




Konferencijos „Lietuvos magistrantų informatikos ir IT tyrimai“ darbai



2021 m.





Konferencijos „Lietuvos magistrantų informatikos ir IT tyrimai“ darbai

2021 m. gegužės 14 d.



VILNIAUS
UNIVERSITETO
LEIDYKLA

2021

Programinis komitetas:

Dr. Jolita Bernatavičienė

Prof. habil. dr. Gintautas Dzemyda

Prof. dr. Olga Kurasova

Prof. dr. Julius Žilinskas

ISBN 978-609-07-0623-7 (skaitmeninis PDF)

<https://doi.org/10.15388/LMITT.2021>

Autorių teisės © Autoriai, 2021. Publikavo Vilniaus universiteto leidykla.

Tai yra atvirosios prieigos žurnalas. Žurnalas platinamas vadovaujantis *Kūrybinių bendrijų licencija – Priskyrimas (CC BY)*, kuri leidžia laisvai ir neribotai naudoti, kaip mano esant reikalinga, be kita ko, kopijuoti, daryti pakeitimus ir kurti išvestinius kūrinius, naudoti komerciniais ir nekomerciniais tikslais nurodant informacijos šaltinį ir autorių.

Ižanga

Konferencija „Lietuvos magistrantų informatikos ir IT tyrimai“ skirta pristatyti magistrų baigiamųjų darbų tyrimus informatikos ir IT srityse. Šio renginio tikslas – pakelti magistrantų įgūdžius, supažindinti su kitų magistrantų atliekamais tyrimais, paskatinti domėtis moksline veikla. Konferencijoje savo pranešimus skaitys studentai iš Kauno technologijos universiteto, Vilniaus universiteto ir Vytauto Didžiojo universiteto.

Konferenciją organizuoja Lietuvos mokslų akademija (LMA) kartu su Vilniaus universitetu. LMA – tai įstaiga, jungianti žymiausius Lietuvos ir savo veikla su Lietuva susijusius mokslininkus. Ji yra nepriklausoma Seimo, Vyriausybės ir jai pavaldžių institucijų ekspertė ir patarėja mokslo bei studijų, kultūros, socialinės raidos, ūkio, gamtosaugos, sveikatos apsaugos, technologijų bei kitais klausimais. LMA įgyvendina šalies mokslui ir eksperimentinei plėtrai reikšmingus ES struktūrinių fondų projektus, rengia šalies bei tarptautines mokslines konferencijas, užsienio mokslininkų seminarus, mokslininkų susitikimus, akademinis skaitymus, parodas. Tikime, kad dalyvavimas šioje LMA kuruojamoje konferencijoje paskatins magistrantus ir kitus studentus tęsti mokslinę veiklą ir pabaigus studijas.

Konferencijos darbuose spausdinti recenzuoti studentų parengti moksliniai straipsniai. Tai dažniausiai pirmosios mokslinės publikacijos, bet tikimės, kad ateityje virs į straipsnius prestižiniuose mokslo žurnaluose. To norėtume palinkėti konferencijos dalyviams.

Organizatoriai

dr. Jolita Bernatavičienė

prof. habil. dr. Gintautas Dzemyda

prof. dr. Olga Kurasova

prof. dr. Julius Žilinskas

Turinys

<i>Alina Belova.</i> Emocijų atpažinimas taikant dirbtinius neuroninius tinklus	5
<i>Deividas Brazauskas.</i> Šnekamosios kalbos identifikavimas	13
<i>Konstantinas Jurgilas.</i> Subjekto 2FA skaitmeninio autentifikavimo prie kritinės infrastruktūros informacinės sistemos struktūrizuotas vertinimas	23
<i>Mantas Kontrimas, Karolis Petrauskas.</i> „Redis Cluster“ podėlio sistemos tyrimas, taikant formalius metodus	34
<i>Gediminas Krasauskas.</i> Dekomponavimo kortų metodas sudėtingoms informacinėms sistemoms dekomponuoti	44
<i>Ingrida Lisinskienė, Ramūnas Kubiliūnas.</i> Anglų kalbos mokymo nuotoliniu būdu metodika ir jos taikymas	53
<i>Algirdas Litvinas.</i> IT priemonių panaudojimo galimybės profesiniam kvalifikacijos kėlimui nuotoliniu būdu.	64
<i>Paulius Milmantas.</i> Privačios informacijos išsaugojimas taikant dirbtinio intelekto technologijas.	71
<i>Vladyslav Palkevič.</i> Automatinė pilvo aortos atsišakojimų paieška kompiuterinės tomografijos nuotraukoje.	77
<i>Gabrielė Ruminavičiūtė.</i> YouTube vaizdo įrašų populiarumo vertinimas naudojant viešai prieinamus metaduomenis.	84
<i>Dominykas Šeputis.</i> Investigation of text data augmentation for transformer training via translation technique	97
<i>Aušra Šubonienė.</i> Pilvo aortos vietos nustatymas krūtinės ląstos tomografinėje nuotraukoje.	106

Emocijų atpažinimas taikant dirbtinius neuroninius tinklus

Alina Belova

VU Matematikos ir informatikos fakultetas,
Naugarduko g. 24, Vilnius
alina.belova@mif.stud.vu.lt

Santrauka. Šiame straipsnyje pristatoma dirbtinių neuroninių tinklų, skirtų emocijų atpažinimui dialogų tekste, apžvalga ir lyginamoji analizė. Dialogų tekstas analizuojamas taikant įprastinius rekurentinius neuroninius tinklus, tačiau didžiausias dėmesys skiriamas DialogueGCN taikymui. DialogueGCN pagalba modeliuojamas pokalbio emocinis kontekstas, turintis įtakos emocijų klasifikavimui. Straipsnyje pateikiami dviejų duomenų aibių (IEMOCAP, MELD) emocijų atpažinimo rezultatai, kurie tik dalinai patvirtina DialogueGCN taikymo pranašumus. Išdėstomi galimi rezultatų paaiškinimai bei tolimesnių darbų alternatyvos.

Raktiniai žodžiai: emocijų atpažinimas, teksto analizė, dirbtinis neuroninis tinklas, grafo neuroninis tinklas, rekurentinis neuroninis tinklas.

1 Įvadas

Emocijų atpažinimas, taikant dirbtinius neuroninius tinklus (DNT), yra viena iš greitai besivystančių šiuolaikinių kompiuterių sistemų sričių. Taikymai apima daugelį kompiuterių sistemų: sveikatos apsaugos, edukacinės, protingų namų [1, 2, 3]. Galima išskirti nemažai sunkumų, susijusių su emocijų klasifikavimu DNT pagalba: psichologinių teorijų nevienodumas, įvesties duomenų kanalų įvairovė, emocijų anotavimas ir t.t. [4, 5, 6].

Šio darbo tikslas – atlikti lyginamąją žmogaus emocijų, perteikiamų rašytinio teksto pavidalu, klasifikatorių analizę. Pagrindinis tyrimo dėmesys skirtas DNT pagrindu veikiantiems modeliams, kurie klasifikuoja emocijas į kelias klases. Siekiant iširti įvesties duomenų įtaką klasifikavimo tikslumui, čia pristatomi dviejų, nepriklausomai sukurtų duomenų aibių analizės rezultatai. Darbo metu iširti DNT modeliai, kurių pagalba analizuojamas pokalbio emocinis kontekstas (DialogueRNN¹, DialogueGCN²), ir DNT architektūros,

¹ angl. *Dialogue Recurrent Neural Network*

² angl. *Dialogue Graph Convolutional Network*

neatliekančios pokalbio konteksto modeliavimo (klasikiniai natūralios kalbos apdorojimo modeliai). Dėl straipsnio ribotumo rekurentinių neuroninių tinklų (angl. *recurrent neural network*, RNN) analizė nėra akcentuojama, pagrindinis dėmesys skiriamas grafo neuroninio tinklo (angl. *graph neural network*, GNN) analizei ir taikymui.

2 Emocijų atpažinimo metodai

Tyrimo vykdymui buvo naudojamos IEMOCAP (angl. *Interactive Emotional Dyadic Motion Capture*) ir MELD (angl. *Multimodal EmotionLines Dataset*) duomenų aibės: analizuojami teksto įrašai anglų kalba [7, 8, 9]. Tarp aibių galima išskirti šiuos skirtumus, turinčius įtakos emocijų atpažinimui:

IEMOCAP. Aibę sudaro 6 emocijų klasės (žr. 3.2 poskyris) ir 151 dialogas.

Dialogai – dirbtinai sukurti, vieno pokalbio dalyvių skaičius – 2, vieno dialogo vidutinis replikų skaičius – 50.

MELD. Aibę sudaro 7 emocijų klasės (žr. 3.2 poskyris) ir 1433 pokalbių įrašai. Pokalbiai – iš serialo „Draugai“, vieno pokalbio dalyvių skaičius – iki 9 asmenų, vieno pokalbio vidutinis replikų skaičius – 10.

Skaičiavimams atlikti buvo naudojami viešai prieinami replikų bruožai, GloVe³ sakinių vektoriai su dimensija 300, ir DialogueGCN⁴ kodas, po nežymių originalaus kodo atnaujinimų ir modifikacijų [10].

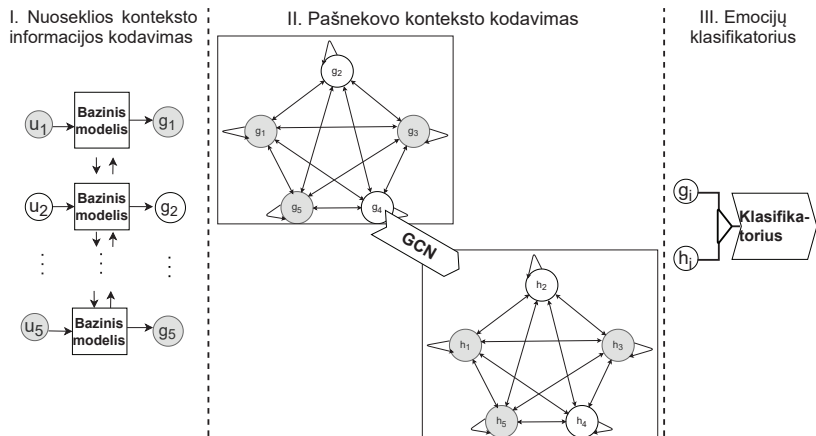
DialogueGCN modelį sudaro RNN ir GNN architektūros: RNN pagalba modeliuojama nuosekli pokalbio informacija, GNN pagalba modeliuojamas pokalbio emocinis kontekstas (žr. 1 pav.). GNN pagrindą sudaro grafo struktūra (viršūnės – pokalbio replikos, briaunos – sąryšiai tarp replikų), kuri sąlygoja erdvinės informacijos tarp grafo viršūnių išsilaikymą, net ir po konvoliucijos operacijos atlikimo. Grafo konvoliucijos (GCN, II-a DialogueGCN modelio dalis) pasekoje kiekvienas mazgas įgauna vis daugiau informacijos iš vis platesnio kaimyninių mazgų spektro – taip vykdomas emocinio konteksto modeliavimas.

Pokalbio analizės DialogueGCN pagalba pavyzdžiui paimeime dviejų asmenų pokalbį iš MELD duomenų aibės ir sukonstruokime pokalbio grafą (žr. 2 pav.). Pradžioje, 2a pav. pokalbio replikos patalpinamos į grafo viršūnes. 2b pav. vaizduojamas detaliau apdorotas dialogo grafas: su $u_1 \dots u_5$ replikų bruožais ir sąryšiais tarp viršūnių. Galutinį pokalbio grafą analizuoja 1 pav.

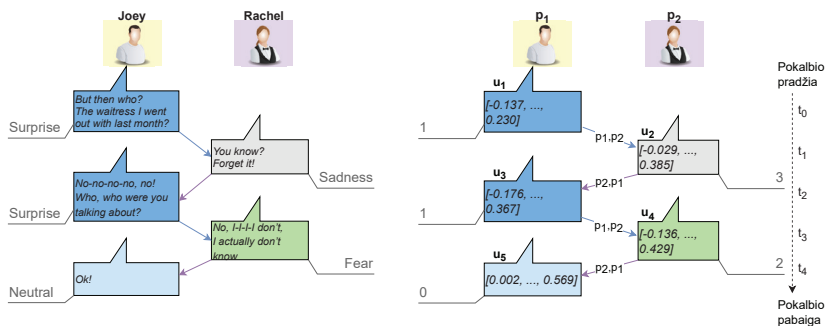
³ <https://nlp.stanford.edu/projects/glove/>

⁴ <https://github.com/declare-lab/conv-emotion>

vaizduojamas DialogueGCN modelis, vykdamtis tolimesnį replikų emocijų atpažinimą.



1 pav. Trijų dalių DialogueGCN modelis, analizuojantis dviejų asmenų $u_1 \dots u_5$ replikas (pilki ir balti rutuliukai). I – bazinis modelis, taikomas nuoseklos pokalbio informacijos modeliavimui (gaunami replikų bruožai $g_1 \dots g_5$). II – GNN, taikomas pokalbio emocinio konteksto modeliavimui (gaunami replikų bruožai $h_1 \dots h_5$). III – emocijų klasifikatorius, sujungiantis g_i ir h_i bruožus bei priskiriantis kiekvienai pokalbio replikai tam tikrą emocijų klasę. Pokalbio duomenis galima apdoroti su GNN (taikant I, II, III) ir be GNN (taikant I, III). Schema nubraižyta vadovaujantis [10] darbu.



2 pav. Dviejų asmenų (Joey ir Rachel) pokalbio grafas: replikoms priskirtos emocijų klasės (surprise, „1“; sadness, „3“; fear, „2“; neutral, „0“). (a) – replikos aprašomos teksto pavaldai; emocijos nėra užkoduotos. (b) – replikas ($u_1 \dots u_5$) nusako skaitiniai GloVe vektoriai su dimensija 300 (skaitomumo sumetimais iš 300 skaičių rodomi tik pirmas ir paskutinis); emocijos nusakytos skaičiais (0...3); briaunoms tarp viršūnių yra priskirti simboliniai žymėjimai (p_1, p_2 ir p_2, p_1); grafo dešinėje įvesta pokalbio laiko ašis ($t_0 \dots t_4$).

Šio tyrimo metu buvo naudojami 6 DNT modeliai:

- Modeliai be GNN – naudojami 3 baziniai rekurentiniai tinklai (rekurentinis vartų vienetas⁵ (angl. *gated recurrent unit*, GRU), trumpalaikės ir ilgalaikės atminties tinklas⁶ (angl. *long short-term memory*, LSTM) ir DialogueRNN⁷) be II-os DialogueGCN dalies [11, 12, 13].
- Modeliai su GNN – naudojami 3 baziniai rekurentiniai tinklai (GRU, LSTM, DialogueRNN) su II-a DialogueGCN dalimi, t.y. taikomos visos DialogueGCN modelio dalys.

3 Rezultatai

Skaičiavimams atlikti buvo naudojamas asmeninis nešiojamas kompiuteris su sistemos specifikacija: *RAM atmintis* – 15,5 GB; *CPU* – Intel® Core™ i5-8300H CPU @ 2,30 GHz x8; *VGA* – Intel® UHD Graphics 630 (CFL GT2); *OS* – Ubuntu 18.04.5 LTS; *OS architektūra* – 64-bit. DNT skaičiavimai buvo vykdomi *Python* aplinkoje, CPU pagalba. Darbo metu buvo atlikta 120 DNT skaičiavimų paleidimų: po pusę su IEMOCAP ir MELD duomenų aibėmis.

3.1 Bendra rezultatų apžvalga

1, 2 lentelėse pateikiami geriausi emocijų klasifikavimo rezultatai, gauti taikant 6 DNT modelius (žr. 2 skyrius). Lentelėse rezultatai yra vertinami pagal bendrą tikslumą ir F_1 matą. Nedidelės tikslumo ir F_1 mato reikšmės yra daug geresnės už atsitiktines, turint galvoje, kad sprendžiamas klasifikavimo uždavinys su 6 (IEMOCAP, žr. 1 lentelė) ir 7 (MELD, žr. 2 lentelė) klasėmis. Be to, išryškėja porą tendencijų:

- GNN tinklo taikymas pagerina IEMOCAP duomenų klasifikavimo tikslumą. MELD duomenų analizė, atlikta su GNN pagalba, duoda žemesnius rezultatus nei be GNN taikymo.
- LSTM tinklas duoda geriausius rezultatus dviems atvejais: analizuojant IEMOCAP su GNN taikymu ir analizuojant MELD be GNN taikymo.

