



LATVIJAS
UNIVERSITĀTE

Promocijas darba
kopsavilkums

Viktorija Ļeonova

**MAŠĪNMĀCĪŠANĀS METOŽU
IZMANTOŠANA RUNĀTĀJA
FRUSTRĀCIJAS LĪMEŅA
NOTEIKŠANAI SOCIĀLO MEDIJU
TEKSTOS LATVIEŠU VALODĀ**

Rīga 2025



LATVIJAS
UNIVERSITĀTE

EKSAKTO ZINĀTŅU UN TEHNOLOĢIJU FAKULTĀTE

Viktorija Ļeonova

**MAŠĪNMĀCĪŠANĀS METOŽU
IZMANTOŠANA RUNĀTĀJA
FRUSTRĀCIJAS LĪMEŅA NOTEIKŠANAI
SOCIĀLO MEDIJU TEKSTOS
LATVIEŠU VALODĀ**

Promocijas darba kopsavilkums

zinātniskā doktora grāda (Ph. D.) iegūšanai
dabaszinātņu nozarē datorzinātnē
Apakšnozare: intelektuālo sistēmu teorija

Rīga 2025

Promocijas darbs izstrādāts Latvijas Universitātes Datorikas fakultātes Datorzinātnes katedrā laika posmā no 2016. līdz 2024. gadam.

Darbs sastāv no ievada, 9 nodaļām, nobeiguma, literatūras saraksta, 11 pielikumiem.

Darba forma: disertācija datorzinātnes nozarē, datorzinātnes intelektuālo sistēmu teorijas apakšnozarē.

Darba zinātniskais vadītājs: Prof., *Dr. sc. comp.* **Jānis Zuters**, Latvijas Universitāte.

Darba recenzenti:

1. Prof., *Dr. sc. comp.* **Inguna Skadiņa**, Latvijas Universitāte;
2. Prof., *Dr.* **Tomas Krilavičius**, Vītauta Dižā Universitāte, Lietuva;
3. Asist. prof., *Dr.* **Anton Leontyev**, Ženēvas koledža, Amerikas Savienotās Valstis.

Promocijas darba aizstāvēšana notiks 2025. gada 17. oktobrī 15.00 Latvijas Universitātes Datorzinātnes un informātikas promocijas padomes atklātā sēdē.

Ar promocijas darbu var iepazīties Latvijas Universitātes bibliotēkā, Kalpaka bulvārī. 4.

LU Eksakto zinātņu un tehnoloģiju fakultātes
Datorzinātnes un informātikas
promocijas padomes priekšsēdētājs _____ / Guntis Bārzdīņš /

Promocijas padomes sekretāre _____ / Sintija Siliņa /

© Latvijas Universitāte, 2025

© Viktorija Ļeonova, 2025

ISBN 978-9934-36-432-7

ISBN 978-9934-36-433-4 (PDF)

Anotācija

Šis darbs piedāvā jaunu mašīnmācīšanās modeli sociālo tīklu dialogu automātiskai anotēšanai un lietotāja emocionālā stāvokļa dinamikas prognozēšanai. Modelis ir balstīts vienlaicīgi uz leksiskajiem un neleksiskajiem emociju izteiksmes līdzekļiem, izmantojot bezprecedenta izsmelšu neleksisko izteiksmju līdzekļu sarakstu. Darbs arī piedāvā modeli, pielāgotu latviešu valodas datiem, un parāda, ka pielāgotais modelis ir vienlīdz efektīvs angļu un latviešu valodā, tādējādi tas ir no valodas neatkarīgs modelis. Lai uzbūvētu šo jauno modeli, tika izveidota jauna datu kopa latviešu valodā, kurā ir no sociālajiem medijiem, konkrēti no X^1 sociālā tīkla, iegūti 300 dialogi, kas ir lietotāju sarunas ar tehnisko atbalstu. Katram lietotāju ziņojumam ir anotēts frustrācijas (neapmierinātības) līmenis skalā no 0 līdz 4, un dialogā tiek analizēta emocionālā stāvokļa dinamika, balstoties uz stāvokļa izmaiņām pēc tehniskā atbalsta speciālista atbildes.

Izmantojot metrikas uz lietotāja izmantoto neleksisko izteiksmes līdzekļu pamata, iegūtais modelis ļauj automātiski anotēt ziņojumu frustrācijas līmeni un paredzēt emocionālā stāvokļa dinamikas izmaiņas. Rezultāti uzrāda, ka neleksisko izteiksmes līdzekļu pievienošana ievadparametru kopā uzlabo emociju noteikšanas un prognozēšanas akurātību. Darbam ir potenciāli pielietojumi klientu atbalsta pilnveidošanā un lietotāju pieredzes uzlabošanā sociālajos tīklos.

¹ Datu vākšanas laikā — Twitter

Saturs

1. Ievads.....	7
1.1. Pētījuma joma	7
1.2. Pētījuma problēmas aktualitāte	8
1.3. Mērķis un uzdevumi.....	8
1.4. Darbā izvirzītās tēzes un jautājumi	9
1.5. Pētniecības metodes	10
1.6. Galvenie rezultāti	10
1.7. Promocijas darba rezultātu aprobācija un publikācija.....	12
2. Promocijas darba kopsavilkuma apraksts	14
2.1. Literatūras apskats.....	14
2.2. Datu kopas.....	14
2.3. Datu vākšana un sagatavošana	15
2.4. Datu apstrāde.....	15
2.5. Pētījums.....	16
2.5.1. Eksperimenta dizains	16
2.5.2. Pirmā fāze: dinamika dialogos (izmantojot angļu valodas datu kopu)	17
2.5.3. Otrā fāze: frustrācijas līmenis un frustrācijas dinamika dialogos (izmantojot latviešu valodas datu kopu)	18
2.5.4. Trešā fāze: modeļa paplašināšana ar datu apstrādi un NLIL funkcijām (latviešu valodā).....	18
2.5.5. Ceturtā fāze: no valodas neatkarīgs modelis.....	19
2.6. Salīdzinājums ar lielo valodas modeļu efektivitāti ziņojumu anotēšanā	20
2.7. Galvenie rezultāti	22
2.7.1. Datu kopas	22
2.7.2. NLIL saraksts.....	22
2.7.3. Modelis	24
2.8. Diskusija un interpretācija.....	24
3. Pētījuma piemērojamības ierobežojumi.....	26

4. Galvenie secinājumi un priekšlikumi	26
Bibliogrāfija	29

Kopsavilkumā izmantotās abreviācijas un saīsinājumi

NLIL — neleksiskie izteiksmes līdzekļi

1. Ievads

Lai spētu dzīvot produktīvu un funkcionālu dzīvi sabiedrībā, ir jāprot novērtēt savas attiecības ar citiem. Nav iespējama koordinācija vai sadarbība, ja indivīdam trūkst cita indivīda prāta modeļa izpratnes, citiem vārdiem sakot, ja viņš nespēj paredzēt cita cilvēka uzvedību, kas attiecīgi ir ļoti atkarīga no attieksmes pret objektiem un apkārtējās vides fenomeniem, tostarp citiem indivīdiem.

Šis princips attiecas uz jebkuru sociālu sugu, un, protams, tas attiecas uz cilvēkiem. Daži zinātnieki uzskata (Whiten, de Waal, 2017), ka mūsu smadzenes ir attīstījušās mūsu sociālās mijiedarbības dēļ, lai slēgtā grupā orientētos pastāvīgi mainīgā sociālā vidē. Neatkarīgi no tā, vai tā ir vai nav taisnība, emocijām un to atpazīšanai citos cilvēkos ir būtiska nozīme mūsu dzīvē. Tādēļ ir tikai dabiski, ņemot vērā interneta straujo attīstību, jo īpaši Web 2.0 ar tā lietotāju radītā satura pārpilnību, ka pētnieki meklē veidu, kā formalizēt emociju atpazīšanu digitālajos medijos.

Kā aprakstīts Verma et al. (2016), šādu multivides līdzekļu neizmērojamā apjoma dēļ cilvēkiem ir gandrīz neiespējami ar tiem strādāt vai pat tikai tos visus pārlūkot; tādēļ pētniekiem ir jāatrod izmantojamas metodes to automātiskai apstrādei.

Tomēr tas pats neizmērojamais skaitļošanas jaudas, glabāšanas apjoma un datu pārraides ātruma pieaugums, kas ļauj lietotājiem radīt dažādu multivides saturu neredzēti lielā apjomā, ir nodrošinājis arī līdzekļus, ar kuriem izstrādāt tehnoloģijas to pārvaldīšanai. Tāpēc pētnieki nepārtraukti cenšas izmantot vismodernākās metodes, lai anotētu emocijas lietotāju radītajā saturā, jo emociju atpazīšana ir pielietojama dažādu mērķu sasniegšanā. Tā var būt noderīga, piemēram, veidojot priekšstatu par tipiskiem uzskatiem par kādu sabiedrisku darbinieku vai fenomenu (Wang et al., 2020) vai veidojot veselības aprūpes sistēmu, kurai raksturīga emociju apzināšana (Ayata et al., 2020).

1.1. Pētījuma joma

Šī promocijas darba joma ir automātiskā emociju anotēšana, it īpaši neapmierinātības atpazīšana angļu un latviešu valodas sociālo mediju tekstos. Tā ir starpdisciplināra joma, kas apvieno mašīnmācīšanos, lingvistiku, psiholingvistiku, neurozinātņi un citas nozares.

Lai gan šīs jomas esošie pētījumi galvenokārt koncentrējas uz modeļiem, kas klasificē pamatemocijas, neapmierinātība — emocija, bieži sastopama komunikācijā, — joprojām tiek plaši ignorēta. Ņemot vērā, ka uzņēmumi arvien vairāk izmanto sociālos tīklus klientu apkalpošanai, neapmierinātības atpazīšana var kalpot kā būtisks rīks lietotāju apmierinātības līmeņa noteikšanai. Tomēr pētījumi par neapmierinātības atpazīšanu, īpaši tekstā, joprojām ir ļoti ierobežoti.

