodo	Su metodu	Be metodo
Sentimento žymės įterpimas	0.945	0.942	0.667	0.568	0.608	0.585
Netekstinių komentarų parametrų įterpimas	0.944	0.945	0.667	0.601	0.595	0.608
Kamienavimas	0.942	0.945	0.645	0.667	0.595	0.608
Diakritinių ženklų panaikinimas	0.945	0.945	0.667	0.612	0.608	0.607
„Emoji“ bei „emoticon“ simbolių pavertimas žodžiais	0.945	0.944	0.645	0.667	0.608	0.597

Identifikavus mašininio mokymosi algoritmų poveikį klasifikatoriaus kokybei svarbu nustatyti ir teksto papildymo bei apdorojimo metodų teigiamą ar neigiamą poveikį. 4 lentelėje galima matyti, jog geriausiems prototipams neigiamo poveikio nepadarė bei teigiamą poveikį turėjo tik sentimentų žymės įterpimas bei diakritinių ženklų panaikinimas. Iš testuotų teksto apdorojimo metodų, tik kamienavimas pakenkė geriausiai pasirodžiusiems prototipams visais 3 statistiniais matais. Likę teksto apdorojimo metodai pakenkia daliai statistinių rezultatų, tačiau pagerina likusius.



Atsižvelgiant į šiuos rezultatus galima padaryti išvadą, jog sentimentų žymės įterpimas bei diakritinių ženklų panaikinimas yra vertingi plačioje aibėje smurtinio turinio atpažinimo prototipų (t.y. pagerina skirtingų tikslų siekiančių klasifikatorių kokybę), kamienavimo metodo vertė - ribota, o likę metodai turėtų būti taikomi atsižvelgiant į kurie statistiniai matai svarbiausi (t.y. kai norima paaugoti vieno statistinio mato rezultatus, siekiant padidinti kitą).

5 lentelė. Smurtinio turinio atpažinimo eksperimentuose naudotų komentarų teksto papildymo ir koregavimo metodų tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo medianos (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio)

Komentarų teksto apdorojimo metodas	Tikslumo mediana		Atpažintų smurtinių komentarų dalies mediana		F1 balo mediana	
	Su metodu	Be metodo	Su metodu	Be metodo	Su metodu	Be metodo
Sentimento žymės įterpimas	0.926	0.926	0.404	0.410	0.486	0.487
Netekstinių komentarų parametrų įterpimas	0.924	0.927	0.399	0.410	0.484	0.489
Kamienavimas	0.925	0.926	0.388	0.437	0.461	0.492
Diakritinių ženklų panaikinimas	0.926	0.925	0.404	0.404	0.489	0.461
„Emoji“ bei „emoticon“ simbolių pavertimas žodžiais	0.926	0.925	0.404	0.404	0.491	0.479

Nors sentimentų žymės įterpimas pagerino geriausiai pasirodžiusio prototipo rezultatus visų matų atžvilgiu, vidutinis tirtas klasifikatorius nuo šio metodo tik kenčia. Iš 5 lentelės duomenų galima matyti, jog sentimentų žymės įterpimas pablogina atpažintų smurtinių komentarų dalies bei F1 balo medianas. Šia savybe nepasižymi diakritinių ženklų panaikinimo metodas, kuris vidutiniame prototipe neturi neigiamo poveikio bei pagerina tikslumą ir F1 balą. Ta pačia savybe pasižymi ir „emoji“ bei „emoticon“ simbolių pavertimas žodžiais. Likę du teksto apdorojimo metodai vidutiniam prototipui turi neigiamą poveikį bent vieno mato atžvilgiu, o likusių statistinių rezultatų - nepagerina. Iš šių bei 4 lentelės duomenų galima identifikuoti, jog sentimentų žymės įterpimas gali pagerinti jau aukštus rezultatus, o diakritinių ženklų panaikinimas – pagerinti bet kokio prototipo rezultatus / kokybę.

## 5.2. Sentimentų analizės įrankio parametru poveikis eksperimentų rezultatams

Nors 5.1 poskyryje nustatyta, jog sentimentų žymės įterpimas į komentarą gali pagerinti geriausiai pasirodžiusio prototipo rezultatus, šis faktas nesuteikia informacijos apie tą žymę formuojančios sentimentų analizės įrankio konfigūraciją. Kadangi sentimentų analizės įrankyje naudojami tie patys teksto apdorojimo metodai bei mašininio mokymosi algoritmai, agregavus duomenis pagal šių priemonių naudojimą galima identifikuoti poveikį smurtinio turinio atpažinimo rezultatams.