3 pav., 4 pav. vaizduojamos tikslumo ir F_1 dispersijos, nustatytos klasifikuojant IEMOCAP ir MELD duomenis su GRU ir LSTM baziniais modeliais (su GNN ir be GNN taikymo). Iš grafikų galima daryti tokius apibendrinimus:

⁵ <https://pytorch.org/docs/stable/generated/torch.nn.GRU.html>

⁶ <https://pytorch.org/docs/stable/generated/torch.nn.LSTM.html>

⁷ <https://github.com/declare-lab/conv-emotion/tree/master/DialogueRNN>


- GNN tinklo taikymas stabilizuoja bazinių tinklų (GRU, žr. 3 pav., ir LSTM, žr. 4 pav.) skaičiavimų tikslumą, nepriklausomai nuo analizuojamos duomenų aibės.
- MELD duomenų analizės atveju, GNN taikymas padidina GRU ir LSTM skaičiavimų F_1 dispersijas, lyginant su šių modelių taikymu be GNN.

1 lentelė. Geriausių IEMOCAP rezultatų F_1 ir tikslumas: mėlyna spalva pažymėtos didžiausios reikšmės. Skaičiavimams naudojami 6 modeliai: GRU su GNN, LSTM su GNN, DialogueRNN su GNN, GRU be GNN, LSTM be GNN, DialogueRNN be GNN.


	GRU		LSTM		DialogueRNN	
	F_1	Tikslumas	F_1	Tikslumas	F_1	Tikslumas
Su GNN	59,73	57,42	61,49	61,00	54,96	55,58
Be GNN	39,53	40,23	40,02	42,01	41,11	42,54

2 lentelė. Geriausių MELD rezultatų F_1 ir tikslumas: mėlyna spalva pažymėtos didžiausios reikšmės. Skaičiavimams naudojami 6 modeliai: GRU su GNN, LSTM su GNN, DialogueRNN su GNN, GRU be GNN, LSTM be GNN, DialogueRNN be GNN.

	GRU		LSTM		DialogueRNN	
	F_1	Tikslumas	F_1	Tikslumas	F_1	Tikslumas
Su GNN	52,01	54,75	51,74	55,02	51,02	55,1
Be GNN	75,1	73,3	76,14	75,8	69,61	59,63

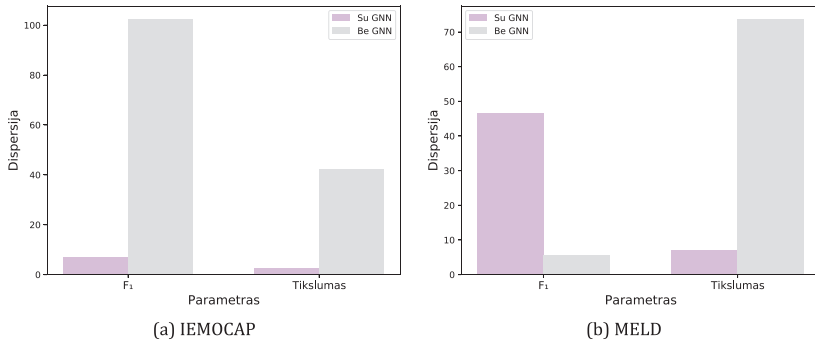


(a) IEMOCAP



(b) MELD

3 pav. Klasifikavimo rezultatų, gautų su GRU baziniu modeliu, tikslumo ir F_1 dispersijos: su GNN (alyvų spalva), be GNN (pilka spalva). Duomenų aibės: IEMOCAP (a), MELD (b).



4 pav. Klasifikavimo rezultatų, gautų su LSTM baziniu modeliu, tikslumo ir F_1 dispersijos: su GNN (alyvų spalva), be GNN (pilka spalva). Duomenų aibės: IEMOCAP (a), MELD (b).

3.2 Pavienių emocijų klasių atpažinimo analizė


Čia yra pristatomi emocijų klasifikavimo rezultatai, gauti taikant LSTM bazinį modelį. Naudojami sekantys emocijų žymėjimai:

IEMOCAP. Emocijų klasės: „hap“ – laimė (angl. *happiness*), „sad“ – liūdesys (angl. *sadness*), „neu“ – neutrali (angl. *neutral*), „ang“ – pyktis (angl. *anger*), „exc“ – jaudulys (angl. *excitement*), „fru“ – frustracija (angl. *frustration*).


MELD. Emocijų klasės: „neu“ – neutrali (angl. *neutral*), „sur“ – nuostaba (angl. *surprise*), „fea“ – baimė (angl. *fear*), „sad“ – liūdesys (angl. *sadness*), „joy“ – džiaugsmas (angl. *joy*), „dis“ – pasibjaurėjimas (angl. *disgust*), „ang“ – pyktis (angl. *anger*).

Iš 5 pav. vaizduojamų IEMOCAP rezultatų galima matyti didelį klasifikavimo pagerėjimą, taikant GNN (žr. 5a pav.). 5b pav. sumaišymo matricoje teisingai nustatytų emocijų įstrižainė yra blyškesnių spalvų, lyginant su pirma matricos eilute (t.y. teisingai aptiktų atvejų skaičius yra mažesnis). Be to, 5b pav. matome, kad gana didelis „hap“ emocijų skaičius buvo klaidingai priskirtas kitoms klasėms („sad“, „neu“, „ang“, „exc“, „fru“), lyginant su 5a pav. rezultatų tvarkingumu.

6 pav. vaizduojami MELD klasifikavimo rezultatai: juose negalime įžiūrėti tvarkingai apibrėžtos sumaišymo matricos įstrižainės. Tačiau galima pastebėti GNN taikymo pranašumus: tarp neutralios ir liūdesio klasių yra mažiau klaidų bei mažiau neutralių emocijų yra priskiriama džiaugsmo klasei. Be to, matome, kad kelių emocijų klasės („fea“, „sad“, „dis“) nebuvo teisingai aptiktos nei su GNN, nei be GNN.



5 pav. IEMOCAP klasifikavimo rezultatai su LSTM, kai GNN yra taikomas (a) ir GNN nėra taikomas (b).



6 pav. MELD klasifikavimo rezultatai su LSTM, kai GNN yra taikomas (a) ir GNN nėra taikomas (b).

4 Išvados

Šio tyrimo metu buvo atlikta lyginamoji emocijų, išreiškiamų teksto pavidalu, atpažinimo analizė: analizei taikomi RNN grįsti metodai (GRU, LSTM, DialogueRNN) bei GNN grįstas modelis DialogueGCN). Sudėtingos GNN struktūros taikymas pasiteisino tik dalinai, ilgų pokalbių su dviem pašnekovais (IEMOCAP duomenų aibė) analizės atveju. Taikant GNN trumpų dialogų analizei (MELD duomenų aibė) buvo gauti žemesni rezultatai, lyginant su paprastesnių modelių (GRU, LSTM) taikymu.

Be to, GNN taikymas, nepriklausomai nuo duomenų aibės, didina kai

kurių emocijų klasifikavimo tikslumą (pvz., liūdesys, neutralumas) ir duoda stabilėnio tikslumo rezultatus. Taigi, emocijų, perteikiamų teksto pavidalu, atpažinimas reikalauja tolimėsių tyrimų vykdymo: modifikuojant GNN tinklų architektūrą bei taikant RNN modelių patobulinimus.

Literatūra

- [1] Daily, S. B. et al. (2017). Chapter 9 - Affective Computing: Historical Foundations, Current Applications, and Future Trends. In: *Emotions and Affect in Human Factors and Human-Computer Interaction*. Ed. by Jeon, M. San Diego: Academic Press, 213–231.
- [2] Pieroni, M. et al. (2015). Affective Internet of Things: Mimicking human-like personality in designing smart-objects. In: *2015 IEEE 2nd World Forum on Internet of Things (WF-IoT)*. 400–405.
- [3] Kaklauskas, A., Lill, I., Puust, R., & Ubarte, I. (2020). 9 - Affective Internet of Things. In: *Start-Up Creation (Second Edition)*. Ed. by Pacheco-Torgal, F. et al. Second Edition. Woodhead Publishing Series in Civil and Structural Engineering. Woodhead Publishing, 203–233.
- [4] Pantic, M., & Rothkrantz, L. (2003). Toward an affect-sensitive multimodal human-computer interaction. *Proceedings of the IEEE*, 91(9), 1370–1390.
- [5] Kołakowska, A. et al. (2013). Emotion recognition and its application in software engineering. *2013 6th International Conference on Human System Interactions, HSI 2013*, 532–539.
- [6] Poria, S., Majumder, N., Mihalcea, R., & Hovy, E. (2019). Emotion Recognition in Conversation: Research Challenges, Datasets, and Recent Advances. *IEEE Access*, 7, 100943–100953.
- [7] Busso, C. et al. (2008). IEMOCAP: interactive emotional dyadic motion capture database. *Language Resources and Evaluation*, 42(4), 335–359.
- [8] Zahiri, S., & Choi, J. D. (2018). Emotion Detection on TV Show Transcripts with Sequence-based Convolutional Neural Networks. In: *Proceedings of the AAAI Workshop on Affective Content Analysis. AFFCON'18*. New Orleans, LA, 44–51.
- [9] Poria, S. et al. (2019). MELD: A Multimodal Multi-Party Dataset for Emotion Recognition in Conversations. In: *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. Florence, Italy: Association for Computational Linguistics, 527–536.
- [10] Ghosal, D. et al. (2019). DialogueGCN: A Graph Convolutional Neural Network for Emotion Recognition in Conversation. In: *EMNLP-IJCNLP*. Hong Kong, China: Association for Computational Linguistics, 154–164.
- [11] Cho, K. et al. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. In: *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Doha, Qatar: Association for Computational Linguistics.
- [12] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
- [13] Majumder, N. et al. (2019). DialogueRNN: An Attentive RNN for Emotion Detection in Conversations. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(1), 6818–6825.

Šnekamosios kalbos identifikavimas

Deividas Brazauskas

Vytauto Didžiojo universitetas, Informatikos fakultetas,
Vileikos g. 8, LT-44404, Kaunas
brazauskas862611594@gmail.com

Santrauka. Šiame straipsnyje gilinamasi į skirtingų autorių naudojamus šnekamosios kalbos identifikavimo metodus ir pasiektus rezultatus. Tiriamos jau egzistuojančios atviro kodo sistemos. Bandoma jas optimizuoti, apjungti naudojant bendrą duomenų rinkinį, atlikti kryžminį sistemų patikrinimą ir apjungti gautus rezultatus naudojant meta-klasifikatorių [1]. Taip pat, didesniai klasifikavimo tikslumui išgauti yra panaudojamas šnekos atpažinimo servisas, gauti rezultatai yra sujungiami su atviro kodo sistemų rezultatais naudojant meta-klasifikatorių. Tyrimo metu atlikti 4 eksperimentai, kurių pagalba buvo pasiektas statistiškai reikšmingas klasifikavimo tikslumo pagerinimas.

Raktiniai žodžiai: šnekamosios kalbos identifikavimas, šnekos atpažinimas, dirbtiniai neuroniniai tinklai, mašininis mokymasis, meta-klasifikatorius.

1 Įvadas

Sparčiai augant privačių, bei komercinių tarptautinių komunikacijų poreikiui dažnai kyla skirtingomis kalbomis bendraujančių asmenų komunikacijos problemos. Esamų technologijų pagalba įmanoma bendrauti su skirtingų tautybių asmenimis, nors ir jie nesupranta kito asmens vartojamos kalbos. Tokios technologijos turi savo limitus, kaip: kalbėtojų įpareigojimas jau žinoti kito kalbėtojo vartojamą kalbą, priverčiant atlikti sistemų konfigūracijos darbus prieš pradėdant pokalbį, tik tekstinio vertimo palaikymas, mažas palaikomų kalbų, tokių kaip Lietuvių, kiekis. Viešai prieinamų sprendimų leidžiančių identifikuoti šnekamąją kalbą šiuo metu nėra, yra tik pavienės - uždaro kodo, dažnai neužbaigtos arba apleistos sistemos, kurios veikia tik ant savo turimų duomenų rinkinių. Šios sistemos niekada nebuvo apjungtos su kitomis sistemomis ir jų pasiektas tikslumas nebuvo optimalus. Šio darbo tikslas yra iširti kitų autorių naudojamus šnekamosios kalbos metodus, pasiektus rezultatus, optimizuoti esamas šnekamosios kalbos identifikavimo atviro kodo sistemas, atlikti kryžminį patikrinimą, kurio rezultatus

galima apjungti naudojant meta-klasifikatorių, sistemų gautus klasifikavimo rezultatus sujungti su šnekos atpažinimo servisų gautomis tikimybėmis ir apjungti meta-klasifikatoriumi.

2 Analogiškų darbų apžvalga

Tyrimui buvo išanalizuoti egzistuojantys šnekamosios kalbos identifikavimui skirti sprendimai. Analizei pasirinkti 10 straipsnių [2, 3, 4, 5, 6, 7, 8, 9, 10, 11], iš kurių dauguma siūlomų sprendimų dar nėra realizuoti ne-laboratorinėje aplinkoje. Palyginimui buvo pasirinktos 3 atviro kodo sistemos: autorius Paul-Louis Pröve [12], Catalin Tiseanu [13] ir Nipun Manral [14], kurios buvo apleistos po jų sukūrimo, tačiau pavyko atstatyti jų veikimą. Sistemų naudojami duomenų rinkiniai nebuvo viešai pasiekiami, daugumai autorių duomenų rinkiniai buvo suteikiami tik sistemų kūrimo tikslais. Autorių naudoti požymių aptikimo ir klasifikavimo metodai matomi 1 lentelėje. Straipsniuose dažnai aptariama daugiau nei vienas metodas siekiant rasti efektyviausią iš jų. Aptariami naudoti požymių aptikimo metodai buvo: MFCC [15], SDC, LPC, LPCC, BoS, JFA, PLP, SVM, Voice tokenizer, dažniausiai sutinkamas metodas - MFCC, kuris buvo naudojamas 7 autorių, dažniausiai naudojamas klasifikavimo metodas buvo GMM [16] ir jo kombinacijos su kitais metodais. Jis buvo naudojamas 7 iš analizuojamų straipsnių. Kiti naudojami metodai buvo: DNN [17], RNN, LSA, KNN [18], Mixture Smoothing, PRLM, P-PRLM, dauguma iš šių metodų buvo jungiami su kitais klasifikavimo metodais.

1 lentelė. Straipsnių naudoti metodai

Straipsnio autorius	Klasifikavimo metodai	Požymių aptikimo metodai
Gregoire Montavon [2]	TDNN, CNN [19]	CNN-TDNN
Haizhou Li and Bin [3]	LSA, BOS, KNN, Mixture Smoothing, SVM, GMM, P-PRLM	Voice tokenizer, SVM
Panikos Heracleous [4]	DNN, CNN, GMM-UBM, SVM	Bottleneck naudojant CNN
Ryo Masumura [5]	PA-DNN, SA-DNN, PPA-DNN, SA-LSTM-RNN, PA-LSTM-RNN, PPA-LSTM-RNN, DNN, PRLM, P-PRLM	MFCC
Eslam Mansour Mohammed [6]	WPT, ANN	MFCC, LPC

Straipsnio autorius	Klasifikavimo metodai	Požymių aptikimo metodai
Malo Grisard [7]	UBM, GMM, DNN, UBM/GMM-IV-LR	MFCC, LPC
Maarten Van Segbroeck [8]	PRLM, GMM	MFCC, SDC, PLP, JFA
Brij Mohan Lal Srivastava [9]	P-PRLM, PRLM, RNN, GMM, SVM, DNN, HMM, RNNLM	MFCC, LPCC, SDC
Rong Tong [10]	GMM, PPRLM, BOS, UBM	MFCC, SDC
Bing Jiang [11]	P-PRLM, PPRSVM, GMM-UBM, GMM-SVM, DNN, HMM, DBF-TV, PDBFTV	MFCC, SDC, PLP

Tyrimė buvo dirbama su 3 šnekamosios kalbos identifikavimo atviro kodo sistemomis. Jose naudojami požymių aptikimo, bei klasifikavimo metodai matomi 2 lentelėje. Visos tiriamos sistemos naudojo MFCC metodą požymių aptikimo tikslams, klasifikavimo tikslams naudojami metodai buvo CNN, kurį naudojo Paul-Louis Pröve, GMM – Catalin Tiseanu ir jungtinis GRU/LSTM metodas, kurį pasitelkė Nipun Manral.