Lielākā daļa esošo emociju anotēšanas metožu balstās uz leksisko analīzi, izmantojot vārdu virknes, n-grammas un noskaņojuma vārdu kopumus, lai noteiktu emocionālo noskaņu. Lai gan šādas pieejas ir efektīvas, tās ignorē neleksiskās iezīmes, kas digitālajā saziņā ir būtiskas. Atšķirībā no strukturēta rakstītā teksta, sociālo mediju ziņojumi ietver dažādus neleksiskos elementus, piemēram, pieturzīmju secības (tādas, kā atkārtotas izsaukuma zīmes, daudzpunktes un citas), emocijzīmes, kas izpauž noskaņojumu vai emocijas, un ASCII/Unicode simbolus (piemēram, $_(\u221f)_/\$), kas būtiski veicina emocionālo izteiksmi. Neskatoties uz to nozīmi, šie elementi līdz šim netika pietiekoši pētīti neapmierinātības atpazīšanas modeļos.

Turklāt emociju atpazīšanas pētījumi lielākoties ir vērsti uz angļu valodu, atstājot mazresursu valodas, piemēram, latviešu, nepietiekami izpētītas un atbalslītas šajā jomā.

1.2. Pētījuma problēmas aktualitāte

Pētījuma mērķis ir pievērsties nepilnīgi izpētītajiem aspektiem līdzšinējos pētījumos par emociju anotēšanu tekstā. Pirmkārt, nav pietiekami izpētīta tāda bieži sastopama emocija kā frustrācija, kuras izpēti varētu izmantot dažādos veidos, tostarp klientu apmierinātības un neapmierinātības mērīšanai. Vēl viens svarīgs aspekts ir tas, ka tādi daudzsološi teksta elementi kā neleksiskie izteiksmes līdzekļi (*non-lexical means of expression*, tālāk tekstā — NLIL) netiek pietiekami izmantoti un to visaptverošs saraksts nav pieejams. Tajā pašā laikā sarežģītas n-grammas un metrikas tiek plaši izmantotas leksiskajiem izteiksmes līdzekļiem, bet tikai plaši izplatītām valodām, tāpēc vēl viens promocijas darba aspekts veltīts rīku pieejamībai zemu resursu valodām, šajā gadījumā — latviešu valodai, ar mērķi izveidot no valodas neatkarīgu rīku, kura izmantošanai nebūtu nepieciešams ļoti liels anotēto tekstu korpus.

Promocijas darbs tiecas aizpildīt šos iztrūkumus. Tajā tiek pētīta un anotēta līdz šim nepietiekami izskatīta emocija — neapmierinātība (Leonova, Zuters, 2021), un šī procesa gaitā tiek izveidotas jaunas datu kopas angļu un latviešu valodai, kas ir mazresursu valoda, tādējādi palielinot pieejamo korpusu skaitu.

Šajā darbā tiek analizētas arī līdz šim maz pētītas teksta iezīmes — NLIL, izskatot hipotēzi, ka uz NLIL balstītu iezīmju iekļaušana var uzlabot neapmierinātības atpazīšanas akurātību. Pētījuma rezultāti apstiprina šo hipotēzi gan latviešu, gan angļu valodas datu kopā.

1.3. Mērķis un uzdevumi

Promocijas darba ietvaros veiktā pētījuma mērķis ir izstrādāt modeli, kas precīzi prognozētu neapmierinātības līmeni lietotāja ziņojumā angļu un latviešu valodās dialogā ar klientu atbalsta pārstāvi, balstoties uz ziņojuma leksiskajām un neleksiskajām pazīmēm vai uz lietotāja iepriekšējā ziņojuma un tam sekojošās

klientu atbalsta atbildes leksiskajām un neleksiskajām iezīmēm. Lai sasniegtu šo mērķi, pētījumā tiek risināti šādi uzdevumi:

1. Atrast vai izveidot piemērotu emociju anotēšanas modeli, kas noteic frustrācijas līmeni teksta fragmentam, piemēram, sociālo mediju ziņojumam.
2. Konstruēt modeli, kas varētu ziņojumiem automātiski anotēt frustrācijas līmeņus, pamatojoties uz ziņojuma tekstu.
3. Atrast vai izveidot datu kopu, kas ir piemērota frustrācijas anotēšanas modeļa apmācībai.
4. Apmācīt un notestēt modeli.
5. Izpētīt datu kopu un iegūt no tās NLIL, kas potenciāli varētu kalpot kā prognozētāji ziņojumā paustās frustrācijas līmenim.
6. Sastādīt sarakstu ar uz NLIL balstītām pazīmēm, kuras liecina par korelāciju ar ziņojumā pausto frustrācijas līmeni.
7. Konstruēt modeli, kā ieejas parametrus izmantojot uz NLIL balstītos raksturlielumus, un pārbaudīt to efektu uz modeļa prognostisko veikspēju.
8. Pārbaudīt datu kopu sološo datu apstrādes metožu izmantošanai, un pārbaudīt šo metožu ietekmi uz modeļa prognostisko veikspēju.

Šo uzdevumu veiksmīga izpilde:

1. Veicinās pirmapstrādi latviešu valodas ziņojumiem sociālajos tīklos.
2. Nodrošinās pamatu neapmierinātības anotēšanas uzdevumiem angļu un latviešu valodās.
3. Iespējams, palīdzēs emociju anotēšanas uzdevumos valodām, kurām ir līdzīgs kultūras konteksts un līdzīga NLIL lietošana.
4. Nodrošinās visaptverošu sarakstu NLIL, kas sastopami sociālo tīklu ziņojumos angļu un latviešu valodās.

1.4. Darbā izvirzītās tēzes un jautājumi

Šajā pētījumā tiek pārbaudītas sekojošas tēzes:

1. Klientu atbalsta dialogos angļu un latviešu valodā lietotāja frustrācijas intensitāti ziņojumā, kas ņemta kā trīs neatkarīgu anotētāju mediānas vērtējums, var prognozēt no lietotāja ziņojuma teksta, izmantojot uz neironu tīkla balstītu modeli ar interaktīvi veidotu vārdu krājumu. Turklāt rezultāts uzlabojas, ja pievieno uz NLIL balstītu raksturlielumus un pielieto teksta segmentāciju ar GenSeg segmentācijas rīku un citas teksta apstrādes metodes, piemēram, diakritisko zīmju dzēšanu, un ir salīdzināms ar rezultātiem, ko var panākt lielie valodas modeļi.
2. Klientu atbalsta dialogos angļu un latviešu valodā lietotāja šībrīža ziņojuma frustrācijas intensitāti var prognozēt pēc atslēgvārdiem lietotāja iepriekšējā ziņojumā kopā ar atslēgvārdiem (no citas kopas) klientu atbalsta atbildes ziņojumā starp šiem lietotāja ziņojumiem.

Tika izskatīti sekojoši pētnieciski jautājumi:

1. Kā izmērīt frustrācijas intensitāti, izpausto lietotāja ziņojumā sociālā tīklā?
2. Kādām īpašībām jāpiemīt datu kopai, lai to varētu izmantot modeļa apmācīšanai un testēšanai?
3. Kādus uz NLIL balstītus raksturlielumus var pielietot frustrācijas prognozēšanai?
4. Kāda ir vislabākā frustrācijas prognozēšanas modeļa konfigurācija?
5. Kādas datu apstrādes metodes var pielietot, lai uzlabotu prognozēšanas akurātību?
6. Cik laba ir sasniegtā prognozēšanas akurātība, salīdzinot ar universālo lielo valodas modeļu uzrādītajiem rezultātiem?

1.5. Pētniecības metodes

Darbā izstrādes gaitā tika izmantotas šādas pētniecības metodes:

- *Zinātniskās literatūras analīze.* Tika izpētīti recenzēti avoti, tostarp grāmatas, zinātniskie žurnāli un publikācijas, kā arī arXiv preprinti emociju anotēšanas, neironu tīklu un psiholingvistikas jomās, lai noteiktu gan bāzliniju, gan jaunākās pieejas emociju anotācijā. Tika identificēts zināšanu trūkums — proti, nepietiekami pētījumi par neapmierinātības anotāciju un par NLIL pielietošanu emociju anotācijā latviešu un angļu valodās.
- *Iteratīvs izstrādes process.* Šī darbā ietvaros izstrādātie rīki un modeļi tika projektēti, īstenoti un pilnveidoti cikliskā procesā, veicot uzlabojumus un izmaiņas pēc iepriekšējo iterāciju rezultātu analīzes.
- *Kontrolēti eksperimenti.* Algoritmu un izstrādāto neironu tīklu modeļu veikspēja tika sistemātiski novērtēta, izmantojot kontrolētus eksperimentālos uzstādījumus.
- *Kvantitatīvā novērtēšana.* Pētījumā izmantotās novērtēšanas metodes balstās uz skaitliskajiem rādītājiem, nodrošinot iespēju objektīvi salīdzināt dažādas pieejas un modeļus.
- *Kļūdu analīze.* Kur iespējams, kļūdas tika analizētas, lai identificētu to iespējamus cēloņus un potenciālos uzlabojumus.

1.6. Galvenie rezultāti

Promocijas darbā tiek sniegti šādi uzlabojumi neapmierinātības atpazīšanā sociālo mediju ziņojumos:

- Interaktīva vārdnīcas izveide: ieviesta jauna iteratīvā pieeja prediktoru vārdnīcas veidošanai, kas ļauj apmācīt modeli, izmantojot nelielas anotētas datu kopas.
- Jauna emociju anotēšanas pieeja: atšķirībā no tradicionālajiem modeļiem, kas balstās tikai uz leksiskajām iezīmēm, šajā darbā modeļa ievadparametru veidošanai ir izmantotas arī NLIL iezīmes, piemēram, pieturzīmju secības,

emocijzīmes un citas tiešsaistes saziņai raksturīgas pazīmes, kas uzlabo neapmierinātības līmeņa prognozēšanas akurātību (accuracy).