6 lentelė. Smurtinio turinio atpažinimo eksperimentų tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo rezultatai suskirstyti pagal eksperimentuose naudojamą sentimentų analizės įrankio algoritmą (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio; agreguojant duomenis neįtraukiami prototipai, kuriuose neįterpiama sentimentų žymė)

Sentimentų analizės algoritmas	Tikslumas		Atpažintų smurtinių komentarų dalis		F1 balas	
	Aukščiausias	Mediana	Aukščiausia	Mediana	Aukščiausias	Mediana
Naivaus Bajeso	0.944	0.926	0.645	0.404	0.608	0.484
Atraminų vektorių	0.945	0.926	0.667	0.404	0.605	0.485
FastText	0.944	0.926	0.612	0.404	0.606	0.489
Hibridinis	0.945	0.926	0.628	0.404	0.603	0.486

Grupuojant pagal sentimentų analizės įrankiui naudojamus algoritmus geriausiai pasirodė atraminų vektorių algoritmas – pagal 6 lentelės duomenis, šį algoritmą naudojantys klasifikatoriai pasiekė aukščiausią tikslumą bei atpažintų smurtinių komentarų dalį. Neblogai sugebėjo pasirodyti ir kiti algoritmai: aukščiausią F1 balą sugebėjo pasiekti prototipai naudojantys naivaus Bajeso algoritmą sentimentų žyme suformuoti, o aukščiausiam tikslumui sugebėjo prilygti hibridinį sentimentų analizės algoritmą naudojantys prototipai. Šie rezultatai rodo, jog didžiojoje dalyje sentimentų analizės užduočių atraminų vektorių klasifikatorius yra geriausias mašininio mokymosi algoritmas siekiant sukurti sentimentų analizės įrankį.

Analizuojant 6 lentelės statistinių matų medianas galima matyti, jog visų sentimentų analizės algoritmų poveikis vidutinio smurtinio turinio atpažinimo prototipo tikslumui bei atpažintų smurtinių komentarų daliai yra neutralus. Algoritmų poveikis aktualesnis F1 balo medianai - šioje kategorijoje visus likusius algoritmus sugebėjo nugalėti FastText.

7 lentelė. Eksperimentuose testuotų sentimentų analizės klasifikatoriaus naudojamų atsiliapimų teksto papildymo ir koregavimo metodų aukščiausias pasiekiamas tikslumas, atpažintų smurtinių komentarų dalis bei F1 balas (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio)

Atsiliapimų teksto apdorojimo metodas	Aukščiausias tikslumas		Aukščiausia atpažintų smurtinių komentarų dalis		Aukščiausias F1 balas	
	Su metodu	Be metodo	Su metodu	Be metodo	Su metodu	Be metodo
Netekstinių atsiliapimų parametrų įterpimas	0.945	0.945	0.645	0.667	0.607	0.608
Kamienavimas	0.945	0.945	0.645	0.667	0.608	0.606
Diakritinių ženklų panaikinimas	0.945	0.945	0.645	0.667	0.608	0.607
„Emoji“ bei „emoticon“ simbolių pavertimas žodžiais	0.945	0.945	0.667	0.639	0.606	0.608

Iš 7 lentelės duomenų galima matyti, jog nė vienas iš sentimentų analizei naudojamų atsiliapimų apdorojimo metodų nesugebėjo pagerinti aukščiausio pasiekto tikslumo. Aukščiausios atpažintų smurtinių komentarų dalies atžvilgiu visi metodai išskyrus vieną - „emoji“ bei „emoticon“ simbolių pavertimas žodžiais - pablogino rezultatus. Aukščiausią F1 balą padėjo pasiekti kamienavimas bei diakritinių ženklų panaikinimas, o netekstinių atsiliapimų parametrų įterpimas ir „emoji“ bei „emoticon“ simbolių pavertimas žodžiais turėjo priešingą poveikį - abu metodai pakenkė F1 balui. Iš šių rezultatų galima spręsti, jog teksto apdorojimo metodai neturi teigiamo poveikio tikslumui, tačiau gali pagerinti klasifikatoriaus F1 balą.

8 lentelė. Eksperimentuose testuotų sentimentų analizės klasifikatoriaus naudojamų atsiliepimų teksto papildymo ir koregavimo metodų tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo medianos (dešimtaine trupmena; skaičiai suapvalinti iki 3 skaičių po kablelio)

Atsiliepimų teksto apdorojimo metodas	Tikslumo mediana		Atpažintų smurtinių komentarų dalies mediana		F1 balo mediana	
	Su metodu	Be metodo	Su metodu	Be metodo	Su metodu	Be metodo
Netekstinių parametrų įterpimas	0.926	0.926	0.404	0.404	0.486	0.486
Kamienavimas	0.926	0.926	0.404	0.404	0.486	0.486
Diakritinių ženklų panaikinimas	0.926	0.926	0.404	0.404	0.486	0.486
„Emoji“ bei „emoticon“ simbolių pavertimas žodžiais	0.926	0.926	0.404	0.404	0.486	0.486

8 lentelėje galima pastebėti, jog tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo medianų nepagerino nė vienas iš tirtų atsiliepimų apdorojimo metodų. Iš 7 ir 8 lentelės duomenų galima padaryti išvadą, jog sentimentų analizės įrankį apmokyti naudojamų tekstų apdorojimas gali pagerinti jau aukštus smurtinio turinio atpažinimo prototipo rezultatus, tačiau poveikio vidutiniam prototipui šis įrankis neturi.