2 lentelė. Atviro kodo sistemų metodai

Sistemos autorius	Mokymo metodai	Požymių aptikimo metodai
Paul-Louis Pröve	CNN	MFCC
Catalin Tiseanu	GMM	MFCC
Nipun Manral	GRU/LSTM	MFCC

Kai kurių straipsnių autorių (pvz.: Malo Grisard ir Maarten Van Segbroeck) įverčių tikslas buvo kuo mažesnis kompiuterio resursų suvartojimas – Cavg (angl. Cost Average), kol kitų autorių (pvz.: Ryo Masumura) – identifikavimo laiko pagerinimas ir mažesnis kompiuterio resursų sunaudojimas. Buvo pastebėta, kad didžiausią tikslumą (mažiausią EER [20]) turintys klasifikatoriai yra hibridiniai, tiksliausias pasiektas rezultatas buvo 0.72 % EER autoriaus Malo Grisard straipsnyje. Daugelis iš analizuotų straipsnių autorių įgyvendino savo užsibrėžtus įverčių tikslus.

Šiame straipsnyje siūlomas sprendimas yra optimizuoti jau esamas atviro kodo šnekamosios kalbos identifikavimo sistemas ir sujungti su šnekos atpažinimo, t. y. įrašus į tekstą verčiančiais, servisais naudojant bendrą duomenų rinkinį, bei gautus rezultatus apjungti naudojant meta-klasifikatorių.

3 Problemos sprendimas

Norint pradėti problemos sprendimą pirma yra paruošiamas duomenų rinkinys, naudojamas visose analizuojamose sistemose. Jis paruoštas iš 5 kalbų: Vokiečių (DE), Anglų (EN), Ispanų (ES), Prancūzų (FR) ir Lietuvių (LT), kiekvienai kalbai turint po lygiai 10 valandų įrašų. Kalbų DE, EN, ES, FR įrašai surinkti iš VoxForge [21], viešai prieinamo įrašų šaltinio. LT kalbai viešai prieinamų įrašų rinkinių nerasta, todėl nuspręsta naudoti 40 audio-knygų pavyzdžius. Tai leido sudaryti 8 iš 10 valandų įrašų rinkinį, likę įrašai gauti iš akademiniais tikslams skirtų šaltinių. Įrašų ilgiai yra suvienodinti po 10 sekundžių, ilgesnius įrašus padalijant į atskiras dalis ir pašalinant trumpo ilgio įrašus. Surinktiems LT kalbos įrašams atliktas kokybės suvienodinimas, sutapatinant įrašų kokybę su kitų kalbų įrašais. Tai buvo pasiekta atsitiktinai keičiant įrašų garso ir aido lygius, kalbėjimo greitį, panaudojami „highpass“, bei „bandpass“ signalo filtrai. Buvo suvienodintos įrašų direktorijos, takelių skaičius, dokumentų tipai, bitų sparta (angl. bit-rate). Gauti įrašų rinkinių kalbėtojų kiekiai matomi 4 lentelėje.

4 lentelė. Duomenų rinkinio kalbėtojų kiekiai

Kalba	Kalbėtojai
DE	303
EN	513
ES	232
FR	259
LT	102

Kryžminiam patikrinimui pasiruošti yra reikalingas duomenų išskirtymas į tais pačiais kalbėtojais nepersidengiančias aibes. Tam atlikti duomenų rinkinys indeksuojamas, suliejami visų kalbų įrašai į bendrą aibę, ji išmaišoma atsitiktiniu būdu, įrašai padalijami į 5 dalis, taip, kad aibių įrašų, bei kalbėtojų kiekių skirtumas nebūtų didelis. Paruošti duomenys matomi 5 lentelėje.

Turint paruoštą duomenų rinkinį šią problemą buvo bandoma spręsti keliais alternatyviais eksperimentiniais būdais. Pirmas eksperimentas buvo sutvarkyti sistemų [12, 13, 14] atvirą programinį kodą, suvienodinant jų naudojamus duomenų rinkinius, ištaisant pastebėtas daromas klaidas ir

5 lentelė. Duomenų rinkinio kalbėtojų kiekiai

Aibės nr.	Kalbėtojų kiekis	Įrašų kiekiai					
		DE	EN	ES	FR	LT	Bendras
1	278	780	701	660	667	351	3159
2	277	833	679	759	653	873	3797
3	281	516	706	625	717	796	3360
4	282	716	775	785	782	776	3834
5	291	755	739	771	781	804	3850

optimizuojant jų įverčius, tokius kaip sistemų modelio sluoksniuose neuronų kiekius. Išbandyti sistemas individualiai naudojant bendrą duomenų rinkinį. Antras eksperimentas buvo atlikti sistemų kryžminį patikrinimą ir apjungti gautus rezultatus išbandant keletą meta-klasifikatorių. Meta-klasifikatoriaus realizavimui buvo naudojamas WEKA [22] programinės įrangos paketas. Trečias – panaudoti šnekos atpažinimo servisu, norint gauti statistinį kiekvieno įrašo priklausomumą nuo tam tikros kalbos tikimybės įverčio. Naudotas įrašus į tekstą verčiantis šnekos atpažinimo servisas Google Cloud Speech-to-Text [23]. Sukurtas programinis kodas, kuris nusiunčia kiekvieną įrašą į nuotolinį servisą kiekvienai tikrinamai kalbai. Kartu su įrašu į servisą yra paduodamas kalbos sutrumpinimas. Tai leidžia servisui nuspėti duoto įrašo kalbos klasių tikimybes specifinėms kalboms. Iš gautų įverčių kalbų tikimybių kiekvienam įrašui yra išrenkami po 5 požymius – kiekvienos kalbos tikimybės procentinis įvertis, kurio pavyzdys matomas 1 pav. Gautų duomenų aibė buvo panaudota meta-klasifikatoriuje tikslumo įverčiui išgauti.

file	language	sys_4_de	sys_4_en	sys_4_es	sys_4_fr	sys_4_lt
en_3438	en	0.214	0.241	0.173	0.255	0.116
en_895	en	0.207	0.275	0.2	0.111	0.206
de_2475	de	0.273	0.246	0.261	0.117	0.103
en_1414	en	0.221	0.167	0.228	0.261	0.123

1 pav. Meta-klasifikatoriaus duomenys

Ketvirtas eksperimentas – sujungti sistemų [12, 13, 14] sprendimus su šnekos atpažinimo gautais sprendimais ir juos apjungti naudojant meta-klasifikatorių. Į meta-klasifikatorių yra paduodami įrašų kalbų tikimybių įver-

tinimo duomenys, kurie susideda iš 20 požymių - 5 požymiai iš kiekvienos sistemos. Meta-klasifikatoriaus realizavimui buvo pasitelktas įrankis WEKA. Atlikus kiekvieną eksperimentą tyrimų sprendimams buvo patikrinamas statistinis reikšmingumas, skaičiuojant pasikliautinius intervalus [24], su 95 % pasikliautinumu lygiu. Pasikliautinumo intervalų formulės yra:

$$\bar{x} - Z^* \left(\frac{\sigma}{\sqrt{n}} \right), \bar{x} + Z^* \left(\frac{\sigma}{\sqrt{n}} \right)$$

4 Pasiūlytų metodų tyrimai


Sistemos buvo vertinamos naudojant tikslumo įvertį. Tikslumas yra skaičiavimo, matavimo arba klasifikavimo rezultatų tikslinimo su atskaitos verte kokybinis matas, kuris apskaičiuojamas su šia formule:

$$\text{tikslumas} = \frac{TN + TP}{TP + FP + TN + FN}$$


Paruošus duomenų rinkinį toliau buvo atliekami sistemų [12, 13, 14] optimizavimo darbai. Paul-Louis Pröve sistemai buvo keičiamos parametų Epochs ir Chunks reikšmės, geriausios reikšmės, kurios matomos 2 ir 3 pav., buvo nustatytos: Epochs - 10, Chunks - 1000. Pakeitus Catalin Tiseanu sistemos parametro NUM_MIXTURES reikšmę, kuri yra matoma 4 pav., geriausias tikslumo rezultatas buvo pasiektas naudojant 2048 reikšmę. Nipun Manral keičiant Epochs parametro reikšmę, kuri matoma 5 pav., atrasta geriausia parametro reikšmė - 20. Buvo bandomi optimizuoti ir kiti sistemos rasti parametrai, tačiau juos keičiant žybaus sistemos tikslumo pokyčio nebuvo. Atlikus sistemų optimizavimo darbus gautas vidutiniškai 7 % tikslumo padidėjimas. Atsižvelgus į pasikliautinumo intervalus, galime teigti, jog optimizuotų sistemų tikslumo pagerėjimas yra statistiškai reikšmingas. Daugiau informacijos matoma 6 lentelėje.

Pritaikius 5-kartų kryžminio patikrinimo procedūrą ir jos rezultatus apjungus meta-klasifikatoriumi, buvo gautas 72,63 % tikslumas, naudojant 100 iteracijų Bagging [25] klasifikatorių. Meta-klasifikatoriuje buvo išbandyti visi galimi algoritmai su optimizuotomis algoritmų parametų variacijomis. Apskaičiavus pasikliautinumo intervalą buvo pastebėta, kad šis tikslumo pagerėjimas nėra statistiškai reikšmingas. Pritaikius šnekos atpažinimo sistemą ir gautus rezultatus apjungus meta-klasifikatoriumi buvo gautas 82,72 %


tikslumas, naudojant 100 iteracijų Bagging klasifikatorių. Atlikus pasikliautinumo intervalo skaičiavimus, buvo matoma, kad tikslumo pokytis buvo statistiškai reikšmingas. Sujungus atviro kodo sistemų, bei šnekos atpažinimo sistemos rezultatus ir pritaikius jiems 100 iteracijų Bagging meta-klasifikatorių buvo gautas 89,95 % klasifikavimo tikslumas. Apskaičiavus jungtinės sistemos pasikliautinumo intervalą, buvo pastebėtas statistiškai reikšmingas tikslumo pagerėjimas.




2 pav. Paul-Louis Pröve parametras Epochs



3 pav. Paul-Louis Pröve parametras Chunks



4 pav. Catalin Tiseanu parametras NUM_MIXTURES



5 pav. Nipun Manral sistemos Epochs

6 lentelė. Atviro kodo sistemų optimizavimas

Sistemos autorius	Neoptimizuotas tikslumas %	Optimizuotas tikslumas %
Paul-Louis Pröve	60	66
Catalin Tiseanu	63	71
Nipun Manral	32	39

5 Išvados

Atlikus straipsnių analizę, pastebėta, kad dažniausiai naudojamas metodas požymių aptikimui yra MFCC, o mokymui – GMM. Galime teigti, kad šie metodai buvo pasirinkti dėl jų efektyvumo. Išanalizavus 3 atviro kodo sistemų veikimą, pastebėta, kad šių sistemų veikimas yra ribotas, neoptimizuotas ir ne pilnai įgyvendinta sistemų kūrėjų vizija, todėl jų topologijas toliau galima optimizuoti. Daroma prielaida, kad tai galėtų padėti gauti didesnę klasifikatoriaus tikslumą.

Įrašų kiekis turi didelę įtaką galutiniam sistemų tikslumui, bei mokymo trukmei. Naudojamo duomenų rinkinio praplėtimas, bei optimizavimas yra galimas tolimesnis tikslumo padidinimo būdas. Pastebėtina, kad didinant kalbų kiekį esantį duomenų rinkinyje gali daryti neigiamą įtaką algoritmo tikslumui, todėl didinant kalbų kiekį yra patartina padidinti esamų kalbų įrašų kiekius.

Apibendrinant atliktus eksperimentus pastebėta, kad pirmo eksperimento sistemų optimizavimo darbai suteikė statistiškai reikšmingą pagerėjimą, vidutiniškai 7 % tikslumo. Panaudojus bendrą duomenų rinkinį visoms atviro kodo sistemoms buvo galima palyginti kiekvienos sistemos klasifikatoriaus tikslumą. Buvo pastebėta, kad tiksliausiai klasifikuojanti sistema buvo autoriaus Catalin Tiseanu, sugebanti klasifikuoti 72 % tikslumu. Iš antro eksperimento rezultatų pastebėtas, kad gautas 0,6 % papildomas tikslumas nebuvo statistiškai reikšmingas, tačiau pamatyta, kad meta-klasifikatoriaus gautas tikslumas yra didesnis nei visų 3 atviro kodo sistemų tikslumo įverčių vidurkis. Atlikus trečią eksperimentą pastebėta, kad šnekamosios kalbos identifikavimo tikslumui padeda šnekos atpažinimo sistemos panaudojimas, patartina apjungti klasifikatorių su šiais, bei jau turimais atviro kodo sistemų kalbų tikimybių duomenimis. Atlikus ketvirtą eksperimentą matoma ryški, kad ir blogesnių, sistemų apjungimo naudojant meta-klasifikatorių nauda. Tikėtina, praplečiant meta-klasifikatoriaus naudojamą duomenų rinkinį būdų galima pasiekti didesnio tikslumo nei 89,95 %, tačiau tam reikalinga atliktų papildomų tyrimų su meta-klasifikatoriais.

Literatūra

- [1] A Meta Classifier by Clustering of Classifiers https://link.springer.com/chapter/10.1007/978-3-319-13650-9_13 [žiūrėta 2021 03 22].
- [2] Gregoire Montavon (2009). Deep learning for spoken language identification. Machine Learning Group Berlin Institute of Technology.
- [3] Haizhou Li and Bin (2005). A Phonotactic Language Model for Spoken Language Identification. Ma Institute for Infocomm Research.
- [4] Panikos Heracleous, Kohichi Takai, Keiji Yasuda, Yasser Mohammad, Akio Yoneyama (2018). Comparative Study on Spoken Language Identification Based on Deep Learning. KDDI Research, Inc.
- [5] Ryo Masumura, Taichi Asami, Hirokazu Masataki, Yushi Aono (2017). Parallel Phonetically Aware Dnns And Lstm-Rnns For Frame-By-Frame Discriminative Modeling Of Spoken Language Identification. NTT Media Intelligence Laboratories.
- [6] Eslam Mansour mohammed, Mohammed Sharaf Sayed , Abdalaa Mohammed Moselhy, Abdelaziz Alsayed Abdelnaiem (2013). LPC and MFCC Performance Evaluation with Artificial Neural Network for Spoken Language Identification. Department of Electrical and Computer Engineering.
- [7] Malo Grisar, Petr Motlicek, Wissem Allouchi, Michael Baeriswyl, Alexandros Lazaridis, Qingran Zhan (2019). Spoken language identification using language bottleneck features. EPFL, Department of Electrical Engineering, Lausanne.
- [8] Maarten Van Segbroeck, Ruchir Travadi, Shrikanth S. Narayanan (2015). Rapid Language Identification. IEEE/ACM Transactions On Audio, Speech, And Language Processing 2015.
- [9] Brij Mohan Lal Srivastava, Hari Vydana, Anil Kumar Vuppala, and Manish Shrivastava Language Technology Research Center (2017). Significance of neural phonotactic models for large-scale spoken language identification. International Institute of Information Technology.
- [10] Rong Tong, Bin Ma, Donglai Zhu, Haizhou Li and Eng Siong Chng (2014). Integrating Acoustic, Prosodic And Phonotactic Features For Spoken Language Identification. Institute for Infocomm Research.
- [11] Bing Jiang, Yan Song , Si Wei, Jun-Hua Liu, Ian Vince McLoughlin, Li-Rong Dai (2014). Deep Bottleneck Features for Spoken Language Identification. University of Science and Technology of China.
- [12] Github – Sistema nr. 1 „Spoken Language Recognition“, Paul-Louis Pröve <https://github.com/pietz/language-recognition/> [žiūrėta 2021 03 14].
- [13] Github – Sistema nr. 2 „Spoken language identification“, Catalin Tiseanu <https://github.com/CatalinTiseanu/spoken-language-identification/> [žiūrėta 2021 03 14].
- [14] Github – Sistema nr. 4 „Spoken-Language-Identification“, Nipun Manral <https://github.com/nipunmanral/Spoken-Language-Identification> [žiūrėta 2021 03 14].
- [15] Cepstrum and MFCC <https://wiki.aalto.fi/display/ITSP/Cepstrum+and+MFCC> [žiūrėta 2021 03 22].
- [16] Gaussian Mixture Models Explained <https://towardsdatascience.com/gaussian-mixture-models-explained-6986aaf5a95> [žiūrėta 2021 03 22].
- [17] Deep Neural Network <https://www.sciencedirect.com/topics/engineering/deep-neural-network> [žiūrėta 2021 03 22].
- [18] Machine Learning Basics with the K-Nearest Neighbors Algorithm <https://towardsdatascience.com/machine-learning-basics-with-the-k-nearest-neighbors-algorithm-6a6e71d01761> [žiūrėta 2021 03 22].