- Jaunas datu kopas latviešu un angļu valodās²: izstrādātas divas jaunas lietotāju un klientu atbalsta dialogu datu kopas, kurās ziņojumi ir anotēti ar neapmierinātības līmeņiem, tādējādi palielinot pieejamo korpusu skaitu. Angļu valodas datu kopa iegūta no apstrādātiem Kaggle Twitter klientu atbalsta dialogiem (Axelbrooke, 2017), savukārt latviešu valodas datu kopa tika izveidota manuāli no jauna.
- Teksta apstrāde: darbā ir parādīts, ka pietuvināta morfoloģiskai segmentācija nedaudz uzlabo akurātību (+1pp), samazinot vārdu formu daudzveidību.

Piedāvātā modeļa ar pievienotiem NLIL veikspēja pārspēj bāzes modeļus:

- latviešu valodas datu kopā: +18pp uzlabojums salīdzinājumā ar bāzes modeli, +7pp salīdzinājumā ar modeli tikai ar leksiskajiem ievadparametriem;
- angļu valodas datu kopā: +19pp uzlabojums salīdzinājumā ar bāzes modeli, +6pp salīdzinājumā ar modeli tikai ar leksiskajiem ievadparametriem;
- tikai uz NLIL balstīts modelis (valodas neatkarīgs) sasniedza 40% akurātību, kas ir līdzīga modelim tikai ar leksiskajiem ievadparametriem (41%), pierādot neleksisko iezīmju izmantošanas efektivitāti.

Modeļa salīdzinājums ar lielajiem valodas modeļiem:

- GPT-3.5 Turbo un llama 1:8B uzrādīja bāzes līmeņa vai zemāku veikspēju.
- GPT-4o-mini sasniedza tikai modeļa ar leksiskajiem ievadparametriem akurātību, taču nepārsniedza izstrādātā modeļa akurātību.
- gemma 2:9B pārsniedza piedāvāto modeli angļu valodā (+7pp), bet atpalika latviešu valodā (-4pp).
- GPT-4o pārsniedza piedāvāto modeli abās valodās (+3pp latviešu valodā, +8pp angļu valodā), taču kā maksas lielais modelis tas nav tik pielāgojams kā piedāvātais vieglais, lokāli apmācāmais modelis.

Papildu secinājumi:

- Klientu atbalsta atbildes maz ietekmē neapmierinātības līmeņa samazināšanos, vidēji samazinot neapmierinātību tikai par 0,34 punktiem starp diviem secīgiem lietotāja ziņojumiem.
- Automātiska diakritisko zīmju noņemšana un pareizrakstības normalizācija neuzlaboja modeļa akurātību.
- NLIL iezīmes parādīja lielu prognozēšanas spēku, nodrošinot rezultātus, līdzīgus tradicionāliem leksiskiem ievadparametriem.

Promocijas darbs parāda, ka NLIL integrācija būtiski uzlabo neapmierinātības līmeņa prognozēšanu un piedāvā pielāgojamu alternatīvu liela mēroga valodas modeļiem, īpaši zemas resursu valodās, tādās kā latviešu. Tajā

² Datu kopas ir pieejamas <https://github.com/Lynxa/AnnotatedTweets/>

arī ir parādīts, ka no latviešu datu kopas iegūto NLIL raksturlielumu pievienošana frustrācijas anotēšanas modelim ir vienlīdz noderīga, ja to piemēro angļu valodas datu kopai. Tādējādi modelis ir efektīvi neatkarīgs no valodas (bet ne no kultūras) un var tikt izmantots frustrāciju noteikšanai angļu valodā un, iespējams, arī citās valodās, kurām ir tāda pati kultūras paradigma. Tā paplašināšana citās valodās ir atkarīga no attiecīgo kultūru pārstāvju izmantoto NLIL izpētes un ieguves.

1.7. Promocijas darba rezultātu aprobācija un publikācija

Autore ir vienīgā autore vai līdzautore šādos ar šo disertāciju saistītos rakstos, publicētos recenzējamos zinātnisko rakstu krājumos:

- Leonova, V., 2020. Review of non-English corpora annotated for emotion classification in text. In *Proceedings for Databases and Information Systems: 14th International Baltic Conference, (DB&IS 2020)*, 14 (pp. 96-108). Springer International Publishing.
- Zuters, J. and Leonova, V., 2020. Adaptive Vocabulary Construction for Frustration Intensity Modelling in Customer Support Dialog Texts. *International Journal of Computer Science & Information Technology (IJCSIT)* 12.
- Zuters, J. and Leonova, V., 2020, November. Frustration Intensity Prediction in Customer Support Dialog Texts. In *Proceedings for CS & IT Conference 10(14)*. CS & IT Conference Proceedings.
- Zuters, J., Strazds, G. and Leonova, V., 2019. Morphology-Inspired Word Segmentation for Neural Machine Translation. *Databases and Information Systems X* (pp.225-239).
- Leonova, V. and Zuters, J., 2021, September. Frustration Level Annotation in Latvian Tweets with Non-Lexical Means of Expression. In *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2021)* (pp. 814-823).
- Leonova, V. and Zuters, J., 2022. Frustration Level Analysis in Customer Support Tweets for Different Languages. In *Proceedings for 15th International Baltic Conference on Digital Business and Intelligent Systems (DB&IS 2022) Forum*.
- Leonova, V. and Zuters, J., 2022. Frustration Level in Customer Support Tweets: Towards a Language-Independent Model. *Baltic Journal of Modern Computing*, 10(4) (pp.738-753).

Četras publikācijas saistītas ar promocijas darbu, tika referētas sekojošās zinātniskās konferencēs:

- Leonova, V. Review of non-English corpora annotated for emotion classification in text. *Databases and Information Systems: 14th International Baltic Conference, DB&IS 2020, Tallinn, Estonia, June 16–19, 2020*.

- Zuters, J. and Leonova, V., Frustration Intensity Prediction in Customer Support Dialog Texts. 9th International Conference on Information Technology Convergence and Services ITCS 2020, Sydney, Australia, December 19-20, 2020.
 - Leonova, V. and Zuters, J., 2021. Frustration Level Annotation in Latvian Tweets with Non-Lexical Means of Expression. *International Conference on Recent Advances in Natural Language Processing (RANLP 2021)*, online, September 1-6, 2021.
 - Leonova, V. and Zuters, J., Frustration Level Analysis in Customer Support Tweets for Different Languages, 15th International Baltic Conference on Digital Business and Intelligent Systems DB&IS, Riga, Latvia, July 03-06, 2022.
- Promocijas darbā pētījums tika aprobēts sekojošā pētniecības projektā:
- Eiropas Reģionālās attīstības fonda atbalstīts SIA TILDE un Latvijas Universitātes kopprojekts „Daudzvalodu mākslīgā intelekta balstīta cilvēka un datora mijiedarbība” Nr. 1.1.1.1.1/18/A/148.

2. Promocijas darba kopsavilkuma apraksts

2.1. Literatūras apskats

Ir vispārzināms, ka internetā ir emocionāli piesātināts saturs, kura izmantošana varētu ievērojami palīdzēt ieteikumu sistēmu, tērēšanas robotu un citu rīku izstrādē. Tomēr automatizēta emociju atpazīšana tekstā ir problemātiska to subjektīvā rakstura dēļ un ierobežojumu dēļ, kas saistīti ar emocionālo nianšu izteikšanu tikai vārdos. Sarežģītību palielina arī pieturzīmju izmantošanas īpatnības, piemēram, punktu trūkums interneta žargonā (Khalifa, 2020).

Sākotnēji emociju atpazīšanas joma fokusējās uz runu, bet, attīstoties tādiem sociālajiem tīkliem kā *Facebook* un *X*, fokuss pievērsās tekstam (Dean, 2023). Tomēr būtisks ierobežojums ir tas, ka datu kopās, kuras ir atšķirīgas no angļu valodas, dominē pašaušanās uz Ekmana (Ekman, 1992) pamatemociju sistēmu (Leonova, 2020). Šī sistēma, kurā piedāvātas sešas pamatemocijas, tiek kritizēta par tās vienkāršību un patvaļīgumu (piemēram, Gendron et al., 2014), radot jautājumus par tās piemērojamību.

Attīstoties mašīnmācīšanās metodēm, it īpaši neironu tīkliem, emociju atpazīšana sāka tikt piemērota arī tekstiem (Moriyama un Ozawa, 1999). Neskatoties uz šo progresu, nozīmīgi trūkumi ir novērojami frustrācijas izpētē — vispārārtītas emocijas, kurai ir ļoti liela nozīme klientu apkalpošanas un atbalstā sfērā, kā arī pakalpojumu kvalitātes novērtēšanai (Stauss et al., 2005). Esošie pētījumi par frustrācijas anotēšanu ir nepietiekami un novecojuši (Klein et al., 2002; Hone, 2006), un jaunākie darbi lielā mērā fokusējas uz citiem mērķiem un metodēm (Hu et al., 2018).

Emociju klasifikācija parasti balstās uz vārdiem, jeb leksiskiem līdzekļiem, ar uzsvāru uz leksikonu būvēšanu. Lai gan dažos gadījumos tiek pētītas neleksiskās iezīmes, piemēram, emocijzīmes vai tēmturi (hashtag), to retā klātbūtne atsevišķos kontekstos apgrūtina to izmantošanu. Neleksiskās pazīmes ir vairāk attīstītas mutiskajā saziņā, un trūkst to sistemātiska pārskata uz tekstu balstītā emociju atpazīšanā.