## Rezultatai ir išvados

Atlikus tyrimą gauti šie rezultatai:

1. Sukurti teksto klasifikavimo sistemos metodų rinkiniai bei jais paremti prototipai gebantys atpažinti lietuvių kalba parašytus anoniminius smurtinio pobūdžio komentarus interneto portaluose.
2. Identifikuoti geriausiai tikslumo, atpažintų smurtinių komentarų dalimi bei F1 balo atžvilgiu pasirodę tyrimo metu sukurti prototipai bei jų statistiniai rezultatai.
3. Nustatytas viešai prieinamų etaloninių klasifikatorių tikslumas, atpažintų smurtinių komentarų dalis bei F1 balas siekiant atpažinti smurtinį turinį neformalios lietuvių kalbos tekstuose.
4. Palygintas sukurto hibridinio klasifikatoriaus gebėjimas atpažinti smurtinį turinį su klasifikatoriais naudojančiais tik vieną algoritimą.
5. Identifikuotas taisyklėmis pagrįstų teksto apdorojimo metodų poveikis ieškant smurtinio pobūdžio turinio lietuviškų interneto portalų komentaruose.
6. Nustatytas sentimentų analizės poveikis tikslumui ieškant smurtinio turinio neformalaus pobūdžio lietuviškuose tekstuose.
7. Palygintas skirtingų mašininio mokymosi algoritmų atpažinimo greitis, tikslumas, atpažintų smurtinių komentarų dalis bei F1 balas bandant atpažinti neformalios lietuvių kalbos smurtinį turinį.

Iš tyrimo metu pasiektų rezultatų padarytos šios išvados:

1. Sukurti teksto klasifikavimo sistemos metodų rinkiniai bei jais paremti prototipai tikslumo, atpažintų smurtinių komentarų dalimi bei F1 balo atžvilgiu geba atpažinti lietuvių kalba parašytus anoniminius smurtinio pobūdžio komentarus interneto portaluose geriau nei šiuo metu viešai prieinamos teksto klasifikavimo ir sentimentų analizės sistemos.
2. Sukurti ir analizuoti teksto papildymo ir apdorojimo metodai (įskaitant sentimentų analizę bei šios analizės sugeneruotų duomenų įterpimą) gali pastebimai pagerinti neformalios lietuvių kalbos smurtinio turinio atpažinimo sistemos kokybę.
3. Nors neformalios lietuvių kalbos tekstų sentimentų analizės įrankis gali pasiekti geresnių statistinių rezultatų naudodamas tyrimo metu sukurtais ir analizuotais teksto papildymo bei apdorojimo įrankiais, šių metodų teigiamas poveikis labai ribotas ir gali būti išgaunamas tik labai selektyviai parenkant naudojamus metodus.
4. Teksto kamienavimas didžiojoje dalyje smurtinio turinio atpažinimo sistemų turi neigiamą poveikį užduoties kokybiškam atlikimui.

5. Pasitelkiant tyrimo metu sukurtais metodų rinkiniais įmanoma realizuoti smurtinio turinio neformalia lietuvių kalba atpažinimo sistemas, kurios būtų optimizuotos specifiniams turinio moderavimo poreikiams (pvz. kuo didesnis atpažintų smurtinių komentarų procentas ar kuo mažesnis kiekis nesmurtinių komentarų pažymėtų kaip smurtiniai).
6. Lyginant su vieno mašininio mokymosi algoritmo klasifikatoriais, hibridinių klasifikatorių (t.y. klasifikatoriaus sudaryto iš keleto skirtingų mašininio mokymosi algoritmų) pasitelkiančių balsavimo principą panaudojimas atpažįstant lietuvių kalba parašytus anoniminius smurtinio pobūdžio komentarus interneto portaluose yra ribotas.
7. Iš visų tirtų mašininio mokymosi algoritmų, atraminių vektorių klasifikatorius yra tinkamiausias algoritmas siekiant kiek įmanoma aukštesnių tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo rezultatų smurtinio turinio atpažinimo bei sentimentų analizės sistemose.
8. Nors FastText algoritmas sugeba pasiekti aukštą teksto klasifikavimo greitį, šis įrankis neretai nusileidžia visiems kitiems tyrimo metu testuotiems mašininio mokymosi algoritmams tikslumo, atpažintų smurtinių komentarų dalies bei F1 balo atžvilgiu.