- [19] Convolutional Neural Network <https://www.sciencedirect.com/topics/engineering/convolutional-neural-network> [žiūrėta 2021 03 22].
- [20] EER - equal error rate https://www.webopedia.com/TERM/E/equal_error_rate.html [žiūrėta 2021 03 15].
- [21] VoxForge <http://www.voxforge.org/> [žiūrėta 2021 03 18].
- [22] WEKA <https://www.cs.waikato.ac.nz/ml/weka/> [žiūrėta 2021 03 18].
- [23] Google Cloud Speech-to-Text <https://cloud.google.com/speech-to-text/> [žiūrėta 2021 03 18].
- [24] Pasikliautinis intervalas <https://www.vle.lt/straipsnis/pasikliautinis-intervalas/> [žiūrėta 2021 03 30].
- [25] ML | Bagging classifier <https://www.geeksforgeeks.org/ml-bagging-classifier/> [žiūrėta 2021 03 22].

Subjekto 2FA skaitmeninio autentifikavimo prie kritinės infrastruktūros informacinės sistemos struktūrizuotas vertinimas

Konstantinas Jurgilas

Kauno technologijos universitetas, Informatikos fakultetas,
Studentų g. 50, LT-51368 Kaunas
konstantinas.jurgilas@ktu.edu

Santrauka. Ypatingos svarbos (kitaip – kritinės) infrastruktūros informacinės sistemos apima svarbiausias visuomenės funkcionavimo sritis, reikalingas įvairių paslaugų teikimui. Šioms sistemoms egzistuoja vis didesnė grėsmė tapti skaitmeninių nusikaltimų ir atakų taikiniu, kadangi jos yra kartinės tiek valstybės, tiek visuomenės atžvilgiu. Viena iš svarbiausių priežasčių, sukeliančių grėsmę šių sistemų saugumui, yra silpna nuotolinės prieigos kontrolė – sistemos naudotojo tapatybės valdymas. Šiame straipsnyje pateikiamas pasiūlytas dviejų faktorių (2FA) skaitmeninio autentifikavimo metodas nuotolinei prieigai prie kritinės infrastruktūros informacinės sistemos ir jo struktūrizuotas kokybinių charakteristikų tyrimas bei vertinimas. Tyrimas buvo atliktas dviem etapais: 1) tiriamos metodo charakteristikos panaudojamumo, dislokavimo ir saugumo kategorijose; 2) atliekama lyginamoji tyrimo rezultatų analizė su kitų mokslininkų siūlomais metodais, šiam tikslui panaudojant skaitinį kokybinių charakteristikų vertinimo metodą. Tyrimo rezultatų pagrindu buvo nustatyta, kad siūlomas autentifikavimo metodas yra kokybiškesnis vertintų kategorijų visumos atžvilgiu.

Raktiniai žodžiai: kelių faktorių autentifikacija, kritinės infrastruktūros sistemos.

1 Įvadas

Ypatingos svarbos (kitaip – kritinės) infrastruktūros informacinės sistemos apima svarbiausias visuomenės funkcionavimo sritis, reikalingas įvairių paslaugų teikimui, įtraukiant transporto ir pašto, informacinių technologijų ir elektroninių ryšių, viešojo saugumo, valstybės valdymo, energetikos, užsienio reikalų, saugumo politikos sektorius.

Ypatingos svarbos infrastruktūrų informacinėms sistemoms egzistuoja vis didesnė grėsmė tapti skaitmeninių nusikaltimų ir atakų taikiniu, kadangi jos yra kartinės tiek valstybės, tiek visuomenės atžvilgiu ir palaiko nenu-

trūkstantą šių sektorių teikiamų paslaugų vykdymą. Visuomenė yra priklausoma nuo tokių paslaugų teikimo, tad bet koks jų sutrikdymas gali sukelti nepatogumų ar didelių neigiamų padarinių. Pavyzdžiui, 2015 metų gruodį įvykdytas kibernetinis išpuolis prieš Ukrainos elektros tiekimo tinklą, kuomet beveik ketvirtis milijono žmonių vidury žiemos liko be elektros energijos šešioms valandoms [1].

Viena iš svarbiausių priežasčių, sukeliančių grėsmę kritinės infrastruktūros informacinių sistemų saugumui, yra silpna nuotolinės prieigos kontrolė – sistemos naudotojo tapatybės valdymas. Autentifikacijos procesas yra vienas iš esminių komponentų subjekto (sistemos naudotojo) tapatybės valdyme, kadangi šio proceso metu yra vienareikšmiškai nustatomas sistemos naudotojo identitetas. Jei autentifikacijos procesas yra įvykdomas sėkmingai, sistema pasitiki proceso metu gautu rezultatu ir identifikuoja sistemos naudotoją tik pagal proceso metu gautą informaciją - autentifikacijos kontekstą. Jei autentifikacijos procesas bus pažeistas, egzistuoja itin didelė rizika, jog sistema neteisingai identifikuos bei autentifikuos jos naudotojus. Svarbu pabrėžti, kad esamuose subjekto skaitmeninio autentifikavimo metuose [2] [3] yra naudojami to pačio tipo informacijos pateikimo kanalai (pvz.: tik naudotojo kompiuteris), ko pasekoje didėja rizika, jog kanalo pažeidimo (kibernetinio incidento) metu bus pažeistas visas autentifikacijos procesas. Kelių tipų kanalų panaudojimas (pvz.: naudotojo kompiuteris ir mobilusis įrenginys ar fizinis skaitmeninių žetonų generatorius) užtikrintų didesnę saugos lygį, kadangi pažeidus tik vieną iš kanalų, kitas kanalas užtikrintų autentifikacijos proceso apsaugą nuo pažeidimo. Dalyje esamų sprendimų siūlomas SMS žinučių metodas [4] [5] taip pat nebėra laikomas saugiu, o sistemos naudotojo lokacijos bei biometrinių duomenų panaudojimo realizavimas metuose [6] [7] gana sudėtingai realizuojamas ir taikomas. Mobilaus ryšio įrenginių, kaip antro tipo informacijos kanalo, panaudojimas yra tinkama priemonė skaitmeninės autentifikacijos procese [8], tačiau toks autentifikacijos procesas turi būti praplėstas privalomu subjekto autentifikacijos užklausa patvirtinimu keliais etapais, pvz.: įtraukiant institucijos skirtingų pavaldumo lygmenų vadovus.

Esamų autentifikacijos metodų problematikos analizės pagrindu buvo nustatyta, kad kritinės infrastruktūros informacinių sistemų saugiam nuotoliniam prieigos valdymui turi būti užtikrinti esminiai saugos reikalavimai: 1) nuotolinių naudotojų autentifikacijai turi būti naudojamas stiprus kelių

faktorių autentifikacijos metodas, kuris remiasi keliais kanalais (angl. „*out-of-band authentication*“); 2) turi būti nustatyta procedūra, kuri leistų aukštesnio rango darbuotojui patvirtinti nuotolinės prieigos prašymą, siekiant išvengti neautorizuotų asmenų nuotolinės prieigos prie kritinės infrastruktūros sistemų; 3) nuotolinė prieiga bei autentifikacijos procesas turi vykti naudojant saugų kanalą (HTTPS protokolą bei VPN tunelius).

Atsižvelgiant į tai, suformuotas ir šio tyrimo tikslas - pasiūlyti dviejų faktorių (2FA) skaitmeninio autentifikavimo metodą nuotolinei prieigai prie kritinės infrastruktūros informacinės sistemos ir struktūriškai įvertinti jo kokybines charakteristikas. Tikslu įvykdymui yra keliami šie uždaviniai:

1. suprojektuoti dviejų faktorių skaitmeninio autentifikavimo metodą, kuris tenkintų kritinės infrastruktūros informacinėms sistemoms keliamus saugos reikalavimus ir realizuoti jį sistemos prototipe;
2. atlikti eksperimentinį pasiūlyto metodo veikimo tyrimą, įvertinant metodo kokybines charakteristikas.

Pasiūlyto metodo mokslinis naujumas ir praktiškumas – skaitmeninis autentifikacijos metodas, pagrįstas „*push notification*“ technologijos, skaitmeninių sertifikatų bei autentifikacijos užklausų autorizavimo sinergija, skirta valdyti nuotolinę prieigą prie kritinės infrastruktūros informacinės sistemos.

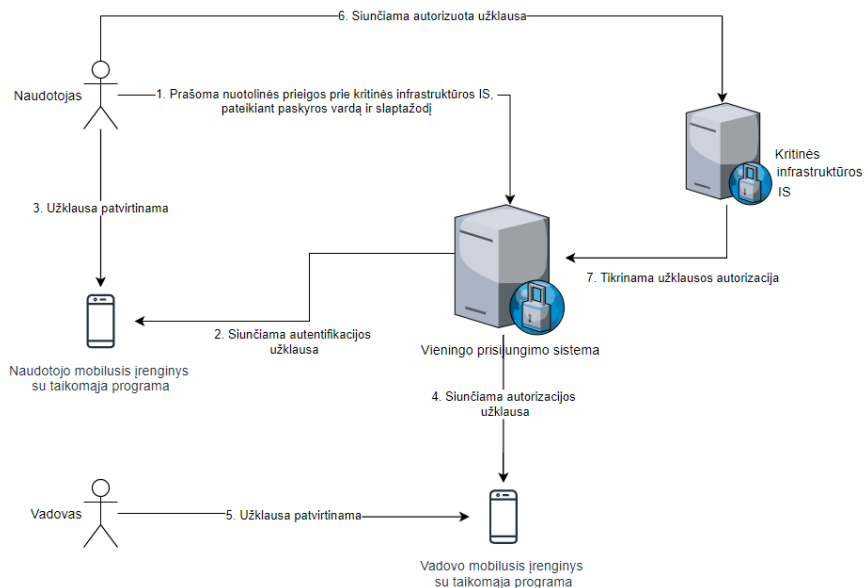
2 2FA skaitmeninis autentifikavimo metodas

Siūlomo autentifikavimo metodo koncepcinis modelis, pateiktas 1 paveikslėlyje, remiasi trijų žingsnių autentifikacijos/autorizacijos procesu.

Naudotojas, norėdamas gauti nuotolinę prieigą prie kritinės infrastruktūros informacinės sistemos, turėtų sėkmingai įvykdyti tokį procesą:

1. pateikti paskyros identifikatorių ir su juo susietą slaptažodį, kurį naudotojas gauna iš administratoriaus, kuomet šis sukuria paskyrą. Jei duomenys yra teisingi - naudotojui į jo susietą mobilaus ryšio įrenginį bus nusiunčiama autentifikacijos užklausa;
2. kuomet pats naudotojas sėkmingai patvirtina atsiųstą jam autentifikacijos užklausa, jo vadovams yra nusiunčiama autorizacijos užklausa, kurioje yra klausiama, ar pavaldiniui yra leidžiama jungtis prie tam tikros sistemos ir yra suteikiama nuotolinė prieiga;
3. jeigu vienas iš nurodytų vadovų sėkmingai patvirtina autorizacijos užklausa, naudotojui yra suteikiama nuotolinė prieiga prie apsaugo-

tos sistemos. Čia svarbu pabrėžti, kad sistema turi suteikti galimybę nurodyti kelis galimus vadovus sistemos naudotojo autorizavimui, siekiant padidinti perteklišumą tais atvejais, kai vieno iš vadovų mobilusis įrenginys nėra pasiekiamas.



1 pav. Autentifikavimo metodo koncepcinis modelis

Realizavus tokį subjekto skaitmeninės autentifikacijos procesą, būtų užtikrinama, jog nuotolinė prieiga prie kritinės infrastruktūros informacinės sistemos yra valdoma taikant saugumo priemones, kurios yra pateikiamos tokio tipo sistemų saugos reikalavimų dokumentuose.

3 Tyrimo metodika

Siekiant nustatyti siūlomo autentifikavimo metodo kokybines charakteristikas, jis buvo tiriamas ir vertinamas pagal [9] literatūros šaltinyje siūlomą autentifikavimo schemų vertinimo metodiką. Metodikoje yra pristatomos 25 autentifikavimo metodų charakteristikos, kuriomis yra įvertinami metodų

privalumai ir trūkumai. Šaltinyje nurodoma, jog metodų saugumo ir panaudojamumo savybės būna sunkiai suderinamos – suteikiant vieną savybę, yra sudėtinga pritaikyti kitą. Autoriai pabrėžia ir dislokavimo savybę, nurodančią, ar metodas gali būti pritaikytas praktiškai.

Atsižvelgus į išskirtas savybių grupes, siūlomo metodo charakteristikos buvo suskirstytos į tris kategorijas: panaudojamumas (angl. „usability“), dislokavimas (angl. „deployment“) ir saugumas (angl. „security“). Šioms kategorijoms priskiriamų charakteristikų tyrimas ir vertinimas atliktas panaudojant skaitinį kokybinių charakteristikų vertinimo metodą:

- Už „+“ įvertinimą skiriamas 1 balas;
- Už „-“ įvertinimą skiriama 0 balų;
- Už „±“ įvertinimą skiriama 0,5 balo.

Taip pat atsižvelgus į tai, kad pasiūlytą metodą siekiama taikyti aukšto saugos lygio reikalaujančioje kritinės infrastruktūros aplinkoje, metodo saugumo kategorijos charakteristikos turi būti svarbesnės nei kitų dviejų – panaudojamumo ar dislokavimo, tad saugumo charakteristikų įverčių sumai yra suteikiamas didesnis koeficientas. Taikant šį vertinimą, maksimalus galimas metodo vertinimas – 30,5 balo. Bendra balų suma apskaičiuojama pagal 1 formulę:

$$\text{Bendras balas} = \sum_i^8 U_i + \sum_j^6 D_j + 1,5 \cdot \sum_k^{11} S_k \quad (1)$$

čia: U_i – panaudojamumo kategorijos i -tosios charakteristikos įvertis; D_j – dislokavimo kategorijos j -tosios charakteristikos įvertis; S_k – saugumo kategorijos k -tosios charakteristikos įvertis.

4 Struktūrizuoto vertinimo eiga

Metodo charakteristikų skirtingose kategorijose apibūdinimai ir jų realizavimo poveikis siūlomo metodo veikimui ir funkcionalumui yra pateikiami 1, 2 ir 3 lentelėse. Panaudojamumo kategorijoje vertintos 8 metodo charakteristikos, dislokavimo – 6 charakteristikos, o didžiausias kiekis vertinamų charakteristikų buvo saugumo kategorijoje – 11 charakteristikų.