Lielākā daļa jaunāko modeļu ir izstrādāta angļu valodai, un ir tikai daži, kas izstrādāti valodām ar zemu resursu apjomu. Tas norāda uz pētījumu trūkumu saistībā ar emociju atpazīšanas modeļu paplašināšanu, lai tie būtu piemērojami dažādiem lingvistiskajiem kontekstiem (Gruzitis et al, 2018).

Šajā promocijas darbā ir apvienots labākais no abām pieejām un risināta frustrācijas atpazīšana ar ierosinātā neironu tīkla modeļa palīdzību.

2.2. Datu kopas

Eksperimentiem tika izmantotas divas datu kopas. Pirmā — angļu valodas datu kopa, kas sastāv no 376 dialogu. Katra lietotāja ziņojumu novērtēja trīs

anotētāji, un eksperimentā tika izmantoti tikai „derīgi” ziņojumi, kuriem katrs no trīs ekspertiem bija piešķīris skaitlisku vērtību. Iegūto datu kopu veidoja 843 anotēti derīgi lietotāja ziņojumi un 470 derīgi atbalsta ziņojumi. Otrā — latviešu valodas datu kopa, kas sastāv no 283 dialogiem, kurus veido 688 lietotāja ziņojumi un 398 klientu atbalsta pārstāvja ziņojumi. Abu datu kopu veidošana ir aprakstīta sadaļā „Datu vākšana un sagatavošana”.

2.3. Datu vākšana un sagatavošana

Angļu valodā. Datu kopa ir izveidota, izmantojot *Kaggle Customer Support Twitter* datu kopu, sasaistot atbildes ar ziņojumu ID un izveidojot secīgus dialogus, kas satur mijiedarbību starp lietotājiem un klientu atbalsta pārstāvjiem. Anotēšanai tika atlasīta 400 dialogu apakškopa, nodrošinot vismaz 800 klientu atbildes. Dialogi tika anonimizēti, un lietotāja/atbalsta ID tika aizstāti ar birkām (labels). Anotētāji klientu ziņojumiem piešķīra vērtējumus, kur skaitliskas vērtības no 0 līdz 4 apzīmēja uztverto frustrācijas līmeni, „n” apzīmēja nespēju noteikt frustrācijas līmeni, bet tukšas vērtības norādīja uz nesaprotamu tekstu. Anotētāju vērtējumu nepretrunīguma (consistency) vērtēšanai tika izmērīta korelācija vienas klases ietvaros (intra-class correlation), kas norādīja uz vidējo līdz labo nepretrunīgumu abām valodām.

Latviešu valodā. Datu kopa ietver sarunas starp lietotājiem un četru lielāko Latvijas interneta un telekomunikāciju pakalpojumu sniedzēju klientu atbalsta pārstāvjiem: Tet, LMT, Bite un Tele2. Tā tika iegūta no šo pakalpojumu sniedzēju X kontiem. Katra saruna iekļauj vismaz divus lietotāja ziņojumus ar klientu atbalsta dienestu ziņojumu starp tiem, un dialogi ir latviešu valodā. Datu kopa tika apkopota manuāli, lai nodrošinātu kritēriju ievērošanu. To veido 283 dialogi, kas sniedz ieskatu par lietotāju un klienta atbalsta mijiedarbību X sociālā tīklā. Tāpat kā angļu valodas datu kopai, dialogi tika anonimizēti, un lietotāju vārdi un e-pasti tika aizstāti ar attiecīgajām birkām. Trīs anotētāji novērtēja uztverto frustrācijas līmeni klientu ziņojumos tādā pašā veidā kā angļu valodas datu kopai.

2.4. Datu apstrāde

Šajā posmā tika analizēta lietotāju ziņojumu pirmapstrādes ietekme latviešu un angļu valodā uz izstrādātā modeļa neapmierinātības prognozēšanas akurātību. Tika aplūkoti sarunvalodā bieži sastopamie sarunvārdi un izpētītas to unifikācijas iespējas ar domu, ka tas varētu uzlabot modeļa veiktspēju. Pirmapstrādes process ietver segmentāciju, diakritisko zīmju noņemšanu, abreviatūru un sarunvalodas normalizāciju.

Segmentācija tika pielietota latviešu valodas tekstiem, ņemot vērā tās fleksīvo dabu, ar ideju, ka vārdu sadalīšana aptuveni morfoloģiskās sastāvdaļās var samazināt gramatisko formu skaitu un attiecīgi uzlabot prognozēšanas

akurātību. Tika analizēta arī diakritisko zīmju noņemšana, jo sociālo tīklu tekstos lietotāji bieži tās izlaiž vai izmanto nepareizi tehnisku ierobežojumu vai gramatikas zināšanu trūkuma dēļ. Tika mēģināts arī aizstāt visbiežāk lietotos sarunvalodas izteicienus un apvienot abreviatūras, taču no visām metodēm tikai segmentācija demonstrēja redzamu efektu uz modeļa veiktspēju.

Datu kopās tika identificēti un analizēti NLIL, piemēram, pieturzīmes, tādas kā izsaukuma zīme, jautājuma zīme vai daudzpunkte, pilnībā lielajiem burtiem rakstīti vārdi, atkārtoti burti, emocijzīmes, tēmturi (hashtags) un ziņojuma garums, lai noteiktu to korelāciju ar neapmierinātības intensitāti. Izrādījās, ka ziņojuma garums ir visprecīzākais rādītājs, bet tādas iezīmes kā pieturzīmes un atsaucis uz institūcijām (piemēram, Patērētāju tiesību aizsardzības centru) arī uzrādīja pozitīvu korelāciju ar neapmierinātību. Tomēr atsevišķi elementi, piemēram, tēmturi, neietekmēja neapmierinātības prognozēšanu.

Noslēgumā var secināt, ka uz NLIL balstītu ievades parametru un datu segmentācijas kombinēta izmantošana būtiski uzlabo prognožu akurātību.

2.5. Pētījums

2.5.1. Eksperimenta dizains

Eksperimentiem tika izmantoti divi korpusi — angļu un latviešu valodā — ar dialogiem starp lietotāju un atbalstu X sociālajā tīklā. Katru lietotāja ierakstu novērtēja trīs anotētāji, un eksperimentu vajadzībām tika izmantoti tikai „derīgi” ieraksti — tie, kuriem visi trīs eksperti piešķīra skaitlisku vērtību. Daži ziņojumi bija grūti novērtējami, tāpēc pēdējā datu kopas versijā bija 843 (latviešu valodā — 688) anotēti derīgi lietotāja ziņojumi, kā arī 470 (latviešu valodā — 398) derīgi atbalsta speciālistu ziņojumi. Derīgs atbalsta ziņojums ir definēts kā ziņojums starp diviem derīgiem lietotāja ziņojumiem. Analizējot frustrācijas dinamiku dialogos, vidējā frustrācijas intensitātes izmaiņa no viena lietotāja ziņojuma līdz nākamajam bija $-0,35$, kas nozīmē, ka vispārīgā gadījumā tika novērots, ka frustrācijas intensitāte no viena ziņojuma līdz nākamajam ziņojumam samazinās, taču tikai nedaudz. Varēja sagaidīt, ka īsa dialoga laikā lietotāja frustrācijas intensitātes vērtējums vidēji paliks būtībā nemainīgs.

Ziņojuma teksta kodēšanai tika izveidotas divas atslēgvārdu vārdnīcas kā saraksti ar mazajiem burtiem rakstītiem atslēgvārdiem, kas derīgos ziņojumos parādījās vismaz trīs reizes, atsevišķi lietotāja ziņojumiem un atbalsta ziņojumiem. Atslēgvārdi tika sakārtoti pēc to vērtējuma noteiktības, un tikai konkrēts skaits vislabāko atslēgvārdu tika pielietots tālāk:

- lietotāja ziņojumiem atslēgvārdi tika kārtoti pēc to ziņojumu vērtējumu standartnovirzes, kuros parādījās konkrētais atslēgvārds;

- atbalsta ziņojumiem atslēgvārdi tika kārtoti pēc divu blakus esošo lietotāju ziņojumu vērtējumu starpības standartnovirzes attiecībā pret ziņojumiem, kuros parādījās konkrētais atslēgvārds.

Tādējādi tika iegūtas divas vārdnīcas: lietotāja atslēgvārdu vārdnīca un atbalsta atslēgvārdu vārdnīca. Atsevišķi dialoga ziņojumi eksperimentos tika attēloti kā vārdu maisi (*bag of words*), izmantojot labākos atslēgvārdus no vārdu krājuma un pierakstot 1 vai 0 katram atslēgvārdam atkarībā no tā, vai tas parādās ziņojumā:

- kodēšana tika veikta atsevišķi lietotāja ziņojumiem un atbalsta ziņojumiem;
- dažādos eksperimentos tika izmantots atšķirīgs „labāko atslēgvārdu” skaits: atslēgvārdu skaitu noteica faktiskā eksperimenta konfigurācija.

Papildus tika pārbaudītas datu kopas un identificēti visi NLIL. Kā ievadparametri tika izmantoti tie, kuriem bija vislielākā korelācija starp uz NLIL balstīto metriku un frustrācijas (neapmierinātības) vērtējumu.

Prognozes modelis tika veidots kā lineārs vienvirziena neironu tīkls, izmantojot vārdu maisu un (uzlabotā modeļa gadījumā) uz NLIL balstītās metrikas, kas aprēķinātas attiecīgajam sociālo mediju ziņojumam, un izvades datus tika iegūts prognozētais frustrācijas līmenis diskrētā skalā no 0 līdz 4. Faktiskie modeļa parametri tika pielāgoti tālāk aprakstīto eksperimentu gaitā.