## Šaltiniai

- [Ale21] Alexa Internet, Inc. *Alexa - Top sites*. Prieiga per internetą: <https://www.alexa.com/topsites>. Žiūrėta: 2021-04-26
- [Ats20] Atsiliepimai.lt. *Produktų ir paslaugų atsiliepimai Lietuvoje - Atsiliepimai.lt*. Prieiga per internetą: <https://atsiliepimai.lt/>. Žiūrėta: 2020-12-17
- [Bal20] BALTO trader, UAB. *Knygos internetu pigiau ir patogiau. / Knygos.lt*. Prieiga per internetą: <https://www.knygos.lt/>. Žiūrėta: 2020-12-17
- [BGG+17] P. Badjatiya, S. Gupta, M. Gupta, V. Varma. Deep learning for hate speech detection in tweets. *Proceedings of the 26th International Conference on World Wide Web Companion*, 2017, p. 759-760
- [Bou21] R. Boulton. *GitHub - snowballstem/pystemmer: Python stemming library using snowball stemmers*. Prieiga per internetą: <https://github.com/snowballstem/pystemmer>. Žiūrėta: 2021-04-25
- [BP13] R. Batuwita, V. Palade. Class imbalance learning methods for support vector machines. *Imbalanced Learning: Foundations, Algorithms, and Applications*; Wiley: Hoboken, NJ, USA, 83, 2013
- [CSB+16] A. Conneau, H. Schwenk, L. Barrault, Y. Lecun. Very deep convolutional networks for text classification. *arXiv preprint arXiv:1606.01781*, 2016
- [CT94] W. B. Cavnar, J. M. Trenkle. N-gram-based text categorization. *Proceedings of SDAIR-94, 3rd annual symposium on document analysis and information retrieval*, 161175, 1994
- [Del20a] Delfi, UAB. *APIE Delfi Lietuva*. Prieiga per internetą: <https://www.delfi.lt/apie/?wid=7269>. Žiūrėta: 2020-12-20
- [Del20b] Delfi, UAB. *DELFI Žinios - Pagrindinis naujienų portalas Lietuvoje*. Prieiga per internetą: <https://www.delfi.lt/>. Žiūrėta: 2020-12-18
- [Die20a] Diena Media News, UAB. *DIENA.lt - Sužinok naujienas pirmas! | Diena.lt*. Prieiga per internetą: <https://www.diena.lt/>. Žiūrėta: 2020-12-18
- [Die20b] Diena Media News, UAB. *Turkija skyrė 25 mln. dolerių baudą „Google“ | Diena.lt*. Prieiga per internetą: <https://www.diena.lt/naujienos/pasaulis/ekonomika-ir-politika/turkija-skyre-25-mln-doleriu-bauda-google-996112?komentarai>. Žiūrėta: 2020-12-20

- [Die20c] Diena Media News, UAB. *Nario erdvė | Diena.lt*. Prieiga per internetą: <https://www.diena.lt/user/register>. Žiūrėta: 2020-12-20
- [DSG16] M. D. Devika, C. Sunitha, A. Ganesh. Sentiment analysis: a comparative study on different approaches. *Procedia Computer Science*, 87, 2016, p. 44-49
- [DWM+17] T. Davidson, D. Warmsley, M. Macy, I. Weber. Automated hate speech detection and the problem of offensive language. *Eleventh international aaai conference on web and social media*, 2017
- [DZM+15] N. Djuric, J. Zhou, R. Morris, M. Grbovic, V. Radosavljevic, N. Bhamidipati. Hate speech detection with comment embeddings. *Proceedings of the 24th international conference on world wide web*, 2015, p. 29-30
- [Fac21a] Facebook Inc. *Facebook - Log In or Sign Up*. Prieiga per internetą: <https://www.facebook.com/>. Žiūrėta: 2021-04-26
- [Fac21b] Facebook Inc. *Text classification · fastText*. Prieiga per internetą: <https://fasttext.cc/docs/en/supervised-tutorial.html>. Žiūrėta: 2021-04-25
- [Fac21c] Facebook Inc. *Automatic hyperparameter optimization · fastText*. Prieiga per internetą: <https://fasttext.cc/docs/en/autotune.html>. Žiūrėta: 2021-04-25
- [Fcr20a] FCR Media Lietuva, UAB. *Lietuvos įmonių katalogas, įmonių paieška, įmonių informacija, įmonės*. Prieiga per internetą: <https://www.imones.lt/>. Žiūrėta: 2020-12-16
- [Fcr20b] FCR Media Lietuva, UAB. *Atsiliepimai, Skundai | www.imones.lt*. Prieiga per internetą: <https://www.imones.lt/atsiliepimai>. Žiūrėta: 2020-12-16
- [FH19] M. Feurer, F. Hutter. *Automated Machine Learning: methods, systems, challenges*. Springer, Cham, 2019, p. 3-33
- [Ger20] Gera dovana, UAB. *Dovanos internetu, originalios dovanų idėjos | Gera dovana*. Prieiga per internetą: <https://www.geradovana.lt/>. Žiūrėta: 2020-12-17
- [Goo20a] Google Ireland Limited. *Devika: Sentiment analysis: a comparative study on... - „Google“ mokslinčius*. Prieiga per internetą: <https://scholar.google.com/scholar?cites=17231704066251747956>. Žiūrėta: 2020-06-11
- [Goo20b] Google Ireland Limited. *Joulin: Bag of tricks for efficient text classification - „Google“ mokslinčius*. Prieiga per internetą:



- <https://scholar.google.com/scholar?cites=4087215990684471244>. Žiūrėta: 2020-06-13
- [Goo20c] Google Ireland Limited. *Kapočiūtė-Dzikienė: Sentiment analysis of Lithuanian...* - „Google“ mokslinčius. Prieiga per internetą: [https://scholar.google.com/scholar?q=related:ozzcUuxIhA8J:scholar.google.com/&scioq=sentiment+analysis+lithuanian&hl=lt&as\\_sdt=0,5](https://scholar.google.com/scholar?q=related:ozzcUuxIhA8J:scholar.google.com/&scioq=sentiment+analysis+lithuanian&hl=lt&as_sdt=0,5). Žiūrėta: 2020-06-14
- [Goo20d] Google Ireland Limited. *Young: Recent trends in deep learning based natural...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.lt/scholar?cites=3050905065745226465>. Žiūrėta: 2020-06-10
- [Goo20e] Google Ireland Limited. *Pandey: Twitter sentiment analysis using hybrid cuckoo...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=12976650586483230143>. Žiūrėta: 2020-06-10
- [Goo20f] Google Ireland Limited. *Djuric: Hate speech detection with comment embeddings* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=12388116322487784373>. Žiūrėta: 2020-06-12
- [Goo20g] Google Ireland Limited. *Davidson: Automated hate speech detection and the...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=8792494420729905567>. Žiūrėta: 2020-06-12
- [Goo20h] Google Ireland Limited. *Miyato: Adversarial training methods for semi-supervised...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=6594257289645930121>. Žiūrėta: 2020-06-14
- [Goo20i] Google Ireland Limited. *Liu: Adversarial multi-task learning for text classification* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=6202310749502426295>. Žiūrėta: 2020-06-14
- [Goo20j] Google Ireland Limited. *Badjatiya: Deep learning for hate speech detection in tweets* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=10862378573327552942>. Žiūrėta: 2020-

- 06-13
- [Goo20k] Google Ireland Limited. *Lee: Sequential short-text classification with recurrent...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=15204618355692725322>. Žiūrėta: 2020-06-13
- [Goo20l] Google Ireland Limited. *Conneau: Very deep convolutional networks for text...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=10851201017229487169>. Žiūrėta: 2020-06-14
- [Goo20m] Google Ireland Limited. *Kapociūtė-Dzikienė: Intrinsic evaluation of Lithuania...* - „Google“ mokslinčius. Prieiga per internetą: [https://scholar.google.lt/scholar?q=related:mPcfnmV5IYoJ:scholar.google.com/&scioq=Intrinsic+Evaluation+of+Lithuanian+WordEmbeddings+Using+WordNet&hl=lt&as\\_sdt=0,5&as\\_vis=1](https://scholar.google.lt/scholar?q=related:mPcfnmV5IYoJ:scholar.google.com/&scioq=Intrinsic+Evaluation+of+Lithuanian+WordEmbeddings+Using+WordNet&hl=lt&as_sdt=0,5&as_vis=1). Žiūrėta: 2020-06-14
- [Goo20n] Google Ireland Limited. *Schmidt: A survey on hate speech detection using...* - „Google“ mokslinčius. Prieiga per internetą: <https://scholar.google.com/scholar?cites=4916490924076363714>. Žiūrėta: 2020-06-12
- [Goo20o] Google Ireland Limited. *Vitkutė-Adžgauskienė: NLP infrastructure for the...* - „Google“ mokslinčius. Prieiga per internetą: [https://scholar.google.com/scholar?q=related:y4p0W1VM6CgJ:scholar.google.com/&scioq=NLP+Infrastructure+for+the+Lithuanian+Language&hl=lt&as\\_sdt=0,5](https://scholar.google.com/scholar?q=related:y4p0W1VM6CgJ:scholar.google.com/&scioq=NLP+Infrastructure+for+the+Lithuanian+Language&hl=lt&as_sdt=0,5). Žiūrėta: 2020-06-14
- [Goo21] Google Ireland Limited. *YouTube*. Prieiga per internetą: <https://www.youtube.com/>. Žiūrėta: 2021-04-26
- [YHP+18] T. Young, D. Hazarika, S. Poria, E. Cambria. Recent trends in deep learning based natural language processing. *ieee Computational intelligence magazine*, 13(3), 2018, p. 55-75
- [JGB+16] A. Joulin, E. Grave, P. Bojanowski, T. Mikolov. Bag of tricks for efficient text classification. *arXiv preprint arXiv:1607.01759*, 2016
- [Kav11] V. Kavaliauskas. Nuomonių analizės taikymas komentarams lietuvių kalboje. *Magistro baigiamasis darbas*, Vytauto Didžiojo universitetas, Vilnius, 2011