1 lentelė. Panaudojamumo charakteristikų vertinimo analizės rezultatai

Nr.	Charakteristika ir jos apibūdinimas	Charakteristikos įgyvendinimas siūlomame metode
U1	Nereikalaujantis atminties pastangų (angl. „ <i>Memory-wise-Effortless</i> “)	Naudotojai turi prisiminti tik paskyros slaptažodį.
U2	Plečiamas tarp paskyrų (angl. „ <i>Scalable-for-Users</i> “)	Metodas yra realizuotas vieningo prisijungimo sistemoje, tad naudotojas vieną paskyrą naudoja prisijungimui prie skirtingų sistemų.
U3	Nereikalaujantis papildomų nešulių (angl. „ <i>Nothing-to-Carry</i> “)	Naudotojas su savimi turi turėti savo mobiliojo ryšio įrenginį, kurį dažniausiai visada nešiojasi su savimi.
U4	Nereikalaujantis fizinių pastangų (angl. „ <i>Physically-Effortless</i> “)	Naudotojas autentifikavimo proceso metu turi įvesti slaptažodį, paspausti kelis mygtukus ir pateikti PIN kodą ar piršto antspaudą, jei yra sukonfigūruotas užklauskos patvirtinimas.
U5	Lengvai išmokstamas (angl. „ <i>Easy-to-Learn</i> “)	Vykdant autentifikacijos procesą, naudotojui yra pateikiamos išsamios instrukcijos ir paaiškinimai, kokius veiksmus jis turi atlikti, norint sėkmingai užbaigti visą procesą.
U6	Efektyviai naudojamas (angl. „ <i>Efficient-to-Use</i> “)	Autentifikacijos procesas gali užtrukti, kadangi vadovas turi sureaguoti ir autorizuoti užklauską. Mobiliojo įrenginio susiejimo procesas yra pakankamai greitas.
U7	Retai klaidingas (angl. „ <i>Infrequent-Errors</i> “)	Autentifikavimo schema nėra sudėtinga ir turėtų visada suveikti kuomet ją vykdo teisėtas naudotojas. Kuomet užklausa yra patvirtinama panaudojant biometrinius piršto antspaudu duomenis, yra naudojami gamykliniai mobiliųjų įrenginių mechanizmai, tad schemos patikimumas priklauso ir nuo šių technologijų patikimumo.
U8	Lengvai kompensuojamas įvykus nelaimėi (angl. „ <i>Easy-Recovery-from-Loss</i> “)	Sukūrus paskyrą, naudotojui yra perduodami keli vienkartiniai slaptažodžiai, su kuriais jis nelaimės atveju gali prisijungti prie paskyrų valdymo sistemos. Prisijungus prie šios sistemos, galima pasikeisti slaptažodį ar pakeisti įrenginį, su kuriuo paskyra yra susieta.

2 lentelė. Dislokavimo charakteristikų vertinimo lentelė

Nr.	Charakteristika ir jos apibūdinimas	Charakteristikos įgyvendinimas siūlomame metode
D1	Prieinamumas (angl. „Accessibility“)	Autentifikacijos schema remiasi WEB naršyklės ir mobiliojo ryšio įrenginio teikiamomis standartinėmis prieinamumo priemonėmis.
D2	Nežymi kaina už kiekvieną naudotoją (angl. „Negligible-Cost-per-User“)	Metodui realizuoti nėra reikalinga papildoma techninė įranga – yra naudojami naudotojų mobilieji įrenginiai.
D3	Suderinamas su serveriu (angl. „Server-Compatible“)	Metodas yra realizuotas vieningo prisijungimo sistemoje, taikančioje standartizuotą <i>OAuth 2.0</i> protokolą, kuris yra suderinamas su įvairiais paslaugų tiekėjais.
D4	Suderinamas su naršykle (angl. „Browser-Compatible“)	Sistemos prototipas teisingai veikia naudojant <i>Google Chrome</i> naršyklę su N-2 versijomis. Naudotojai taip pat papildomai turi įsidiegti mobiliojo ryšio įrenginio taikomąją aplikaciją.
D5	Brandus (angl. „Mature“)	Metodas yra dar tik siūlomas.
D6	Neapsaugotas patento (angl. „Non-Proprietary“)	Metodas yra pateikiamas moksliname darbe ir nėra patentuotas.

3 lentelė. Saugumo charakteristikų vertinimo analizės rezultatai

Nr.	Charakteristika ir jos apibūdinimas	Charakteristikos įgyvendinimas siūlomame metode
S1	Atsparus fiziniam stebėjimui (angl. „Resilient-to-Physical-Observation“)	Metodas yra atsparus fiziniam stebėjimui, kadangi norint atlikti autentifikacijos procesą, reikia turėti fizinį mobiliojo ryšio įrenginį ir pateikti piršto antspaudą, kuomet yra sukonfigūruotas užklauskos patvirtinimas pateikiant šią biometrinę informaciją.
S2	Atsparus nutaikytam apsimetinėjimui (angl. „Resilient-to-Targeted-Impersonation“)	Metodas yra atsparus nutaikytam apsimetinėjimui, kadangi nėra naudojama asmeninė naudotojo informacija.
S3	Atsparus apribotam spėliojimui (angl. „Resilient-to-Throttled-Guessing“)	Metodas yra atsparus apribotam spėliojimui, kadangi neteisingą slaptažodį pateikus 3 kartus, paskyra yra užblokuojama.
S4	Atsparus neapribotam spėliojimui (angl. „Resilient-to-Unthrottled-Guessing“)	Metodas yra atsparus neapribotam spėliojimui, kadangi neteisingą slaptažodį pateikus 3 kartus, paskyra yra užblokuojama.

Nr.	Charakteristika ir jos apibūdinimas	Charakteristikos įgyvendinimas siūlomame metode
S5	Atsparus vidiniam stebėjimui (angl. „ <i>Resilient-to-Internal-Observation</i> “) Piktavališ negali apsimesti naudotoju perimdamas įvestį iš naudojamų įrenginių arba perimant tinklo srautą.	Metodas yra atsparus pakartojimo atakoms, kadangi vykdant autentifikacijos procesą yra tikrinama, kad proceso žingsniai būtų atliekami tik vieną kartą. Metodas gali būti pažeistas, jei žalinga programine įranga bus paveikta naudotojo naršyklė, naudotojo ir vadovo mobiliojo ryšio įrenginiai.
S6	Atsparus informacijos nutekėjimui iš tikrintojo (angl. „ <i>Resilient-to-Leaks-from-Other-Verifiers</i> “) Metodas užtikrina, jog informacijai nutekėjus iš tikrintojo, piktavaliai negalės pasinaudoti šia informacija apsimetant naudotoju.	Vieningo prisijungimo sistema (tikrintojas) naudotojų slaptažodžius saugo naudodama stiprų <i>bcrypt</i> slaptažodžių santraukos algoritmą. Vieningo prisijungimo sistema taip pat saugo tik viešąjį naudotojo kriptografinį raktą, kuris yra skirtas patvirtinti užklausų patvirtinimo parašus, tad šio rakto kompromitacija nepaveiktų metodo saugos.
S7	Atsparus apgaulės atakoms (angl. „ <i>Resilient-to-Phishing</i> “)	Piktavališ apgaulės metodu galėtų perimti tik naudotojo slaptažodį, tačiau negalėtų paveikti užklausų patvirtinimo naudojant mobiliojo ryšio įrenginį.
S8	Atsparus vagystei (angl. „ <i>Resilient-to-Theft</i> “) Kuomet metodas naudoja fizinį įrenginį autentifikacijos atlikimui, piktavališ perimtas įrenginys negali būti panaudotas autentifikacijos vykdymui.	Kuomet užklausų patvirtinimui yra sukonfigūruotas piršto antspaudo panaudojimas, pavogto įrenginio panaudojimas tampa labai komplikuotas. Taip pat svarbu paminėti, jog perėmus ir panaudojus tik naudotojo įrenginį, metodui apsaugą suteikia vadovo įrenginio panaudojimas autorizacijos patvirtinimui.
S9	Nenaudojantis patikimos trečios šalies (angl. „ <i>No-Trusted-Third-Party</i> “)	Metodą realizuojanti vieningo prisijungimo sistema remiasi trečiosios šalies <i>Google Firebase</i> paslauga.
S10	Reikalaujantis tiesioginio patvirtinimo (angl. „ <i>Requiring-Explicit-Consent</i> “)	Naudotojas turi tiesiogiai pareikšti prašymą autentifikuotis, pateikiant pradinę prisijungimo vardo ir slaptažodžio formą.
S11	Neatsiejamas (angl. „ <i>Unlinkable</i> “)	<i>JWT</i> žetone yra nurodomas vieningo prisijungimo sistemos naudotojui suteiktas unikalus identifikatorius.

5 Rezultatų analizė

4 lentelėje yra pateikiama lyginamoji pasiūlyto metodo struktūrizuoto vertinimo rezultatų analizė su kitų mokslininkų siūlomais metodais. (Pastaba: lentelės stulpelyje „Nr.“ pateikiami tirti kitų mokslininkų pasiūlyti metodai [3-12], o šiame darbe siūlomas metodas atitinka Nr. 13.).

4 lentelė. Autentifikavimo metodų kokybinių charakteristikų vertinimo rezultatai

Charakteristikų realizavimas kategorijose

Nr.	Panaudojiamumas (U)								Dislokavimas (D)								Saugumas (S)								Ivertis		
	1	2	3	4	5	6	7	8	1	2	3	4	5	6	1	2	3	4	5	6	7	8	9	10		11	
[3]	0	1	1	0	1	1	1	1	0	1	1	0	1	1	1	1	0	1	1	0	0	0	1	1	1	1	19
[5]	0	1	.5	0	1	.5	1	0	1	1	0	1	1	1	1	1	1	1	1	.5	0	0	1	0	1	1	20.25
[6]	1	1	1	0	1	1	.5	0	1	1	0	.5	0	1	1	.5	1	1	0	1	1	1	1	1	1	1	23.25
[7]	0	0	1	0	1	0	0	0	1	1	0	.5	0	1	1	.5	1	1	1	.5	1	1	1	0	1	1	19
[8]	1	1	.5	0	1	.5	.5	0	1	1	0	.5	1	1	1	1	1	1	1	.5	1	1	1	0	1	1	23.25
[10]	0	1	.5	0	1	.5	1	0	0	1	0	.5	0	1	1	1	1	1	.5	0	1	0	1	1	1	1	19.25
[11]	1	1	.5	0	1	1	1	0	1	1	0	.5	0	1	1	1	1	1	0	1	1	.5	1	1	1	1	23.25
[12]	0	1	.5	0	1	.5	1	0	0	1	.5	.5	0	1	0	1	1	1	.5	1	1	1	1	0	1	1	19.75
13	1	1	.5	0	1	0	.5	1	1	1	1	.5	0	1	1	1	1	1	1	1	1	1	1	0	1	1	24

Lyginamosios pasiūlyto metodo struktūrizuoto vertinimo rezultatų analizės pagrindu nustatyta, kad siūlomas metodas vertinamas 0 balų už U6 charakteristiką (Efektyviai naudojamas), tačiau, lyginant su kitais metodais, yra pranašesnis dėl S5 charakteristikos (Atsparus vidiniam stebėjimui). Taip yra todėl, kad pažeisti visus 3 įrenginius, naudojamus siūlomame skaitmeninės autentifikacijos procese, yra sunku ir reikalauja daug pastangų. Siūlomas autentifikacijos metodas panaudojamumo kategorijoje vertinamas 5 balais, o tai yra tik nežymiai mažesnis vertinimas (-0,5 balo), nei kitų metodų. Dislokavimo kategorijos charakteristikų realizavimas metode vertinamas net 4 balais iš maksimaliai galimų 5. Tačiau svarbiausia, kad saugumo kategorijoje siūlomo metodo charakteristikos vertinamos aukščiausiai (15 balų), lyginant su kitais tirtais metodais. To pasekoje darytina išvada, kad pasiūlytas skaitmeninis autentifikacijos metodas yra kokybiškesnis, lyginant su kitais tirtais metodais, ir gali būti naudojamas nuotolinei prieigai prie kritinės infrastruktūros informacinės sistemos.

6 Išvados

Pasiūlytas subjekto skaitmeninis autentifikacijos metodas, pagrįstas „*push notification*“ technologijos, skaitmeninių sertifikatų bei autentifikacijos užklausų autorizavimo sinergija, skirta valdyti nuotolinę prieigą prie kritinės infrastruktūros informacinės sistemos. Struktūrizuoto metodo kokybinių charakteristikų panaudojamumo, dislokavimo ir saugumo kategorijose tyrimo ir atliktos lyginamosios rezultatų analizės pagrindu nustatyta, kad siūlomas autentifikavimo metodas vertinamas 24 balais iš maksimaliai galimų 30,5 ir yra kokybiškesnis, lyginant su kitais tirtais metodais, kategorijų visumos atžvilgiu.

Literatūra

- [1] “Cyber attacks targeting critical infrastructure | IEC e-tech | Issue’ 02/2019,” IEC e-tech. <https://www.iecetech.org/index.php/Technology-Focus/2019-02/Cyber-attacks-targeting-critical-infrastructure> (accessed Oct. 26, 2019).
- [2] S. Vaithyasubramanian, A. Christy, and D. Saravanan, “TWO FACTOR AUTHENTICATIONS FOR SECURED LOGIN IN SUPPORT OF EFFECTIVE INFORMATION PRESERVATION AND NETWORK SECURITY,” vol. 10, no. 5, p. 5, 2015.
- [3] “Internet Banking Login with Multi-Factor Authentication,” KSII Trans. Internet Inf. Syst., vol. 11, no. 1, Jan. 2016, doi: 10.3837/tiis.2017.01.027.

- [4] "(PDF) Multi-factor Authentication as a Service for Cloud Data Security," ResearchGate. https://www.researchgate.net/publication/313647475_Multi-factor_Authentication_as_a_Service_for_Cloud_Data_Security (accessed Oct. 26, 2019).
- [5] K. W. Hussein, "Design and Implementation of Multi Factor Mechanism for Secure Authentication System," vol. 11, no. 7, p. 7, 2013.
- [6] N. A. Aldumijji and E. A. Khan, "Fingerprint and location based multifactor authentication for mobile applications," *Int. J. Eng.*, p. 13.
- [7] I. A. Lami, T. Kuseler, H. Al-Assam, and S. Jassim, "LocBiometrics: Mobile phone based multi-factor biometric authentication with time and location assurance," p. 4.
- [8] B. Maciej, E. F. Imed, and M. Kurkowski, "Multifactor Authentication Protocol in a Mobile Environment," *IEEE Access*, vol. 7, pp. 157185–157199, 2019, doi: 10.1109/ACCESS.2019.2948922.
- [9] J. Bonneau, C. Herley, P. C. van Oorschot, and F. Stajano, "The Quest to Replace Passwords: A Framework for Comparative Evaluation of Web Authentication Schemes," in *2012 IEEE Symposium on Security and Privacy*, San Francisco, CA, USA, May 2012, pp. 553–567, doi: 10.1109/SP.2012.44.
- [10] A. Abdellaoui, Y. I. Khamlichi, and H. Chaoui, "A Novel Strong Password Generator for Improving Cloud Authentication," *Procedia Comput. Sci.*, vol. 85, pp. 293–300, Jan. 2016, doi: 10.1016/j.procs.2016.05.236.
- [11] X. Fang and J. Zhan, "Online Banking Authentication Using Mobile Phones," in *2010 5th International Conference on Future Information Technology*, Busan, Korea (South), 2010, pp. 1–5, doi: 10.1109/FUTURETECH.2010.5482634.
- [12] M. Misbahuddin, R. Vs, A. Thomas, and U. Kumar, "A Unique-ID based Usable Multi-Factor Authentication Scheme for e-Services," p. 7.

„Redis Cluster“ podėlio sistemos tyrimas, taikant formalius metodus

Mantas Kontrimas, Karolis Petrauskas

Vilniaus universitetas, Matematikos ir informatikos fakultetas,
Informatikos institutas,
Didlaukio g. 47, LT-08303 Vilnius
mantas.kontrimas@mif.stud.vu.lt, karolis.petrauskas@mif.vu.lt

Santrauka. Šiame straipsnyje yra analizuojamas podėlio sistemos „Redis Cluster“ korektiškumas. Analizuojant sistemą buvo naudojami formalūs metodai – TLA⁺ specifikavimo kalba buvo sudaryta sistemos formali specifikacija. Specifikacijos modelio tikrinimo metu buvo vertinama, ar yra užtikrinama sistemos savybė, kad už vieną maišos lizdą yra atsakingas tik vienas pagrindinis mazgas ir jo pavaldūs mazgai. Atlikus modelio tikrinimą buvo surastos situacijos, kada ši sistemos savybė nėra užtikrinama. Surastos klaidos buvo atkartotos realioje sistemoje ir šioms klaidoms buvo pateikti galimi sprendimo būdai.

Raktiniai žodžiai: Redis Cluster, Išskirstytos sistemos, Formalūs metodai, TLA⁺.

1 Įvadas

Šiandien serveriai ir didesnės sistemos turi aptarnauti keletą tūkstančių klientų vienu metu, o vieno naudotojo puslapio užkrovimas gali pareikalauti keleto užklausų, kurios turi būti įvykdytos per sekundės dalis [1], [2]. Būtent todėl šiuolaikinėms sistemoms svarbu sumažinti atsako laiką į užklausas bei darbo krūvį, su kuriuo turi susidoroti serveriai [3]. Podėlio (angl. *cache*) operatyviojoje atmintyje naudojimas yra vienas iš efektyviausių būdų kaip galima tai pasiekti. Podėliui reikalingą struktūrą, susidedančią iš rakto-reikšmės poros, gali pasiūlyti atvirojo kodo produktai: „Redis“, „Memcached“, „Ehcache“ ir kiti [4], [5]. Taip pat, siekiant dar labiau pagerinti podėlio našumą bei patikimumą, podėlis gali būti paskirstytas arba replikuotas tarp mazgų (angl. *nodes*) [4], [6].