Prognozes modeļa novērtēšanai tika izmantoti akurātības rādītāji. Tā kā prognožu klases [0..4] ir sakārtotas, tika ieviesta arī vājāka novērtēšanas metrika — akurātība ar pielaidi ± 1 (par pareizu tiktu uzskatīta arī prognoze, kas „atšķiras par vienu”). Akurātība ar pielaidi ir šķietami labi piemērota šiem uzdevumiem, jo, piemēram, prognozēt 2, ja „īstais” vērtējums ir anotēts kā 3, ir mazāk nepareizi, kā prognozēt 0 šādā pašā situācijā.

2.5.2. Pirmā fāze: dinamika dialogos (izmantojot angļu valodas datu kopu)

- Mērķi: Šī posma mērķis bija pārbaudīt hipotēzes par lietotāju frustrācijas intensitātes prognozēšanu klientu atbalsta dialogos. Tika pārbaudītas divas galvenās hipotēzes, kas ietvēra frustrācijas prognozēšanu no lietotāju ziņojumiem un klientu atbalsta reakcijas ietekmi uz lietotāju frustrācijas dinamiku.
- Metodoloģija: Tika izmantots dialogu korpus, anotēts ar frustrācijas līmeņiem. Pētījumā tika izmantotas atslēgvārdu vārdnīcas, vārdu maisu kodēšana un prognozēšanas modeļi, lai analizētu frustrācijas dinamiku klientu sarunās ar atbalstu.
- Rezultāti: Pētījumā tika novērota neliela frustrācijas intensitātes samazināšanās no ziņojuma uz ziņojumu, taču klientu atbalsta atbilde saturā izmantošana nepalīdzēja prognozēt lietotāju turpmāko emocionālo stāvokli. Pētījuma pirmajā posmā tika pārbaudītas divas hipotēzes, kas attiecās uz frustrāciju klientu atbalsta dialogos, izmantojot angļu valodas datu kopu. Šajās

hipotēzēs tika pētīta lietotāja frustrācijas intensitātes prognozējamība, pamatojoties uz lietotāja ziņojumu tekstu, un klientu atbalsta reakciju ietekme uz lietotāja emocionālo stāvokli. Rezultāti parādīja, ka ierosinātais, uz neironu tīklu balstītais modelis, spēj prognozēt lietotāja neapmierinātības intensitāti, izmantojot lietotāja ziņojumu tekstu. Modelis pārspēja bāzes modeli, kas visos gadījumos piešķīra vienu un to pašu visbiežāk sastopamo vērtējumu, sasniedzot 71% akurātību ar pielaidi.

Pētījumā tika pētīta arī frustrācijas intensitātes dinamika, paredzot lietotāja emocionālā stāvokļa izmaiņas, pamatojoties uz atbalsta speciālista atbildi. Tomēr rezultāti liecināja, ka atbalsta speciālista ziņojuma saturs izmantošana būtiski neuzlaboja lietotāja frustrācijas stāvokļa izmaiņu prognozēšanu.

2.5.3. Otrā fāze: frustrācijas līmenis un frustrācijas dinamika dialogos (izmantojot latviešu valodas datu kopu)

- Mērķi: Paplašinot pirmo fāzi ar latviešu valodas datu kopu, šajā fāzē tika pārbaudītas analogiskas hipotēzes klientu atbalsta dialogiem latviešu valodas kontekstā.
- Metodoloģija: Tika izveidota jauna datu kopa latviešu valodā, kas tika apstrādāta līdzīgi angļu valodas datu kopai. Rezultāti tika salīdzināti ar angļu valodas datu kopu, lai novērtētu secinājumu pārnēsāmību starp valodām.
- Rezultāti: Pētījumā tika konstatēta līdzība starp angļu un latviešu valodas datu kopu frustrāciju prognozēšanas modeļu efektivitāti, kas norāda, ka ierosinātā pieeja varētu būt efektīva neatkarīgi no valodas.

Šajā fāzē pētījums tika paplašināts, iekļaujot arī frustrācijas līmeni un dinamiku Latvijas klientu atbalsta dialogos. Hipotēzes, kas atkārtoja primārajā posmā izvirzītās hipotēzes, tika pārbaudītas ar jaunizveidotu latviešu valodas datu kopu. Modeļa pielāgošana ietvēra dažādu metaparametru un datu apstrādes metožu konfigurāciju izpēti.

Latviešu valodas datu kopa, kas tika iegūta no lielāko telekomunikācijas pakalpojumu sniedzēju X kontiem, tika apstrādāta līdzīgi angļu valodas datu kopai. Ierosinātā modeļa efektivitāte tika novērtēta, izmantojot akurātības rādītājus, par bāzes vērtību nosakot visbiežāk sastopamo vērtību.

Rezultāti liecina, ka nemodificētā modeļa akurātība latviešu valodas datu kopai ir salīdzināma ar bāzes modeļa efektivitāti. Sīkāki secinājumi un salīdzinājumi ir pieejami attiecīgajās pētījuma sadaļās.

2.5.4. Trešā fāze: modeļa paplašināšana ar datu apstrādi un NLIL funkcijām (latviešu valodā)

- Mērķi: Šajā posmā tika pētīta vārdu segmentācijas, ziņojumu unifikācijas un uz NLIL balstītu ieejas parametru ietekme uz frustrācijas prognozēšanas modeļu akurātību latviešu valodā.

- Metodoloģija: Tika pārbaudītas dažādas konfigurācijas, ieskaitot dažādas NLIL-balstīto parametru apakškopas un datu apstrādes metodes. Pētījuma mērķis bija optimizēt modeļa efektivitāti, iekļaujot NLIL-balstītus parametrus un teksta apstrādi.
- Rezultāti: NLIL raksturlielumu, piemēram, ziņojuma garuma un pieturzīmju skaita, iekļaušana uzlaboja frustrācijas prognozēšanas modeļu akurātību. Datu apstrādes metodes, piemēram, segmentācija, arī nedaudz uzlaboja modeļu efektivitāti.

Trešajā posmā pētījums bija veltīts modeļa paplašināšanai ar datu apstrādi un NLIL raksturlielumiem ar mērķi uzlabot frustrācijas intensitātes prognozēšanu klientu atbalsta dialogos latviešu valodā. Tika analizētas hipotēzes, kas saistītas ar gramatikas, diakritisko zīmju, akronīmu un NLIL ietekmi uz uzbūvētā modeļa akurātību. Tika pēģināta NLIL raksturlielumu un dažādu datu apstrādes metožu ietekme uz modeļa akurātību.

Rezultāti parādīja, ka segmentācija nedaudz uzlaboja akurātību, bet saīsinājumu aizstāšanai bija neviennozīmīga ietekme. NLIL pazīmju — tostarp ziņojuma garuma, izsaukuma zīmju, jautājuma zīmju un punktu skaita — iekļaušana pozitīvi ietekmēja akurātību. Izveidotajā modelī tika iekļauti visi identificētie NLIL-balstītie parametri.

Pētījumā tika pārbaudītas arī NLIL metrikas frustrācijas intensitātes prognozēšanai angļu valodas ziņojumos, atklājot līdzības starp latviešu un angļu valodu metriku ietekmes ziņā. Tika identificētas metrikas ar vislielāko ietekmi, kā arī noteikts, ka modelis sasniedza salīdzināmus rezultātus abās valodās. Turklāt tika pēģināti tādi metaparametri kā slēpto neironu skaits un vārdnīcas lielums. Ziņojumu segmentācija ar 64 slēptajiem neironiem un 100 vārdu vārdnīcām demonstrēja visaugstāko efektivitāti, demonstrējot 7pp uzlabojumu salīdzinājumā ar veco modeli.

Šajā posmā modelis tika veiksmīgi paplašināts, iekļaujot NLIL parametrus un optimizējot metaparametrus, šādā veidā uzlabojot akurātību gan latviešu, gan angļu valodas datu kopā.

2.5.5. Ceturtā fāze: no valodas neatkarīgs modelis

- Mērķi: Šajā posmā tika pēģināta no valodas neatkarīga modeļa uzbūve — no modeļa ieejas parametriem tika izslēgta leksiskā informācija, un modelis tika darbināts ar nulles izmēra vārdnīcu.
- Metodoloģija: Pētījumā tika testēts no valodas neatkarīgs modelis ar dažādu slēpto neironu skaitu, lai novērtētu tā efektivitāti frustrācijas intensitātes prognozēšanā dažādās valodās, neizmantojot valodai specifisku leksisko materiālu.
- Rezultāti: No valodas neatkarīgais modelis ir perspektīvs, jo, prognozējot frustrāciju, tas balstās tikai uz NLIL metrikām, tādējādi potenciāli nodrošinot pieeju, kas būtu piemērojama dažādās valodās.

Ceturtajā fāzē tika izpētīta no valodas neatkarīga modeļa uzbūve, darbinot to ar vārdnīcas izmēru nulle. Šī modifikācija pārveidoja modeli jaunā versijā, kas izmanto tikai uz NLIL balstītus ieejas parametrus, tādējādi frustrācijas noteikšanā novēršot atkarību no ziņojumos esošā leksiskā materiāla. Modelis tika testēts ar dažādu slēpto neironu skaitu, un tika identificēts visefektīvākais variants. Pētījumā tika novērtēta šī no valodas neatkarīgā modeļa efektivitāte frustrācijas intensitātes prognozēšanā, nepāļaujoties uz konkrētai valodai specifisku leksisko informāciju.

Šie posmi kopā veido izpēti frustrācijas līmeņa un frustrācijas līmeņa dinamikas prognozēšanā klientu atbalsta dialogos, ņemot vērā gan valodai raksturīgos, gan no valodas neatkarīgos aspektus.