- [KD18] J. Kapočiūtė - Dzikienė, R. Damaševičius. Intrinsic evaluation of Lithuanian word embeddings using WordNet. *Computer Science On-line Conference*. Springer, Cham, 2018, p. 394-404
- [KDW19] J. Kapočiūtė - Dzikienė, R. Damaševičius, M. Woźniak. Sentiment analysis of Lithuanian texts using traditional and deep learning approaches. *Computers*, 8(1), 2019, p. 4
- [KMH+19] K. Kowsari, K. J. Meimandi, M. Heidarysafa, S. Mendu, L. Barnes, D. Brown. Text classification algorithms: A survey. *Information*, 10(4), 2019, p. 150.
- [KVD+12] J. Kapočiūtė - Dzikienė, F. Vaassen, W. Daelemans, A. Krupavičius. Improving topic classification for highly inflective languages. *Proceedings of COLING 2012*, 2012, p. 1393-1410
- [LD16] J. Y. Lee, F. Dernoncourt. Sequential short-text classification with recurrent and convolutional neural networks. *arXiv preprint arXiv:1603.03827*, 2016
- [Lie20] Lietuvos Respublikos Seimas. *Lietuvos Respublikos baudžiamojo kodekso patvirtinimo ir įsigaliojimo įstatymas. Baudžiamasis kodeksas. Galiojanti suvestinė redakcija (nuo 2021-01-01)*, 2020. Prieiga per internetą: <https://e-seimas.lrs.lt/portal/legalAct/lt/TAD/TAIS.111555/asr>
- [LQH17] P. Liu, X. Qiu, X. Huang. Adversarial multi-task learning for text classification. *arXiv preprint arXiv:1704.05742*, 2017
- [Lry20a] Lrytas, UAB. *Lrytas.lt naujienos – sužinoti daugiau!*. Prieiga per internetą: <https://www.lrytas.lt/>. Žiūrėta: 2020-12-18
- [Lry20b] Lrytas, UAB. *Privatumo politika / Lrytas.lt*. Prieiga per internetą: <https://www.lrytas.lt/atsakomybe/>. Žiūrėta: 2020-12-20
- [MDG16] T. Miyato, A. M. Dai, I. Goodfellow. Adversarial training methods for semi-supervised text classification. *arXiv preprint arXiv:1605.07725*, 2016
- [MGK18] M. V. Mäntylä, D. Graziotin, M. Kuutila. The evolution of sentiment analysis—A review of research topics, venues, and top cited papers. *Computer Science Review*, 27, 2018, p. 16-32
- [Mic20] Microsoft Corporation. *New F-Series VM Sizes | Azure Blog and Updates | Microsoft Azure*. Prieiga per internetą: <https://azure.microsoft.com/en-us/blog/f-series-vm-size/>. Žiūrėta: 2020-12-23