„Redis“ – tai viena iš populiariausių NoSQL duomenų bazių, operatyviojoje atmintyje laikanti raktas-reikšmė poros [7]. Dažniausiai ši duomenų bazė yra naudojama kaip podėlis, norint pagerinti sistemos našumą [8], [9].

Be to, „Redis“ palaiko ir blokinių kūrimą (angl. *clustering*), kuris leidžia padidinti podėlio talpą, duomenis paskirstant tarp keleto mazgų.

„Redis Cluster“ duomenis paskirsto skirtingiems mazgams, kurie yra vadinami pagrindiniais (angl. *master*) mazgais, o kiekvienas pagrindinis mazgas gali turėti keletą pavaldžių mazgų (angl. *slave*), kurie saugo pagrindinio mazgo duomenų kopijas. Duomenys „Redis Cluster“ sistemoje yra laikomi 16384 (2^{14}) maišos lizduose (angl. *hash slots*), kurių reikšmės yra apskaičiuojamos raktui, kuriuo norima padėti reikšmę pritaikant maišos funkciją. Kiekvienas mazgas yra atsakingas už tam tikrą maišos lizdų aibę. Blokinį sudarantys mazgai yra visi pilnai tarpusavyje sujungti komunikavimo kanalais, kuriais paskalų (angl. *gossip*) protokolo pagalba dalinasi blokinių būsenų ir ilgainiui sutaria dėl kiekvieno mazgo būsenos [10].

Kadangi „Redis Cluster“ yra išskirstytas podėlis, tai šioje sistemoje gali egzistuoti išskirstytoms sistemos būdingos problemos [11]. Išskirstytose sistemose veiksmai vyksta lygiagrečiai, asinchroniškai, keičiasi mazgų būsenos, mazgai tarpusavyje komunikuoja žinutėmis, o ir sistemoje saugoma informacija yra išskirstyta tarp keleto mazgų. Būtent dėl to yra sunku užtikrinti, kad išskirstyta sistema nuolat veiks korektiškai: bus užtikrintas duomenų neprieštaringumas (angl. *consistency*), sistema nepakliūs į aklaivietes (angl. *deadlock*) arba sistema bus funkciškai teisinga ir pasižymės kitomis jai būdingomis savybėmis, pateiktomis, pavyzdžiui, reikalavimų specifikacijoje [12], [13]. Norint tai užtikrinti, galima naudoti formalius metodus, kurie padeda ištirti sistemos korektiškumą ir jos savybes bei padeda surasti sudėtingas sistemos klaidas, kurių neaptinka kitos verifikavimo technikos [14].

Formalūs metodai – tai matematiniai pagrindu paremti metodai, dažniausiai naudojami aprašant sistemos savybes ir elgseną bei tiriant dviprasmybes, sistemos nepilnumą ir prieštarumą. Sistemos kūrimo metu formalūs metodai gali būti naudojami specifikuojant sistemos reikalavimus, o sudarytos formalios specifikacijos gali padėti surasti sistemos klaidas, projektavimo trūkumus, prieš pradėdant įgyvendinti pačią sistemą. Taikant formalius metodus jau sukurtai sistemai, formalūs metodai gali padėti pagrįsti sistemos įgyvendinimo korektiškumą [15]. Turint formalią specifikaciją, algoritmo ar sistemos korektiškumą galima patikrinti taikant formalios specifikacijos įrodymus, modelio tikrinimą, peržiūras, animacijas ir kitus metodus [16].

Taikant formalius metodus ir rašant formalias specifikacijas, yra naudojamos formalios specifikavimo kalbos, paremtos pasirinktu matematinio

pagrindu, pavyzdžiui, algebra, logika, aibių teorija ir kitomis matematikos sritimis [17]. TLA⁺ kalba – viena iš formalių specifikuojamųjų kalbų, leidžiančių specifikuoti reaktyvias, išskirstytas ir asinchronines sistemas bei aptikti tokių sistemų klaidas [14], [18], [19]. Ši formali specifikuojamųjų kalba paremta veiksmų laiko logika (angl. *temporal logic of actions*, sutrumpintai – TLA), kuri gali būti naudojama tiriant lygiagrečių ir išskirstytų sistemų veikimą bei savybes [20]. TLA⁺ kalba nagrinėjamą sistemą aprašo kaip būsenų mašiną (išreikštą viena matematine formule), o modelio tikrintojas TLC tikrina visas galimas sistemos būsenas baigtiniame sistemos modelyje [18].

„Redis Cluster“ sistemos korektiškumas buvo vertinamas [4], tačiau nepaisant to, kad ši sistema yra plačiai naudojama, mokslinėje literatūroje ji tirta tik fragmentiškai. Atsižvelgiant į tai, šiame straipsnyje yra nagrinėjamas „Redis Cluster“ sistemos korektiškumas, taikant formalius metodus.

2 Formali specifikuojamųjų kalba

Remiantis „Redis Cluster“ dokumentacija ir atvirai prieinamu „Redis Cluster“ sistemos (versija 5.0) programiniu kodu, TLA⁺ kalba buvo sudaryta formali sistemos specifikuojamųjų kalba, nagrinėjanti mazgų būsenos (informacijos apie kitus mazgus ir maišos lizdų atsakomybes) pasikeitimus. Galutiniame rezultate buvo gauta daugiau nei dviejų tūkstančių eilučių formali specifikuojamųjų kalba artima programinio kodo abstrakcijos lygiui.

Formalioje specifikuojamųjų kalboje norint atitikti realios sistemos veikimą buvo modeliuojama žinučių komunikacija tarp blokinį sudarančių mazgų, t. y. vieno būsenų mašinos žingsnio metu būseną pasikeičia tik viename mazge ir informacija apie pasikeitimus pasiekia kitus mazgus, siunčiant žinutes pašalų protokolo pagalba.

Kiekvieno būsenų mašinos žingsnio metu gali įvykti vienas iš veiksmų:

1. Veiksmas susijęs su įvykiu ciklu (angl. *event loop*) – „Redis Cluster“ sistemoje visi veiksmai yra vykdomi vienoje gijoje, todėl visi veiksmai, susiję su žinučių apdorojimu, jų siuntimu, laiko įvykių apdorojimu, yra vykdomi įvykiu cikle.
2. Išoriniai įvykiai, lemiantys skirtingą žinučių apdorojimą ir sistemos veikimą:
 - a. Veiksmas susijęs su laiko pasikeitimais – sistemoje daug veiksmų priklauso nuo laiko, todėl specifikuojamųjų kalboje buvo modeliuojama laiko tėkmė išreikšta tam tikru veiksmu, kuris arba įvyko arba ne.

- b. Veiksmas susijęs su mazgo adreso pasikeitimu – blokinyje vienas iš mazgų gali pradėti bendrauti su kitais mazgais naudojant kitą adresą.
- c. Veiksmas susijęs su blokinio administravimo komandų apdorojimu – tai veiksmai, leidžiantys keisti blokinio konfigūraciją: maišos lizdų pasiskirstymą, mazgų roles ar blokinio sudėtį.

Sudarius formalią specifikaciją, buvo apibrėžtas modelis (specifikacijos egzempliorius) skirtas tirti „Redis Cluster“ sistemos savybes. Modelis TLA⁺ formalioje specifikavimo kalboje leidžia konfigūruoti formalią specifikaciją ir atlikti modelio tikrinimą esant skirtingoms specifikacijoje naudojamų konstantų reikšmėms, pradinei būsenai ir galimai būsenų mašinos būsenai. Sudarytas modelis yra naudojamas vykdant modelio tikrinimą ir generuojant sekančias būsenų mašinos būsenas. Apibrėžtą „Redis Cluster“ modelį sudaro trys pagrindiniai mazgai (mažiausia galima blokinio konfigūracija), kurie lygiomis dalimis yra pasidalinę šešis maišos lizdus. Siekiant sumažinti galimų būsenų skaičių, taip pat modelyje yra pridėtas ribojimas, kad komunikacijos kanaluose tarp mazgų negali būti daugiau nei trijų žinučių. Be to, norint pagreitinti modelio tikrinimą, pradinėje modelio būsenoje visi mazgai jau yra sudarę blokinį – nereikia vykdyti papildomos komunikacijos norint jį sukurti.

Sudarytos specifikacijos ir apibrėžto modelio tikrinimas buvo atliekamas nešiojamuoju kompiuteriu (4 branduoliai, 16GB RAM) bei TLA⁺ Toolbox įrankiu (versija 1.7.1). Modelio tikrinimo metu buvo vertinama ar nėra pažeidžiamos sistemos savybės bei taip pat buvo tikrinamas tipų korektiškumas bei buvo tikrinama, ar sistema nepasiekia aklavietės. Naudojantis TLC įrankiu apibrėžto modelio tikrinimas buvo atliekamas tol, kol buvo surasta, kad yra pažeidžiama tikrinama savybė.

3 Tiriama „Redis Cluster“ savybė

Remiantis „Redis Cluster“ sistemos dokumentacija buvo išskirtos savybės, kurios turi būti užtikrintos, kad sistema veiktų korektiškai. Iš šių savybių buvo išsirinkta viena svarbiausių sistemos savybių – už vieną maišos lizdą gali būti atsakingas tik vienas pagrindinis mazgas ir jo pavaldūs mazgai. Šios savybės užtikrinimas bus vertinamas modelio tikrinimo metu.

Ši savybė yra svarbi, kadangi maišos lizduose yra saugomi klientų atsiųsti duomenys ir, susidarius situacijai, kai už vieną maišos lizdą yra atsakingi keltas mazgų, klientai gali prarasti anksčiau siųstus savo duomenis arba gali

nežinoti, į kurį mazgą reikia kreiptis dėl duomenų patalpinimo. Taip pat svarbu, kad visuose mazguose informacija, kuris mazgas yra atsakingas už kurį maišos lizdą, sutaptų. Tai reikalinga dėl to, kad „Redis Cluster“ klientai gali kreiptis į bet kurį blokinį sudarantį mazgą bandydami gauti maišos lizde saugomas reikšmes. Apdorojant tokią užklausą mazgas, jeigu jis nėra atsakingas už tą maišos lizdą, klientui gali grąžinti *MOVED* klaidos pranešimą su nurodymu, į kurį mazgą reikia kreiptis dėl tame maišos lizde saugomos informacijos. Esant blogai informacijai apie mazgo maišos lizdus, „Redis Cluster“ klientai gali nežinoti su kuriuo blokiniu mazgu jiems iš tikrųjų reikia komunikuoti.

Maišos lizdų savybės užtikrinimas formalioje specifikacijoje buvo aprašytas invariantu. TLA⁺ kalbos invariantą išreikštą predikatų logika galima pamatyti formulėje (1),

$$\begin{aligned} \forall s \in \text{MAIŠOSLIZDAI}, n, m \in \text{MAZGAI.S}(n) \wedge S(m) \wedge \neg M(n, s) \wedge \neg M(m, s) \\ \rightarrow \exists o \in \text{MAZGAI.A}(n, s, o) \wedge A(m, s, o) \end{aligned} \quad (1)$$

kur $S(x)$ – mazgas x gali priimti skaitymo komandą, $M(x, y)$ – mazgo x požiūriu maišos lizdas y migruoja ir $A(x, y, z)$ – mazgo x požiūriu už maišos lizdą y yra atsakingas mazgas z . Šiuo invariantu yra tikrinama, kad bet kuriuose dviejuose mazguose n ir m , kurie gali priimti kliento komandas (yra pagrindiniai mazgai, jų požiūriu blokiny yra veikiantis ir dabar yra vykdomas žinučių skaitymo ir rašymo etapas, tačiau šiuo metu nėra apdorojama jokia žinutė), informacija apie mazgus ir jų maišos lizdų atsakomybes turi sutapti. Tikrinant šią savybę yra atsižvelgiama tik į pagrindinius mazgus dėl to, kad norint gauti tikslius duomenis „Redis Cluster“ klientai turi kreiptis į pagrindinį mazgą. Taip pat, nėra tikrinami maišos lizdai, kurie dalyvauja maišos lizdų pertvarkyme (angl. *resharding*) – procese, kai maišos lizdai iš vieno mazgo yra perkelti į kitą mazgą. Nors ir reali sistema gali aptarnauti tokius maišos lizdus naudojant komandą *asking* ir klaidos pranešimą *-ASK*, tačiau, norint supaprastinti invariantą, buvo atsižvelgta tik į atvejus, kada klientai gali naudoti komandas *get* ir *set* tam tikram maišos lizdui.

4 Tyrimo rezultatai

Naudojantis TLC modelio tikrintoju, buvo rasta atvejų, kai yra pažeidžiamas maišos lizdų invariantas (1). Rastos klaidos, jų priežastys ir pasiūlymai, kaip būtų galima jas ištaisyti pateikti žemiau.

1 klaida: Komanda *cluster setslot <maišos lizdas> node <mazgas>* pažeidžia maišos lizdų savybę

Maišos lizdų savybės pažeidimo priežastis – komandos *cluster setslot* subkomandą *node* galima iškviešti nurodant mazgą, kuris nedalyvauja maišos lizdų pertvarkyme. Sistema leidžia atlikti tokius veiksmus, nes viena iš subkomandos *node* paskirčių – rankiniu būdu pakeičiant maišos lizdų atsakomybes paspartinti informacijos apie įvykusį maišos lizdų pertvarkymą pasklidimą po „Redis Cluster“ blokinį. Tačiau, kaip pavyko nustatyti, toks subkomandos veikimas pažeidžia maišos lizdų savybę.

Rasta klaida buvo atkartota realioje sistemoje. Buvo sukurtas „Redis Cluster“ blokinys, kurį sudaro trys pagrindiniai mazgai: mazgas A, mazgas B ir mazgas C. Maišos lizdai mazgams buvo padalinti po lygias dalis. Turint tokią sistemos konfigūraciją ir naudojantis tekstine sąsaja (angl. *command line interface*) *redis-cli*, maišos lizdas 5061 buvo paskirtas mazgui B siunčiant subkomandą *node* mazgui A. Mazgui A apdorojus tokią komandą susidarė situacija, kad mazgo A požiūriu už 5061 maišos lizdą yra atsakingas mazgas B, o mazgo B požiūriu už šitą maišos lizdą yra atsakingas mazgas A. Esant tokiai situacijai per *redis-cli* nusiuntus komandą *get 5061* mazgui A yra gaunamas begalinis ciklas, kadangi mazgas A atsako, kad klientui dėl šio maišos lizdo reikia kreiptis į mazgą B, ir *redis-cli* pabandžius nusiųsti šitą *get* komandą mazgui B, jis atsako, kad klientui reikia kreiptis į mazgą A.

Norint ištaisyti šią klaidą būtų galima uždrausti kviesti *node* subkomandą, kai einamasis mazgas arba mazgas perduotas subkomandos parametruose nedalyvauja maišos lizdų pertvarkyme. Pašalintą *node* subkomandos funkcionalumą – paspartinti paskalų informacijos sklaidą apie pasikeitusius maišos lizdus, būtų galima užtikrinti šią atsakomybę perkeliant iš kliento į serverio pusę. Išsiuntus subkomandą *node* tiksliniam (angl. *target*) mazgui, kuris importuoja maišos lizdą, komandos apdorojimo metu tikslinis mazgas taip pat galėtų išsiųsti *ping* žinutes su pasikeitusiomis maišos lizdų atsakomybėmis visiems blokiniio mazgams.

Perkėlus siūlomą pakeitimą į žinučių apdorojimo specifikaciją ir toliau vykdant modelio tikrinimą buvo pastebėta, kad subkomanda *node* vis tiek pažeidžia maišos lizdų invariantą. Kadangi informacija apie maišos lizdo migruojančią ir importuojančią būseną yra saugoma atitinkamai pirminiame (angl. *source*) ir tiksliniame mazge, tai subkomanda *node* leidžia nesilaikyti maišos lizdų pertvarkymo proceso veiksmų.