2.6. Salīdzinājums ar lielo valodas modeļu efektivitāti ziņojumu anotēšanā

Lai novērtētu ierosinātā modeļa efektivitāti, tas tika salīdzināts ar pieciem pazīstamiem lielajiem valodas modeļiem, proti, GPT-3.5, GPT-4o mini, GPT-4o, llama un gemma. Eksperimentos šie modeļi tika izmantoti šādās versijās: GPT-3.5 Turbo (OpenAI, 2022), GPT-4o mini (OpenAI, 2024), GPT-4o (OpenAI, 2024), llama3:8b (Ollama, 2024), llama3:8b-uncensored (Sun, 2024), gemma1:7b (Ollama, 2024), gemma2:9b (Ollama, 2024).

Lai rezultāti būtu salīdzināmi, kā ziņojumu un anotētāju piešķirto atzīmju avots tika izmantotas tās pašas datu kopas. Minētie lieli valodas modeļi tika savukārt pielietoti, lai anotētu ziņojumus frustrācijas līmeņiem, izmantojot īpaši šim nolūkam konstruētas un pielāgotas uzvednes (prompts), un rezultāti tika salīdzināti ar ierosinātā modeļa efektivitāti.

1. tabula. Lielo valodas modeļu akurātība, ievadam izmantojot angļu un latviešu valodas datus

Modelis	Akurātība (<i>accuracy</i>) salīdzinājumā ar cilvēkiem-annotētajiem angļu valodai, %	Akurātība (<i>accuracy</i>) salīdzinājumā ar cilvēkiem-annotētajiem latviešu valodai, %
gemma2:9b	56	44
GPT-3.5 Turbo	28	33
GPT-4o mini	39	48
GPT-4o	57	52
bāzlīnija	28	31
modelis bez NLIL	42	41
ierosinātais modelis ar NLIL	49	49

Šajā tabulā (1. tabulā) parādīta šādu modeļu efektivitāte salīdzinājumā ar piedāvāto pielāgoto NLIL modeli: gemma2:9b, GPT-3.5 Turbo, GPT-4o mini un GPT-4o. llama3:8b un llama3:8b-uncensored latviešu datu kopai uzrāda attiecīgi 27% un 22% akurātību, savukārt gemma1:7b pareizi prognozē atzīmes 13% gadījumu, nesasniedzot pat bāzlīniju (baseline), tāpēc šie valodas modeļi tika izslēgti no turpmākajiem eksperimentiem.

Acīmredzams, ka GPT-3.5 Turbo nav piemērots šim uzdevumam, jo ir gandrīz precīzi vienāds ar bāzlīnijas līmeni. GPT-4o mini parāda labākus rezultātus, sasniedzot ierosinātā modeļa bez NLIL līmeni angļu valodas datiem un gandrīz sasniedzot uzlabotā modeļa akurātību (*accuracy*) latviešu valodai (1pp atšķirība). GPT-4o un gemma2:9b sasniedz labākus rezultātus, parādot, ka lielais valodas modelis var noteikt frustrācijas līmeni labāk nekā piedāvātais modelis, tomēr sasniegtie rezultāti ir salīdzināmi — GPT-4o ir 3pp priekšrocība latviešu valodas datu kopai un 8pp angļu valodas datu kopai, kamēr gemma2:9b ir līdzīga 7pp priekšrocība angļu valodā, bet tomēr tā ir tikai nedaudz labāka

(3pp) par modeli bez NLIL latviešu valodā. Iespējams izskaidrojums ir tāds, ka šī valodas modeļa apmācībai izmantotie materiāli bija angļu, nevis latviešu valodā. Vienlaicīgi tas parāda, ka ierosinātā modeļa demonstrētos rezultātus var atkārtot ar vispārējas nozīmes NLIL, piemēram, gpt-4o, tādējādi netiešā veidā apstiprinot sasniegtos rezultātus.

2.7. Galvenie rezultāti

Galvenie šajā darbā demonstrētie rezultāti ir šādi:

1. Divas jaunas datu kopas — attiecīgi latviešu un angļu valodā.
2. Saraksts ar visiem identificētiem NLIL, ko sociālo mediju lietotāji izmanto sarunās ar klientu atbalsta speciālistiem.
3. Uz neironu tīkliem balstītais modelis lietotāju ziņojumu anotēšanai ar uztverto lietotāju frustrācijas līmeni.

2.7.1. Datu kopas

Šajā pētījumā tiek sniegtas un aprakstītas divas datu kopas: latviešu valodā un angļu valodā. Šīs datu kopas ietver klientu atbalsta dialogus, un tās tika izmantotas neironu tīklu modeļa apmācībai un novērtēšanai attiecībā uz neapmierinātības prognozēšanu. Angļu valodas datu kopa ir balstīta uz Kaggle Twitter klientu atbalsta dialogiem un ietver gandrīz 400 sarunas ar kopumā 900 ziņojumiem, kas anotēti ar neapmierinātības intensitāti skalā no 0 līdz 4. Latviešu valodas datu kopa tika manuāli savākta no lielāko interneta un telekomunikāciju pakalpojumu sniedzēju X kontiem, un tajā ir 283 dialogi ar 688 lietotāju replikām un 398 klientu atbalsta pārstāvju atbildēm, kur visiem lietotāju ziņojumiem ir līdzīgi ticis anotēts neapmierinātības līmenis.

2.7.2. NLIL saraksts

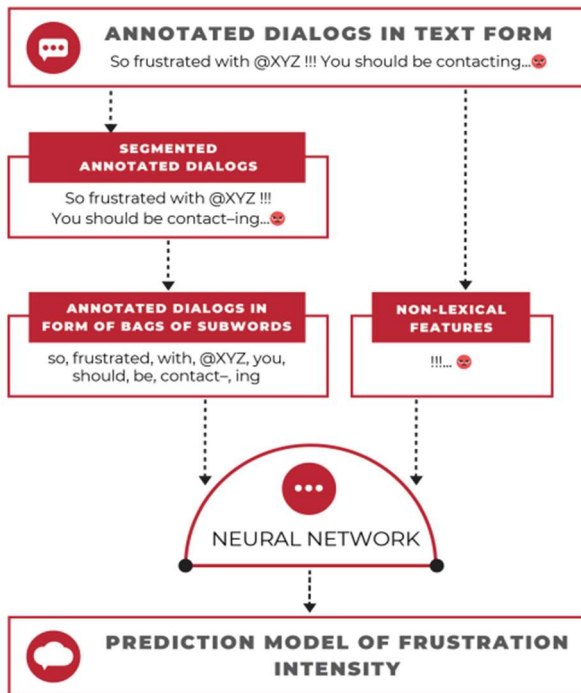
Šajā pētījumā ir sniegts saraksts ar NLIL, kas tika identificēti pēc datu kopu izpētes. To iekļaušana uzlabo emociju anotēšanas akurātību, kas tiek parādīts attiecībā uz uztverto frustrācijas līmeni. NLIL saraksts ir sniegts 2. tabulā.

2. tabula. Identificētie NLIL un to korelācija ar anotēto frustrācijas līmeni

Raksturlielums	Korelācija ar frustrācijas līmeņa mediānas vērtību
Izsaukuma zīmju skaits ziņojumā	ļoti vāja pozitīva korelācija (0,05).
Izsaukuma zīmju skaits ziņojumā, normalizēts pēc ziņojuma garuma	vāja negatīva korelācija (-0,10).
Jautājumu zīmju skaits ziņojumā	vāja pozitīva korelācija (0,14).
Komatu skaits ziņojumā	vāja pozitīva korelācija (0,26).
Punktu skaits ziņojumā	vāja pozitīva korelācija (0,28).
Pēdiņu skaits (‘, ’, “, ”, ` , ") ziņojumā	vāja pozitīva korelācija (0,13).
Ar lielajiem burtiem rakstīto vārdu, kas garāki par 4 simboliem, skaits ziņojumā	vāja pozitīva korelācija (0,12).
Burta „a” atkārtošana vairāk nekā divas reizes pēc kārtas ziņojumā.	ļoti vāja pozitīva korelācija (0,07).
Emocijzīmju skaits ziņojumā neatkarīgi no noskaņojuma	vāja pozitīva korelācija (0,14).
Pozitīvo emocijzīmju (<i>positive smileys</i>) (veidotu no tipogrāfijas zīmēm) skaits ziņojumā	ļoti vāja negatīva korelācija (-0,09)
Negatīvo emocijzīmju (<i>negative smileys</i>) (veidotu no tipogrāfijas zīmēm) skaits ziņojumā	ļoti vāja pozitīva korelācija (0,04).
Attēla klātbūtne ziņojumā	ļoti vāja pozitīva korelācija (0,05).
Atsauce uz PTACGovLV ziņojumā	vāja pozitīva korelācija (0,10).
Ziņojuma garums	vidējā pozitīvā korelācija (0,44).

2.7.3. Modelis

Šajā darbā ir piedāvāts uz neironu tīklu balstīts modelis, kas, pateicoties interaktīva vārdu krājuma izveidei un NLIL metrikai kā ieejas parametru izmantošanai, var darboties kā no valodas neatkarīgs modelis, kas var anotēt frustrācijas līmeni lietotāja ziņojumā sociālajos medijos ar akurātību, kas ievērojami pārsniedz bāzlīniju: 48% un 49% precīzai anotēšanai respektīvi angļu un latviešu valodā, un 80% un 90% aptuvenai anotēšanai. Modeļa augsta līmeņa shēma ir parādīta 1. attēlā.



1. attēls. Augsta līmeņa shēma frustrācijas līmeņa prognozēšanas modelim, kurā iekļauti uz NLIL balstīti parametri.