- [Min20a] 15min, UAB. *Komentavimo taisyklės | 15min.lt*. Prieiga per internetą: <https://www.15min.lt/komentavimo-taisykles>. Žiūrėta: 2020-12-20
- [Min20b] 15min, UAB. *15min naujienos – Suprasti akimirksniu*. Prieiga per internetą: <https://www.15min.lt/>. Žiūrėta: 2020-12-18
- [MRS09] C. D. Manning, P. Raghavan, H. Schütze. *An Introduction to Information Retrieval*. Cambridge University Press, Cambridge, 2009
- [Pig20a] Pigu, UAB. *Pigu.lt - prekybos centras internete*. Prieiga per internetą: <https://pigu.lt/lt/>. Žiūrėta: 2020-12-15
- [Pig20b] Pigu, UAB. *Atsiliepimai | pigu.lt*. Prieiga per internetą: <https://pigu.lt/lt/atsiliepimai>. Žiūrėta: 2020-12-16
- [Por01] M. F. Porter. *Snowball: A language for stemming algorithms*, 2001. Prieiga per internetą: <https://snowballstem.org/texts/introduction.html>
- [PRS17] A. C. Pandey, D. S. Rajpoot, M. Saraswat. Twitter sentiment analysis using hybrid cuckoo search method. *Information Processing & Management*, 53(4), 2017, p. 764-779
- [PVG+11] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, É. Duchesnay. Scikit-learn: Machine learning in Python. *Journal of machine Learning research*, 12, 2011, p. 2825-2830.
- [Res20a] Respublikos leidiniai, UAB. *Respublika.lt - naujienų ir žinių portalas*. Prieiga per internetą: <https://www.respublika.lt/>. Žiūrėta: 2020-12-18
- [Res20b] Respublikos leidiniai, UAB. *Respublika.lt - naujienų ir žinių portalas*. Prieiga per internetą: [https://www.respublika.lt/lt/naujienos/pramogos/kinas\\_muzika\\_tv/kaip\\_desrininkas\\_ir\\_juru\\_pestininkas\\_tapo\\_pasaulio\\_kino\\_legenda,coments.1#komentarai](https://www.respublika.lt/lt/naujienos/pramogos/kinas_muzika_tv/kaip_desrininkas_ir_juru_pestininkas_tapo_pasaulio_kino_legenda,coments.1#komentarai). Žiūrėta: 2020-12-20
- [RST+03] J. D. Rennie, L. Shih, J. Teevan, D. R. Karger. Tackling the poor assumptions of naive bayes text classifiers. *Proceedings of the 20th international conference on machine learning (ICML-03)*, 2003, p. 616-623
- [SB88] G. Salton, C. Buckley. Term-weighting approaches in automatic text retrieval. *Information processing & management*, 24(5), 1988, p. 513-523.

- [Sch03] K. M. Schneider. A comparison of event models for Naive Bayes anti-spam e-mail filtering. *Proceedings of the tenth conference on European chapter of the Association for Computational Linguistics-Volume 1*, Association for Computational Linguistics , 2003, p. 307-314
- [Sci20a] Scikit-learn developers. *sklearn.feature\_extraction.text.CountVectorizer* — *scikit-learn 0.24.0 documentation*. Prieiga per internetą: [https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_extraction.text.CountVectorizer.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.CountVectorizer.html). Žiūrėta: 2020-12-23
- [Sci20b] Scikit-learn developers. *sklearn.feature\_extraction.text.TfidfTransformer* — *scikit-learn 0.24.0 documentation*. Prieiga per internetą: [https://scikit-learn.org/stable/modules/generated/sklearn.feature\\_extraction.text.TfidfTransformer.html](https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.TfidfTransformer.html). Žiūrėta: 2020-12-23
- [Sci20c] Scikit-learn developers. *sklearn.linear\_model.SGDClassifier* — *scikit-learn 0.24.0 documentation*. Prieiga per internetą: [https://scikit-learn.org/stable/modules/generated/sklearn.linear\\_model.SGDClassifier.html](https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.SGDClassifier.html). Žiūrėta: 2020-12-23
- [Sci20d] Scikit-learn developers. *sklearn.ensemble.VotingClassifier* — *scikit-learn 0.24.0 documentation*. Prieiga per internetą: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.VotingClassifier.html>. Žiūrėta: 2020-12-23
- [Sci20e] Scikit-learn developers. *sklearn.model\_selection.train\_test\_split* — *scikit-learn 0.24.0 documentation*. Prieiga per internetą: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.train\\_test\\_split.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.train_test_split.html). Žiūrėta: 2020-12-23
- [Sci21a] Scikit-learn developers. *sklearn.naive\_bayes.ComplementNB* — *scikit-learn 0.24.1 documentation*. Prieiga per internetą: [https://scikit-learn.org/stable/modules/generated/sklearn.naive\\_bayes.ComplementNB.html](https://scikit-learn.org/stable/modules/generated/sklearn.naive_bayes.ComplementNB.html). Žiūrėta: 2021-04-26
- [Sci21b] Scikit-learn developers. *sklearn.model\_selection.GridSearchCV* — *scikit-learn 0.24.1 documentation*. Prieiga per internetą: [https://scikit-learn.org/stable/modules/generated/sklearn.model\\_selection.GridSearchCV.html](https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html).