Šią klaidą būtų galima ištaisyti priverčiant klientus laikytis maišos lizdų pertvarkymo proceso veiksmų tvarkos. Tai būtų galima užtikrinti pradedant dalintis informacija apie maišos lizdo migruojančią būseną su visais blokinio mazgais – papildant paskalų informaciją. Tada tikslinis mazgas galėtų pakeisti maišos lizdo būseną į importuojančią tik tada, kai iš pirminio mazgo gavo informaciją, kad jis pakeitė norimo maišos lizdo būseną į migruojančią. Taip pat reiktų užtikrinti, kad subkomandą *node* būtų galima iškviešti tik tada, kai einamasis mazgas importuoja komandoje nurodytą maišos lizdą ir kai mazgas nurodytas subkomandoje *node* yra einamasis mazgas. Toks pakeitimas reikalingas norint užtikrinti, kad už maišos lizdų pertvarkymo proceso užbaigimą būtų atsakingas tik tas mazgas, kuris importuoja maišos lizdą. Kitu atveju, nesant šiam pakeitimui, būtų galima pasiekti situaciją, kai pirminis mazgas pakeičia maišos lizdo būseną į migruojančią ir iš karto užbaigia maišos lizdo pertvarkymo procesą gaudamas subkomandą *node*.

Įvykdžius visus siūlomus pakeitimus, maišos lizdo pertvarkymo procesas būtų vykdomas siunčiant komandas:

1. *Cluster setslot <maišos lizdas> migrating <tikslinis mazgas>* – ši komanda pakeistų maišos lizdo būseną į migruojančią ir ši informacija būtų pasidalinta su kitais mazgais paskalų protokolo pagalba.
2. *Cluster setslot <maišos lizdas> importing <pirminis mazgas>* – po pakeitimų šią komandą būtų galima iškviešti tik tada, kad buvo gauta paskalų informacija, kad maišos lizdas yra migruojančioje būsenoje.
3. *Migrate* – duomenys yra perkeliami iš pirminio mazgo į tikslinį mazgą.
4. *Cluster setslot <maišos lizdas> node <tikslinis mazgas>* – šią komandą būtų galima išsiųsti tik mazgui, kuris importuoja maišos lizdą. Taip būtų užbaigtas maišos lizdo pertvarkymo procesas, o pirminis mazgas išvalytų maišos lizdo migruojančią būseną tik tada, kai gautų paskalų informaciją, kad tikslinis mazgas (arba tikslinio mazgo pavaldus mazgas) tapo atsakingas už migruojantį maišos lizdą.

2 klaida: Komanda *cluster setslot* priima neteisingus parametrus

Tiriant 1 klaidos pasireiškimo aplinkybes, buvo rasta, kad yra pažeidžiamas maišos lizdų invariantas, kai komandos *cluster setslot* subkomandoms *importing* ir *migrating* yra perduodami blogi parametrai:

1. *Migrating* subkomanda leidžia parametruose perduoti tikslinį mazgą, kuris sutampa su einamuoju mazgu, kuriam yra siunčiama administravimo komanda.

2. *Importing* subkomanda leidžia parametruose perduoti pirminį mazgą, kuris sutampa su einamuoju mazgu.
3. Subkomandos *importing* parametruose galima perduoti maišos lizdą, už kurį nėra atsakingas komandoje nurodytas pirminis mazgas.

Visas šia klaidas pavyko atkartoti realioje sistemoje naudojantis *redis-cli*. Šias klaidas galima lengvai ištaisyti sistemoje pridėdant papildomus patikrinimus, kad komandos yra kviečiamos perduodant teisingus parametrus.

3 klaida: Komandos *cluster addslots* ir *cluster delslots* pažeidžia maišos lizdų savybę

Modelio tikrinimo metu buvo rasta, kad komandų *cluster addslots* ir *cluster delslots* naudojimas pažeidžia maišos lizdų invariantą. Einamajame mazge apdorojus šias komandas, maišos lizdų atsakomybių pasikeitimas nepasiekia kitų mazgų.

Deja, bet šios klaidos nepavyko pilnai atkartoti realioje sistemoje – įvykus maišos lizdų pasikeitimams, dėl paskalų protokolo visada buvo sugrįžtama į pradinę būseną. Taip atsitiko dėl to, kad kitų mazgų požiūriu neįvyko jokie maišos lizdų pasikeitimai ir einamojo mazgo *configEpoch* reikšmė (skaičius nusakantis mazgo būsenos naujumą) buvo mažesnė ir nepakito – kitų mazgų *configEpoch* reikšmė buvo didesnė ir jų paskalų informacija laimėjo.

Norint ištaisyti šią klaidą būtų galima įvykus maišos lizdų pasikeitimams padidinti einamojo mazgo *configEpoch* reikšmę, kad kiti mazgai priimtų šią informaciją kaip naujausią. Kitas būdas taisyti šią klaidą: užtikrinti, kad šias komandas būtų galima apdoroti tik tada, kai sistema yra reikalingoje būsenoje, kurios metu apdorojus *addslots* ir *delslots* komandas nebūtų pažeista maišos lizdų savybė.

Ši sistemos klaida nėra kritinė kadangi „Redis Cluster“ dokumentacijoje nurodyta, kad šią komandą patartina siųsti tik tada, kai yra kuriamas naujas blokinys arba kai bandoma ištaisyti nenumatytas klaidas. Patys kūrėjai nurodo, kad šios komandos kvietimas nereikiamu metu gali palikti blokinį klaidingoje būsenoje, kaip ir buvo rasta modelio tikrinimo metu. Taip pat *cluster delslots* komanda nėra plačiai naudojama ir ji sistemoje buvo pridėta tik norint turėti pilnai užpildytą API sąsają.

5 Išvados

TLA⁺ formalia specifikavimo kalba sudarius „Redis Cluster“ formalią specifikaciją ir atlikus modelio tikrinimą, buvo nustatyta, kad tam tikrose situacijose sistema gali veikti nekorektiškai – yra pažeidžiama sistemos maišos lizdų savybė (1). Pradinio modelio tikrinimo metu buvo identifikuotos sistemos klaidos, kurios buvo atkartotos realioje sistemoje naudojant tekstinę sąsają *redis-cli*. Šioms klaidoms buvo pateikti galimi sprendimo būdai, kaip jas būtų galima ištaisyti.

Detali sistemos specifikacija, artima programinio kodo abstrakcijos lygiui, leido surasti klaidas susijusias su blogais komandos parametrais. Rašant specifikaciją tik pagal sistemos dokumentaciją, šios klaidos galėjo būti nepastebėtos, kadangi nesiremiant programiniu kodu, būtų daroma prielaida, kad sistemoje egzistuoja korektiški komandos parametru patikrinimai.

Sudaryta „Redis Cluster“ sistemos formali specifikacija leis toliau tirti ir kitas „Redis Cluster“ sistemos savybes, bei leis patikrinti, ar atlikus sistemos pakeitimus yra išlaikomas algoritmo korektiškumas ir nėra pažeidžiamos sistemos savybės.

Literatūra

- [1] B. Veal and A. Foong. Performance scalability of a multi-core web server. In Proceedings of the 3rd ACM/IEEE Symposium on Architecture for Networking and Communications Systems, pp. 57–66, New York, NY, USA. ACM, 2007.
- [2] V. Zakhary, D. Agrawal, and A. E. Abbadi. Caching at the web scale. Proceedings of the VLDB Endowment, 10:2002–2005, 2017.
- [3] Y. Cheng, A. Gupta, and A. R. Butt. An in-memory object caching framework with adaptive load balancing. In Proceedings of the Tenth European Conference on Computer Systems, 4:1–4:16, New York, NY, USA. ACM, 2015.
- [4] S. Chen, X. Tang, H. Wang, H. Zhao, and M. Guo. Towards scalable and reliable in-memory storage system: a case study with Redis. In 2016 IEEE Trustcom/BigDataSE/ISPA, pp. 1660–1667, 2016.
- [5] B. Li, Y. Fu, and Z. Li. The research and improvement of distributed caching system Memcached. In 2017 4th International Conference on Information, Cybernetics and Computational Social Systems (ICCSS), pp. 460–463, 2017.
- [6] A. Patil and R. Ingle. Leveraging information bus with in-memory caching for service oriented architecture. In 2013 Third International Conference on Advances in Computing and Communications, pp. 382–388, 2013.
- [7] J. L. Carlson. Redis in action. Manning Publications Co., Greenwich, CT, USA, 2013. 5, 322 p.
- [8] Z. Ji, I. Ganchev, M. O'Droma, and T. Ding. A distributed Redis framework for use in the UCWW. In 2014 International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery, pp. 241–244, 2014.

- [9] D. Li, M. Dong, Y. Yuan, J. Chen, K. Ota, and Y. Tang. SEER-MCcache: a prefetchable memory object caching system for IoT real-time data processing. *IEEE Internet of Things Journal*, 5:3648–3660, 2018.
- [10] Redis. Redis cluster specification. <https://redis.io/topics/cluster-spec>, 2018. Kreiptasi 2019-05-19.
- [11] D. Abadi. Consistency tradeoffs in modern distributed database system design: CAP is only part of the story. *Computer*, 45:37–42, 2012.
- [12] F. A. Bianchi, A. Margara, and M. Pezzè. A survey of recent trends in testing concurrent software systems. *IEEE Transactions on Software Engineering*, 44:747–783, 2018.
- [13] D. Malhotra. Deadlock prevention algorithm in Grid environment. *MATEC Web of Conferences*, 57:02013, 2016.
- [14] C. Newcombe, T. Rath, F. Zhang, B. Munteanu, M. Brooker, and M. Deardeuff. How Amazon Web Services uses formal methods. *Communications of the ACM*, 58:66–73, 2015.
- [15] J. M. Wing. A specifier’s introduction to formal methods. *Computer*, 23:8–23, 1990.
- [16] S. Liu. Validating formal specifications using testing-based specification animation. In *Proceedings of the 4th FME Workshop on Formal Methods in Software Engineering*, pp. 29–35, New York, NY, USA. ACM, 2016.
- [17] N. A. Ali, A. A. Mirghani, and A. Y. Ibrahim. Alneelain: a formal specification language. In *2017 International Conference on Communication, Control, Computing and Electronics Engineering (ICCCCEE)*, pp. 1–9, 2017.
- [18] L. Lamport, J. Matthews, M. Tuttle, and Y. Yu. Specifying and verifying systems with TLA+. In *Proceedings of the 10th Workshop on ACM SIGOPS European Workshop*, pp. 45–48, New York, NY, USA. ACM, 2002.
- [19] O. Mosbahi. Combining formal methods for the development of reactive systems. *ACM Transactions on Embedded Computing Systems*, 12:16:1–16:29, 2013.
- [20] L. Lamport. The temporal logic of actions. *ACM Transactions on Programming Languages and Systems*, 16:872–923, 1994.

Dekomponavimo kortų metodas sudėtingoms informacinėms sistemoms dekomponuoti

Gediminas Krasauskas

Vilniaus universitetas, Matematikos ir informatikos fakultetas,
Didlaukio g. 47, LT-08303 Vilnius
gediminas.krasauskas@mif.stud.vu.lt

Santrauka. Šiame straipsnyje pateikiami sudėtingų informacinių sistemų dekomponavimo, būtino siekiant mažinti artefakto, kurį reikia įgyvendinti, sudėtingumą, tyrimo rezultatai. Programų sistemų kūrimo srityje yra atlikta įvairių tyrimų, skirtų dekompozicijos procesui analizuoti ir kiekybiniais dekomponavimo rezultatų vertinimams atlikti. Tačiau programų sistemų kūrime naudojami „skaidyk ir valdyk“ metodai negali būti tiesiogiai taikomi sudėtingoms informacinėms sistemoms dekomponuoti, pamatuoti dekompozicijos gerumą ir palyginti su kitomis alternatyvomis. Pasiūlytasis dekomponavimo kortų metodas, kuris apima struktūrinį dekompozicijos vertinimą atsižvelgiant į kiekybinius atributus, charakterizuojamas kaip hierarchinis ir nedarantis konkrečių techninių sprendimų aukštam abstrakcijos lygmenyje. Gauti rezultatai sudaro prielaidas tolesniems tyrimams vykdyti.

Raktiniai žodžiai: sistemų dekomponavimas, informacinės sistemos, sudėtingos sistemos, kokybės funkcijų sklaidos metodika, struktūrinis sudėtingumas.

1 Įvadas

Kuriant sudėtingas informacines sistemas dekomponavimo procesas turi būti pagrįstas ir metodiškai vykdomas. Tai yra vienas iš pirminių tokių sistemų kūrimo gyvavimo ciklo etapų. Nuo dekompozicijos kokybės tiesiogiai priklauso visos kuriamos sistemos ir jos dalių kokybė bei sudėtingumas.

Už sistemos dekompoziciją yra atsakingi sistemų architektai (toliau – architektai). Tačiau kiekvieno architekto kompetencijos, patirtis ir požiūris į kuriamas sistemas skiriasi. Dėl šios priežasties yra tikėtina, kad kiekvieno iš architektų atlikto sistemos dekomponavimo rezultatai skirsis. Prie skirtingų rezultatų prisideda ir tai, kad nėra visuotinai pripažintų universalių standartų arba metodų šiai veiklai atlikti, vyrauja architektūros stilių įvairovė. To

pasekmė – sistemų kūrimo projektų nesėkmės, kurias reikšmingai nulemia nekokybiška dekompozicija, sukuriant sistemas, kurios nepasiekia norimų tikslų, arba padidina sistemos sudėtingumą iki nevaldomo.

Pateiktos priežastys leidžia teigti, kad sudėtingų informacinių sistemų dekomponavimas yra aktuali problema. Prasmingi rezultatai šioje srityje, tokie kaip metodiniai pagrindai, kiekybinis dekompozicijos matavimas ir dekompozicijos alternatyvų vertinimas, gali ne tik palengvinti architektų darbą, bet ir užtikrinti tokias kuriamų sistemų savybes, kaip kokybė ir potencialus sudėtingumas.

Šiame straipsnyje pateikiamas atlikto tyrimo rezultatas – parodoma, kokiū būdu įvertinti atliktą dekompoziciją ir kaip gauti kiekybinius vertinimo rezultatus, šitaip užtikrinant skirtingų dekompozicijos alternatyvų palyginimo galimybes.

Antrame skyriuje apžvelgiami kitų autorių, nagrinėjusių panašią problemą, vykdyti tyrimai ir rezultatai. Trečiame skyriuje aptariamas dekomponavimo kortų metodas bei jo dalys ir kuris yra grindžiamas kokybės funkcijų sklaidos metodikos principais. Ketvirtame skyriuje pateikiamos dekompozicijos matavimo ir vertinimo galimybės taikant dekomponavimo kortų metodą. Penktame skyriuje pateiktos darbo išvados.

2 Susiję darbai

Nemažai tyrimų yra atlikta sistemos dekomponavimo strategijų analizės srityje. Tačiau nėra aišku, kuris dekomponavimo būdas labiausiai tinkamas konkrečiam sistemos tipui arba jos dekompozicijai konkrečiame abstrakcijos lygmenyje. Literatūroje dažniausiai galima aptikti tokius dekomponavimo būdus: funkcinę [1], probleminių freimų [2], agentų [3], kintamumo [4], surinkimo [5] ir kitas. Straipsnyje [6] yra pateikiamas apibendrintas dekomponavimo būdų klasifikavimas, išskiriantis 11 skirtingų galimų dekompozicijos kategorijų kombinuojant sistemos struktūrų, elgsenų ir tikslų kriterijus.

Taip pat yra atlikta įvairių tyrimų sistemų sudėtingumo srityje ir kaip jį sąlygoja dekompozicija. Straipsnis [7] išskiria 3 sistemų sudėtingumo tipus: struktūrinį, dinaminį ir organizacinį. Autoriai teigia, kad struktūrinis sudėtingumas priklauso nuo sistemos vidaus, t. y. jos sudedamųjų dalių. Dinaminis sudėtingumas priklauso nuo sistemos elgsenos, funkcijų, o organizacinis sudėtingumas yra veikiamas organizacijos struktūros ir sistemos vystymo procesų.

Struktūriniam sudėtingumui matuoti nemažai autorių pateikia įvairių kiekybinių matavimo būdų. Vienas iš jų straipsnyje [8] pateikia kompleksinį matavimą atsižvelgiant į 3 kriterijus: individualių sudedamųjų dalių sudėtingumą, ryšių tarp sudedamųjų dalių sudėtingumą ir topologinį sistemos sudėtingumą. Straipsnis [9] taip pat siūlo analogišką struktūrinio sudėtingumo matavimą, kuriuo remiantis yra atsižvelgiama į dekompozicijos granuliarumą, t. y. sudedamųjų dalių kiekį. Literatūroje galima rasti topologinio sistemų sudėtingumo matavimus grafų struktūrose pasinaudojant matricos energija [10].