2.8. Diskusija un interpretācija

Ierosinātais, uz neironu tīklu balstītais modelis izmanto adaptīvu vārdnīcas izveidošanu un prognozē lietotāja frustrācijas intensitāti no klienta atbalstam adresēta lietotāja ziņojuma teksta. Šis modelis kā ievades parametrus izmanto iekodētu lietotāja ziņojuma attēlojumu un sniedz rezultātu kā frustrācijas intensitātes veselu skaitļu vērtējumu 5 punktu skalā (no 0 līdz 4). Modeļa rezultējoša akurātība tika salīdzināta ar bāzes scenāriju, kurā visiem ziņojumiem

vienkārši piešķir visbiežāk sastopamo birku (28%). Papildus precīzai akurātībai tika aprēķināta arī akurātība ar pielaidi (pieļaujot starpību 1 starp faktisko un prognozēto novērtējumu). Izmantojot šo „±1 akurātības” metriku, modeļa efektivitāte ir salīdzināta ar atbilstošo bāzliniju (71% šai metrikai). Adaptīva vārdnīcas konstruēšana ļauj apmācīt modeli, izmantojot nelielu datu kopu, kas ir īpaši svarīgi zemu resursu valodām. Gan angļu valodas, gan latviešu valodas datu kopai labākie rezultāti precīzās akurātības ziņā tiek sasniegti, izmantojot vārdnīcu, kas satur 100 labākos prediktorus (*predictors*), bet labākie rezultāti akurātībai ar pielaidi 1 tiek sasniegti, izmantojot vārdnīcu ar 300 labākajiem prediktoriem. Labākie prediktori tiek definēti kā vārdi (vai vārdu fragmenti), kuriem atbilst viszemākā standartnovirze frustrācijas vērtējumam, ko anotētāji piešķirušī visiem konkrēto vārdu saturošiem ziņojumiem. Šī apmācības metode uzlabo prognozēšanas akurātību par 13pp un 11pp precīzai akurātībai respektīvi angļu un latviešu valodas datiem, un par 9pp akurātībai ar pielaidi 1 abām valodām, ko var attiecināt uz to, ka jau sākotnēji bāzes līmenis ir samērā augsts.

Šajā darbā aprakstīta arī eksperimentu virkne, kurā tika pētīta lietotāja frustrācijas līmeņa dinamika sarunas gaitā un tās korelācija ar klientu atbalsta pārstāvja ziņojuma saturu. Pētījumā tika secināts, ka izmantotās metodes nav ļāvušas prognozēt frustrācijas līmeni, izmantojot šo pieeju, labāk nekā bāzes scenārijā.

Modelis tika izveidots, izmantojot interaktīvo vārdnīcas konstruēšanu un uz NLIL balstītus parametrus. Eksperimenti liecina, ka uz NLIL balstītas metrikas uzlabo frustrāciju līmeņa prognozēšanas akurātību par 7pp. NLIL būtības dēļ tie ir atkarīgi no valodas tikai ierobežotā mērā. Salīdzinot modeļa efektivitāti, izmantojot latviešu un angļu valodu datu kopas, redzams, ka abos gadījumos prognozēšanas akurātības uzlabojums ir vienāds. Tas nozīmē, ka, kamēr NLIL lietošanas modeļi sociālajos tīklos ir vienādi, modelis ir efektīvi neatkarīgs no valodas.

Datu kopām piemērotā datu segmentācija arī nodrošināja līdzīgu uzlabojumu latviešu un angļu datu valodu kopām — aptuveni 1pp. Lai gan tādai sintētiskai valodai kā latviešu valoda tas bija sagaidāms, uzlabojums, kas bija redzams angļu valodas datu kopai, nozīmē, ka angļu valodā ir pietiekams gramatisko formu skaits, lai segmentācija varētu nozīmīgi ietekmēt rezultātu.

Kopumā rezultāti liecina, ka, izmantojot interaktīvo vārdnīcas konstruēšanu, NLIL un segmentāciju, var prognozēt uztverto frustrācijas līmeni, izmantojot nelielas datu kopas modeļa apmācīšanai neatkarīgi no konkrētās valodas.

Salīdzinājums ar lielajiem valodas modeļiem. Modeļa akurātība tika salīdzināta ar tādiem LLM kā GPT3.5-turbo, GPT 4o-mini un GPT-4o, gemma 1:7, gemma 2:9b, kā arī llama 3:8b. Rezultāti liecina, ka GPT-3.5 Turbo, llama 3:8b, gemma 1:7b un GPT4o-mini parāda sliktākus rezultātus nekā ierosinātais modelis, savukārt gemma-2:9b nodrošina labāku akurātību angļu valodā un sliktāku latviešu valodā, bet GPT-4o — ievērojami (8pp) un nedaudz (3pp) labāku akurātību respektīvi gan angļu, gan arī latviešu valodā.

3. Pētījuma piemērojamības ierobežojumi

Ierosinātais modelis ir efektīvi neatkarīgs no valodas (bet ne no kultūras), un to var izmantot frustrācijas atpazīšanai angļu valodā un, iespējams, arī citās valodās, kurām ir tāda pati kultūras paradigma un kuras attiecīgi izmanto NLIL līdzīgā veidā. Vienīgais priekšnoteikums tam ir datu kopas pieejamība, kas anotēta saderīgā veidā. Tā kā demonstrētie rezultāti tika sasniegti ar nelielu datu kopu, ieguldījums, kas būtu nepieciešamas, lai to nodrošinātu arī citai valodai, nebūtu pārāk apjomīgs.

Protams, modeļa piemērošana citām valodām vēl ir jāpārbauda, un pašlaik tā aprobežojas ar izteiksmes līdzekļiem, kas ir kopīgi Eiropas valodu lietotājiem. Tā attiecināšana uz citām valodām ir atkarīga no attiecīgo kultūru pārstāvju izmantoto NLIL izpētes un ekstrahēšanas.

Šī darba pētāmo jomu ierobežo arī pētāmā emocija un medijs. Modelis mēra tikai frustrācijas līmeni, kas izteikts tekstos sociālajos medijos, lai gan ir pamats domāt, ka arī citas emocijas varētu korelēt ar dažādiem NLIL, kas atrodas tekstā. Līdzīgā veidā šajā darbā tiek pētīts tikai konkrēts runas veids — tā sauktā mutvārdu runa rakstiskā formā, un tieši interneta runa, kas atrodas kaut kur starp mutvārdu runu un rakstītu tekstu. Tādējādi tajā tiek ņemts vērā konkrēts NLIL kopums, kas iegūts no sniegtās datu kopas.

4. Galvenie secinājumi un priekšlikumi

Šajā darbā ir ierosināti vairāki rezultāti frustrāciju atpazīšanas un novērtēšanas jomā sociālo mediju ziņojumos.

Tas piedāvā jaunu pieeju emociju anotēšanai, kurā, lai noteiktu ziņojuma autora emocionālo stāvokli, papildus pašu vārdu emocionālajai nokrāsai tiek izmantoti NLIL. Šajā darbā izmantotie NLIL ietver gan „tradicionālos” līdzekļus, piemēram, izsaukuma zīmes, gan nestandarta līdzekļus, piemēram, punktu skaitu ziņojumā, gan sociālajiem medijiem raksturīgos līdzekļus, piemēram, emocijzīmes. Šajā pētījumā ir sniegts apkopotais NLIL saraksts un izskaidrota to loma frustrācijas līmeņa noteikšanā. Tajā arī demonstrēta jauna pieeja ziņojumu leksiskās informācijas izmantošanai, proti, interaktīva labākās prediktoru vārdnīcas uzbūve. Tajā arī ierosināts izmantot datu segmentāciju akurātības uzlabošanai.

Šajā pētījumā ir ierosināts modelis, kas izmanto gan uz NLIL balstītas metrikas, konstruētas, pamatojoties uz ziņojumos atrodamo neleksisko informāciju, gan vārdu maisu, kas tiek iegūts no ziņojuma, izmantojot interaktīvi uzbūvētu vārdnīcu, un turklāt ievada apstrādei izmanto segmentāciju, kas ir līdzīga morfoloģiskai, lai palielinātu vārdnīcas konstruēšanas efektivitāti. Citas ievades apstrādes metodes, konkrēti — diakritisko zīmju dzēšana un populārāko pareizrakstības variāciju unificēšana, nedeva apmierinošus rezultātus, pat ja tās tika izmantotas vienlaikus.

Modeļa efektivitātes novērtēšanai tika izmantota vienu elementu izslēdzošā („leave-one-out”) šķērsvalidācija, apmācot modeli uz visas datu kopas, izņemot vienu elementu, nosakot modeļa prognozēto izlaistā elementa frustrācijas līmeni un atkārtotot šo procedūru katram datu kopas ierakstam, aprēķinot akurātību kā to ierakstu īpatsvaru, kuriem frustrācijas līmeni modelis prognozējis pareizi, turklāt atkārtotot aprēķinu vairākas reizes un ņemot vidējo vērtību. Ierosinātais modelis tika salīdzināts ar modeli, kas izmantoja tikai uz leksikas iezīmēm balstītu ievades informāciju.

Lai arī modelis, kas izmantoja tikai interaktīvi veidotu vārdnīcu, uzrādīja 11pp uzlabojumu salīdzinājumā ar bāzlīniju, jaunais modelis, kas tika piemērots latviešu datu kopai, sasniedza 17pp akurātības uzlabojumu salīdzinājumā ar bāzlīniju un 5pp salīdzinājumā ar modeli bez NLIL. Pārbaudot rezultātu, ko radīja papildu ievades apstrāde ar teksta segmentāciju un koriģējot metaparametrus, izrādījās, ka šāda segmentācija nodrošina papildus 1pp uzlabojumu, kas kopumā dod 18pp uzlabojumu salīdzinājumā ar bāzlīniju un 7pp uzlabojumu salīdzinājumā ar modeli, kas izmanto tikai leksiskās pazīmes. Tas pats modelis, pielietojot to angļu valodas datu kopai, sasniedz 47% akurātību, kas attiecīgi sniedz 19pp un 6pp akurātības pieaugumu. Tomēr, ja metrikas tiek pielāgotas atbilstoši angļu valodas datiem, iegūtā akurātība angļu valodas datu kopā ir 49%, kas ir par 21pp augstāka nekā bāzes scenārijam un par 8pp precīzāka nekā modelim bez NLIL pazīmēm.