Žiūrėta: 2021-04-26

- [Skr12] I. Skrupskelytė. Sentimentų analizė lietuviškuose internetiniuose dokumentuose naudojant kalbos technologijas. *Magistro baigiamasis darbas*, Vytauto Didžiojo universitetas, Vilnius, 2012
- [SPW+13] R. Socher, A. Perelygin, J. Wu, J. Chuang, C. D. Manning, A. Y. Ng, C. Potts. Recursive deep models for semantic compositionality over a sentiment treebank. *Proceedings of the 2013 conference on empirical methods in natural language processing*, 2013, p. 1631-1642
- [SW17] A. Schmidt, M. Wiegand. A survey on hate speech detection using natural language processing. *Proceedings of the Fifth International Workshop on Natural Language Processing for Social Media*, 2017, p. 1-10
- [Tam18] J. Tamašauskas. Socialiniuose tinkluose naudojamų emotikonų ir sentimentų analizės vertinimo tyrimas. *Magistro baigiamasis darbas*, Vilniaus universitetas, Vilnius, 2018
- [Var20a] VARLE, UAB. *Prekybos centras internete | VARLE.LT*. Prieiga per internetą: <https://www.varle.lt/>. Žiūrėta: 2020-12-15
- [Var20b] VARLE, UAB. *Vartotojų atsiliepimai | Varle.lt*. Prieiga per internetą: <https://www.varle.lt/atsiliepimai/>. Žiūrėta: 2020-12-15
- [VUA+16] D. Vitkutė - Adžgauskienė, A. Utkā, D. Amilevičius, T. Krilavičius. NLP infrastructure for the Lithuanian language. *LREC 2016: 10th international conference on Language resources and evaluation, 23-28 May, 2016, Portorož, Slovenia: proceedings. Paris: European Language Resources Association, 2016*, 2016
- [Wik21] Wikimedia Foundation, Inc. *Wikipedia*. Prieiga per internetą: <https://www.wikipedia.org/>. Žiūrėta: 2021-04-26

## Sąvokų apibrėžimai

Dirbtinis neuroninis tinklas	Mašininio mokymosi technologija dalinai pagrįsta žmogaus neuronų struktūra. Ši technologija sudaryta iš tarpusavyje sujungtų neuronų, kurie laiko savyje informaciją, atlieką ateinančios informacijos apdorojimą ir / ar perduoda informaciją kitiems neuronams.
Duomenų požymiai	Išvestinės duomenų aibės elementų reikšmės naudojamos mašininio mokymosi algoritmuose (angl. „features“)
Gilusis mokymasis	Mašininio mokymosi metodai (dažniausiai dirbtiniai neuroniniai tinklai) naudojantys kelis apdorojimo sluoksnius
Hiperparametras	Mašininio mokymosi algoritmo ar šio algoritmo pagalbinio metodo parametras, kuris leidžia koreguoti kaip yra apmokoma bendra mašininio mokymosi sistema (angl. „hyperparameter“)
Ilgos trumpalaikės atminties modelis	Rekurentinio neuroninio tinklo architektūra, gebanti apdoroti dinaminio ilgio informacijos srautus
Kamienavimas	Teksto apdorojimo metodas, kurio metu siekiama panaikinti visų tekste esančių žodžių dalis išskyrus kamieną (angl. „stemming“)
Konvoliucinis neuroninis tinklas	Dirbtinių neuroninių tinklų tipas savo veikime naudojantis konvoliucijos matematinę operatorių
Natūralios kalbos apdorojimas	Sritis kompiuterinių metodų skirtų apdoroti bei išgauti kompiuteriams suprantamą informaciją iš tekstinio turinio (angl. „natural language processing“)
Rekurentinis neuroninis tinklas	Dirbtinių neuroninių tinklų modelis pasižyminti cikliškomis jungtimis tarp neuronų
Sentimentų analizė	Turinio klasifikavimo užduotis, kurios metu siekiama identifikuoti skirtingų tekstų, frazių, žodžių, paveikslėlių, garsų ar kitų objektų emocinę reikšmę
Žodžių įterpimas	Žodžių pavertimas į realių skaičių vektorius (angl. „word embedding“). Atliekama norint paversti žodžius į mašininio mokymosi algoritmams geriau apdorojamą formą

## **Santrumpos**

API	Aplikacijų programavimo sąsaja (angl. „application programming interface“)
HTML	Hiperteksto žymėjimo kalba (angl. „Hypertext Markup Language“)
HTTP	Hiperteksto perdavimo protokolas (angl. „Hypertext Transfer Protocol“)
LKSSAIS	Lietuvių kalbos sintaksinės ir semantinės analizės informacinė sistema
TF-IDF	Termino dažnis padalintas iš dokumento dažnio (angl. „Term Frequency – Inverse Document Frequency“)