Ierosinātais modelis tika papildus salīdzināts ar liela mēroga valodas modeļiem, secinot, ka tas pārspēj mazāk attīstītos modeļus, piemēram, llama3:8b un GPT-4o mini, bet angļu valodas datiem to ievērojami pārspēj GPT-4o (8pp) un gemma2:9b (7pp), lai gan latviešu valodā to pārspēj tikai GPT-4o un tikai nedaudz (3p), kas liecina par sasniegto rezultātu pamatošību.

Kā starpposms šajā pētījumā ir izstrādāts jauns uz neironu tīklu balstīts modelis, kas izmanto interaktīvu vārdnīcu, lai prognozētu frustrācijas intensitāti klientu ziņojumos sarunās ar klientu atbalsta pārstāvjiem. Vispopulārākā vērtējuma piešķiršana visiem ziņojumiem tika izmantota kā bāzlīnija, un tika pierādīts, ka frustrācijas intensitāti atsevišķā ziņojumā var prognozēt, pamatojoties uz tā saturu. Šīs prognozes akurātība ievērojami pārsniedz bāzlīniju (41% pret 27% angļu valodas gadījumā un 31% pret 42% latviešu valodas gadījumā). Pētot klientu atbalsta ziņojumu ietekmi uz lietotāja emocionālo stāvokli, tika konstatēts, ka parasti lietotāja emocionālais stāvoklis gandrīz nemainās, no viena ziņojuma līdz nākamajam vidēji nedaudz samazinoties par 0,34 punktiem. Ņemot vērā problēmas, kas saistītas ar precīzu lietotāja frustrācijas līmeņa mērīšanu, mēģinājums modelēt šo dinamiku kā funkciju no atbalsta aģenta ziņojumu emocionālās valences šī eksperimenta gaitā nav guvis panākumus.

Eksperimentu laikā tika pārbaudīts vēl viens modelis. Tajā kā ieejas parametri tika izmantoti tikai uz NLIL balstīti rādītāji, un tika konstatēts, ka šā modeļa akurātība (40%) būtiski neatšķiras no interaktīvi konstruētā uz vārdu

maisa balstītā modeļa akurātības (41%). Šis modelis ir pilnībā neatkarīgs no valodas un parāda, ka leksisko un neleksisko izteiksmes līdzekļu izmantošana dod līdzīgus rezultātus.

Šajā pētījumā ir arī sniegtas un aprakstītas divas datu kopas — attiecīgi latviešu un angļu valodā. Tās satur dialogu kopas attiecīgajās valodās starp lietotāju un klientu atbalsta dienesta pārstāvi, kuros ir vairāk nekā viens lietotāja ziņojums. Šīs datu kopas tika izmantotas, lai apmācītu un novērtētu aprakstīto uz neironu tīklu balstīto modeli frustrācijas līmeņa prognozēšanai, kā arī lai nodemonstrētu NLIL lomu frustrācijas prognozēšanā un atšķirības frustrācijas novērtēšanā abās valodās. Datu kopa angļu valodā tika izstrādāta, izmantojot *Kaggle Twitter* klientu atbalsta dienesta klientu apkalpošanas dialogu apakškopu, kuru veido gandrīz 400 dialogi un kas ietver gandrīz 900 atsevišķus ziņojumus. Latviešu valodas datu kopa tika apkopota manuāli no lielāko interneta un telekomunikāciju pakalpojumu sniedzēju *X* kontiem, un kopā tajā ir 283 dialogi ar 688 lietotāja un 398 klientu atbalsta dienesta pārstāvja ierakstiem. Abās datu kopās katram lietotāja ierakstam ir anotēta frustrācijas intensitāte skalā no 0 līdz 4.

Bibliogrāfija

- Axelbrooke, S., 2017. Customer Support on Twitter [Data set]. Kaggle. Retrieved 9 August 2020 from: <https://www.kaggle.com/thoughtvector/customer-support-on-twitter>
- Ayata, D., Yaslan, Y. and Kamasak, M.E., 2020. Emotion recognition from multimodal physiological signals for emotion aware healthcare systems. *Journal of Medical and Biological Engineering* 40(2) (pp.149-157).
- Dean, B., 2023, 27 March. *Social Network Usage & Growth Statistics: How Many People Use Social Media in 2023?* Backlinko. Retrieved 1 November 2023 from: <https://backlinko.com/social-media-users>
- Ekman, P., 1992. An Argument for Basic Emotions. *Cognition & Emotion* 6(3-4) (pp. 169–200).
- Gendron, M., Roberson, D., van der Vyver, J.M. and Barrett, L.F., 2014. Perceptions of emotion from facial expressions are not culturally universal: evidence from a remote culture. *Emotion*, 14(2) (p. 251).
- Gruzitis, N., Nespore-Berzkalne, G. and Saulite, B., 2018, May. Creation of Latvian FrameNet based on universal dependencies. In *Proceedings of the International FrameNet Workshop (IFNW)* (pp. 23-27).
- Hu, T., Xu, A., Liu, Z., You, Q., Guo, Y., Sinha, V., Luo, J. and Akkiraju, R., 2018. Touch your heart: A tone-aware chatbot for customer care on social media. In *Proceedings of the 2018 CHI conference on human factors in computing systems* (pp. 1-12).
- Klein, J., Moon, Y. and Picard, R.W., 2002. This computer responds to user frustration: Theory, design, and results. *Interacting with computers* 14(2) (pp. 119-140).
- Khalifa, N.S., 2019. Internet chat as ‘jargon’. *Journal of Language Studies* 3(1) (pp.121-132).
- Leonova, V., 2020. Review of non-English corpora annotated for emotion classification in text. In *Proceedings of the Databases and Information Systems: 14th International Baltic Conference, (DB&IS 2020)* (pp. 96-108). Springer International Publishing.

Leonova, V. and Zutters, J., 2021, September. Frustration Level Annotation in Latvian Tweets with Non-Lexical Means of Expression. In *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2021)* (pp. 814-823).

Moriyama, T. and Ozawa, S., 1999, June. Emotion recognition and synthesis system on speech. In *Proceedings IEEE International Conference on Multimedia Computing and Systems 1* (pp. 840-844). IEEE.

Ollama, 2024. *Llama 3* [LLM]. Ollama. Retrieved 24 October 2024 from: <https://ollama.com/library/llama3:8b>

Ollama, 2024. *Gemma* [LLM]. Ollama. Retrieved 24 October 2024 from: <https://ollama.com/library/gemma:7b>

Ollama, 2024. *Google Gemma 2* [LLM]. Ollama. Retrieved 24 October 2024 from: <https://ollama.com/library/gemma2:9b>

OpenAI, 2022. *GPT-3.5 Turbo* [LLM]. OpenAI. Retrieved 24 October 2024 from: <https://platform.openai.com/docs/models/gpt-3-5-turbo>

OpenAI, 2024. *GPT-4o mini* [LLM]. OpenAI. Retrieved 24 October 2024 from: <https://platform.openai.com/docs/models/gpt-4o-mini>

OpenAI, 2024. *GPT-4o* [LLM]. OpenAI. Retrieved 24 October 2024 from: <https://platform.openai.com/docs/models/gpt-4o>

Stauss, B., Schmidt, M. and Schoeler, A., 2005. Customer frustration in loyalty programs. *International Journal of Service Industry Management*, 16(3) (pp.229-252).

Sun, J. [sunapi386], 2024. *Ollama import of Oreguteng/Llama-3-8B-Lexi-Uncensored-GGUF* [LLM]. Ollama. Retrieved 24 October 2024 from: <https://ollama.com/sunapi386/llama-3-lexi-uncensored>

Verma, J.P., Agrawal, S., Patel, B. and Patel, A., 2016. Big data analytics: Challenges and applications for text, audio, video, and social media data. *International Journal on Soft Computing, Artificial Intelligence and Applications (IJSCAI)* 5(1) (pp. 41-51).

Wang, S., Schraagen, M., Sang, E.T.K. and Dastani, M., 2020, December. Public sentiment on governmental COVID-19 measures in Dutch social media. In *Proceedings of the 1st Workshop on NLP for COVID-19 (Part 2) at the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP 2020)*.

Whiten, A. and van de Waal, E., 2017. Social learning, culture and the ‘socio-cultural brain’ of human and non-human primates. *Neuroscience & Biobehavioral Reviews*, 82 (pp. 58-75).

Pateicības

Šajā rakstā izmantotais pētījums tika daļēji atbalstīts ar Eiropas Reģionālās attīstības fonda līdzekļiem SIA TILDE un Latvijas Universitātes kopprojekta „Daudzvalodu mākslīgā intelekta balstīta cilvēka un datora mijiedarbība” Nr. 1.1.1.1.1/18/A/148 ietvaros.

Autore vēlas izteikt pateicību: Dmitrijam Kuzmenko, datorikas maģistram, par koda apskati; Jekaterinai Aleksejenokai, filoloģijas maģistrei, Marijai Boginai, kognitīvo zinātņu bakalauram, par konsultācijām lingvistikā; Svetlanai Burmistrovai specialistam grafiskā dizainā, par palīdzību ar grafiskām shēmām; Katerinai Ļitvinovai, psiholoģijas bakalauram, Jeļenai Burcevai, ekonomikas bakalauram, Svetlanai Ščegolihinai par palīdzību datu kopas anotēšanā; Oļegam Ošmjanam, datorzinātņu maģistram, par rediģēšanu; Aleksandram Rivošam, datorzinātņu maģistram, par visu.

NATIONAL
DEVELOPMENT
PLAN 2020



EUROPEAN UNION
European Regional
Development Fund



INVESTING IN YOUR FUTURE