Straipsnyje [11] pateiktos 8 struktūrinio sudėtingumo metrikos, suskirstytos pagal moduliarumą, pakartotinį panaudojimą ir sistemos vidinę hierarchiją, o [12] autoriai pateikia 9 metrikas, kurių dalis yra skirta struktūriniam sudėtingumui matuoti. Ryšiams tarp sudedamųjų dalių sudėtingumui pamatuoti straipsnio [9] autoriai siūlo pagal 3 aspektus: suderinamumu, savalaikiškumu ir konfidencialumu, o šie aspektai papildomai turi individualią vertinimo skalę. Straipsnio [12] autoriai papildomai siūlo įtraukti ryšių kryptingumą ir pabrėžia ryšių ciklą svarbą sudėtingumo matavimui. Kai kurie autoriai siūlo matricomis paremtos metodikos taikymą sistemos sudedamųjų dalių tarpusavio ryšiams analizuoti, kuri yra vadinama DSM [13].

3 Dekomponavimo kortų metodas sudėtingoms sistemoms dekomponuoti

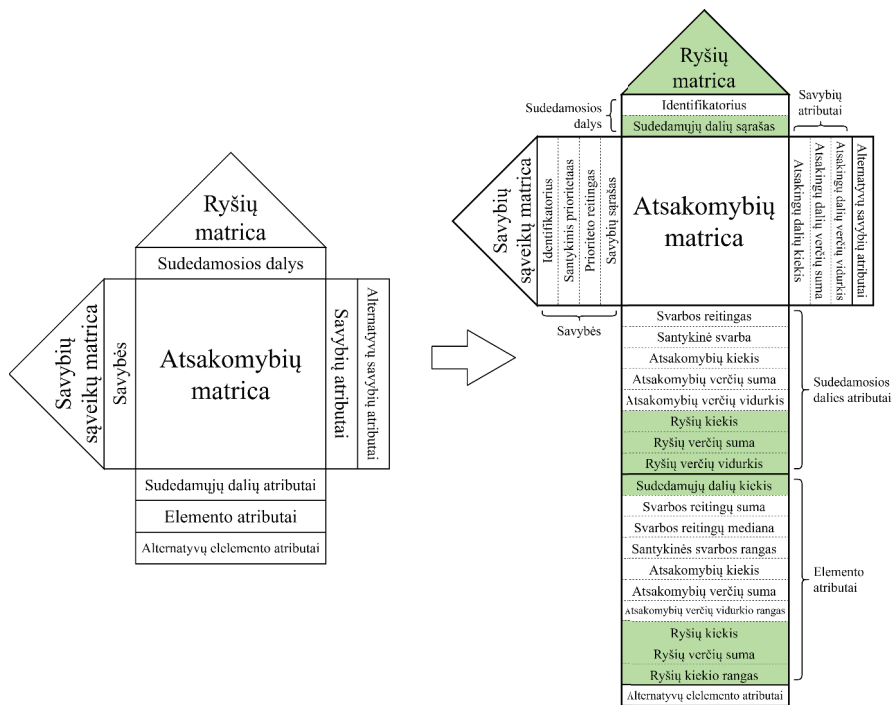
Tyrimo metu sudarytas dekomponavimo kortų (DK) metodas savo esme grindžiamas kokybės funkcijų sklaidos (KFS) metodika [14]. DK metodas yra skirtas sudėtingoms sistemoms dekomponuoti ir jį taikant galima pasiekti šiuos tikslus:

- transformuoti sistemos reikalavimus į sistemos architektūrinius sprendinius;
- užtikrinti, kad vykdant dekompoziciją nebūtų ignoruoti ar praleisti jokie reikalavimai;
- įvertinti ir palyginti skirtingas dekompozicijos alternatyvas ir pasirinkti labiau tinkamą.

DK metodas – tai KFS metodikos ir jos kokybės kortos pritaikymas sudėtingų sistemų dekomponavimo procesui. Originali KFS metodika yra skirta naudotojų poreikiams transformuoti į produkto inžinerines charakteristikas.

Po pirmojo taikymo Japonijos automobilių pramonėje ši metodika buvo adaptuota daugelyje skirtingų sričių, apimant ir programų sistemų kūrimą [15].

Siekiant užtikrinti sisteminių sudėtingų sistemų dekomponavimo procedūrą, DK metode išlaikomi pagrindiniai KFS metodikos principai ir specializuota bei išplėsta KFS kokybės korta: dekomponavimo kortoje aprašomos norimo dekomponuoti sistemos elemento savybės ir sudedamosios dalys. Be to, kortose turi būti tiek savybių, tiek sudedamųjų dalių kiekybiniai atributai. Galiausiai, perėjimas į žemesnį lygmenį atliekamas kiekvienai sudedamajai daliai sukuriant po naują dekomponavimo kortą.



1 pav. Dekomponavimo kortos dalys.

1 pav. pateiktos kortos vaizduoja konkrečios sistemos arba jos sudedamosios dalies dekompoziciją. Prieš atliekant dekompoziciją reikalavimų inžinieriai pateikia sąrašą reikalavimų, kuriuos turi tenkinti dekomponuojamas elementas (savybių sąrašas). Tada, atsižvelgdamas į reikalavimų rinkinį,

architektas parengia architektūrinį sprendinį: dekomponuoja elementą į sudedamąsias dalis (gaunamas sudedamųjų dalių sąrašas). Kiekvienai tokiai sudedamajai daliai architektas priskiria atsakomybę realizuoti konkrečius reikalavimus (atsakomybių matrica) bei užpildo likusius kortos atributus. Perėjimas į žemesnį abstrakcijos lygmenį vykdomas kiekvienai sudedamajai daliai sukūrus atskirą dekomponavimo kortą ir naują reikalavimų rinkinį (savybių sąrašas).

1 pav. taip pat yra pavaizduoti papildomi dekomponavimo kortos atributai. Kairėje pusėje yra pateikta abstrakti kortos struktūra, kurioje atributai suskirstyti į grupes, o dešinėje pusėje pateikta detali kortos struktūra. Kadangi straipsnyje nagrinėjamas dekompozicijos struktūrinis vertinimas, šiame kontekste aktualūs yra tik dalis kortos atributų. Šią aibę sudaro: sudedamosios dalys (sudedamųjų dalių sąrašas), ryšių matrica, sudedamųjų dalių atributai (ryšių kiekis, ryšių verčių suma, ryšių verčių vidurkis) ir dekomponuojamo elemento atributai (sudedamųjų dalių kiekis, ryšių kiekis, ryšių verčių suma, ryšių verčių vidurkis). Išvardinti atributai dešinėje kortoje (žr. 1 pav.) paryškinti išsiskiriančia spalva.

4 Dekompozicijos vertinimas ir pasirinkimas

Sistemų sudėtingumui matuoti naudojami įvairūs matai. Vienas pagrindinių informacinių sistemų sudėtingumo matų yra struktūrinis (dar vadinamas topologiniu) sudėtingumas. Tą sąlygoja šiandienos inžinerinių sistemų sudėtingumas, glūdintis jų persipynusioje architektūroje, kurią įgyvendina daug sudedamųjų dalių ir jų tarpusavio sąveika. Todėl, norint įvertinti sudėtingą sistemą arba palyginti ją su kitomis sistemomis, skaitinis jos struktūrinio sudėtingumo vertinimas yra privalomas.

Struktūrinis sudėtingumas nusakomas nagrinėjant sistemos struktūrą ir kompoziciją. Detaliau aptarsime dekomponavimo kortų metode naudojamus dekompozicijos struktūrinio sudėtingumo matus, nusakomus posistemų kiekiu ir jų tarpusavio sąveika.

Posistemų kiekis. Posistemų kiekis turi tiesioginę įtaką sistemos sudėtingumui. Jeigu sistema vienu būdu būtų išskaidyta į 2, o kitu būdu į 5 vienodo sudėtingumo dalis, antras dekompozicijos būdas lemtų aukštesnį sistemos sudėtingumą. Didelis sudedamųjų dalių kiekis sąlygoja daugiau potencialių tarpusavio ryšių, daugiau kūrimo ir palaikymo pastangų.

Natūralu, kad dekompozicija nėra prasminga, jeigu posistemų kiekis yra lygus 0 arba 1. Posistemų kiekiui esant lygiam 0, tai reiškia, kad sistemai dekompozicija nėra taikoma ir ji yra traktuojama kaip atominis neskaidomas elementas. Jeigu posistemų kiekis lygus 1, tuomet, neprarandant informacijos, ji gali būti dekomponuojama tik į save pačią.

Posistemų tarpusavio ryšiai. Tai aspektas, nusakantis kaip konkreti posistemė sąveikauja su kitomis posistemėmis. Nuo jo tiesiogiai priklauso visos sistemos sudėtingumas. DK metodas matuoja tarpusavio ryšius dviejuose skirtinguose kontekstuose: elemente, kuris dekomponuotas ir kiekvienoje elemento sudedamojoje dalyje. Matuojant tarpusavio sąveikos aspektą galima naudoti kelis matavimus.

Pirma, tai ryšių kiekis. Kuo daugiau struktūrinis elementas turės ryšių, tuo jis bus sudėtingesnis: reikalaus daugiau integracijų kūrimo, transakcijų apdorojimo, testavimo ir palaikymo pastangų. Kadangi posistemės viena su kita palaiko ryšį interfeisų pagalba, jų pokyčio rizika ir kaina smarkiai išauga dėl priklausomybių sukkelto inertiškumo. Tačiau visiškai išvengti tarpusavio ryšių negalima. Kiekviena posistemė turi turėti bent vieną ryšį su kita posisteme, kitaip ji negalėtų būti sistemos dalis – tokiu atveju ši posistemė būtų atskira nepriklausoma sistema. Ryšių kiekis gaunamas taikant formules (1) – sudedamosios dalies kontekste ir (2) – dekomponuojamo elemento kontekste:

$$f(x) = \sum_{i=1}^n 1, \text{ tiems } i, \text{ kuriems } x \neq x_i \text{ ir } C(x, x_i) > 0, n > 0 \quad (1)$$

ir

$$\alpha = \frac{\sum_{i=1}^n f(x_i)}{2}, n > 0. \quad (2)$$

Čia $f(x)$ – sudedamosios dalies x ryšių su kitomis dalimis kiekis; α – bendras ryšių kiekis dekomponuotame elemente; n – sudedamųjų dalių kiekis; $C(x, x_i)$ – tarp sudedamųjų dalių x ir x_i egzistuojantis ryšio stiprumas.

Antra, tai ryšio stiprumo vertinimas. Ryšys, kuriuo dvi posistemės viena kitai asinchroniškai perduoda gigabaitus informacijos per sekundę užtikrinant maksimalų konfidencialumą bei informacijos nepraradimą stipriai prisidės prie sistemos sudėtingumo. Tačiau ryšys, kuriuo viena posistemė kitai kartą per parą perduos savo būseną *true* arba *false* formatu, menkai paveiks ben-

drą sistemos sudėtingumą. Sudedamųjų dalių tarpusavio sąveika DK metode vertinama trimis skirtingais tipais: neegzistuojančiu, silpnu ir stipriu.

Ryšio stiprumo matas leidžia įvertinti jo intensyvumą. Šis matas taip pat pravartus kai ryšių kiekis skirtingose dalyse yra vienodas – tokiu atveju sudėtingesnė dalis bus ta, kurios ryšių stiprumų vertės aukštesnės. Ryšių stiprumų suma gaunama taikant formules (3) – sudedamosios dalies kontekste ir (4) – dekomponuojamo elemento kontekste:

$$g(x) = \sum_{i=1}^n C(x, x_i), \text{ tiems } i, \text{ kuriems } x \neq x_i, n > 0 \quad (3)$$

ir

$$\beta = \frac{\sum_{i=1}^n g(x_i)}{2}, n > 0. \quad (4)$$

Čia $g(x)$ – sudedamosios dalies x ryšių su kitomis dalimis stiprumų suma; β – bendra ryšių stiprumų suma dekomponuotame elemente; n – sudedamųjų dalių kiekis; $C(x, x_i)$ – tarp sudedamųjų dalių x ir x_i egzistuojantis ryšio stiprumas.

Dar vienas matas, susijęs su ryšių stiprumu, yra sudedamosios dalies ryšių stiprumo vidurkis. Jis leidžia įvertinti, kokie yra vyraujantys sudedamosios dalies ryšiai ir yra gaunamas taikant formulę (5):

$$h(x) = \frac{f(x)}{g(x)}. \quad (5)$$


Čia $h(x)$ – sudedamosios dalies x ryšių stiprumo vidurkis; $g(x)$ – sudedamosios dalies x ryšių su kitomis dalimis stiprumų suma; $f(x)$ – sudedamosios dalies x ryšių su kitomis dalimis kiekis.

Paskutinis matas, susijęs su ryšių stiprumu, yra visų dekomponuojamo elemento sudedamųjų dalių ryšių kiekio rangas. Šis atributas leidžia identifikuoti neproporcingai sudėtingas ir inertiškas elemento sudedamąsias dalis, apskaičiuojant skirtumą tarp didžiausių ir mažiausių ryšių kiekių turinčių dalių. Atributo dydis gaunamas taikant formulę (6):

$$\gamma = \max_{vi \in n} f(x_i) - \min_{vi \in n} f(x_i), [n] = \{1, \dots, n\}. \quad (6)$$

Čia γ – ryšių kiekio rangas; $f(x)$ – sudedamosios dalies x ryšių su kitomis dalimis kiekis; n – sudedamųjų dalių kiekis.

Visi prieš tai aprašyti posistemų tarpusavio ryšių grupės atributai gaunami iš ryšių matricos bei prisideda prie tendencijų atpažinimo. 2 pav. pateikiamas pavyzdys, t. y. trys skirtingi DK metodo ryšių matricos užpildymo variantai: A variante dauguma sudedamųjų dalių nesąveikauja tarpusavyje; B variante yra daug tarpusavio ryšių, iš kurių stiprių ryšių yra dauguma; C variante dvi sudedamosios dalys (c ir g) turi daugumą ryšių.



2 pav. Ryšių matricos užpildymo pavyzdžiai.

Naudojant DK metodą ir įvertinus dekompozicijas, galima pasirinkti tinkamą alternatyvą. Dekompozicijos alternatyvos yra lyginamos gretinant elemento atributų grupę (žr. 1 pav.), į kurią patenka šie struktūrinio sudėtingumo vertinimo atributai: dekomponuotų dalių kiekis, ryšių kiekis, ryšių verčių suma ir ryšių kiekio rangas. Konkretūs nurodymai, kurie architektui leistų vienareikšmiškai pasirinkti dekompoziciją, šio darbo kontekste nėra detalizuojami.

5 Išvados

Darbe yra pateiktas dekomponavimo kortų metodas sudėtingoms informacinėms sistemoms dekomponuoti ir toms dekompozicijoms vertinti. Metodas įgyvendina hierarchinį dekomponavimo būdą, kur pirmame lygmenyje identifikuojami sistemos elementai (posistemės), o žemesniame lygmenyje – tų elementų sudedamosios dalys. Kitaip sakant, sudėtingų informacinių sistemų dekomponavimo metu pirmajame lygmenyje nereikia taikyti dekomponavimo būdų (kitais žodžiais, rinktis konkretų architektūros stilių), kurie jau reiškia konkrečius techninius ribojimus. Gautos dekompozicijos tinkamumas nurodytų kriterijų ir sudėtingumo atžvilgiu turi būti vertinamas analizuojant atitinkamas kortos dalis, užpildomas pagal metodo taisykles.

Tai leidžia gauti skaitinį dekompozicijos struktūrinio sudėtingumo įvertį, kas yra privaloma, norint palyginti skirtingas dekompozicijas. Naudojant dekomponavimo kortų metodą, skirtingų dekomponavimo alternatyvų palyginimas vykdomas tarpusavyje gretinant šiuos atributus: dekomponuotų dalių kiekį, ryšių kiekį, ryšių verčių sumą ir ryšių kiekio rangą.

Literatūra

- [1] Komoto, H., & Tomiyama, T. (2012). A framework for computer aided conceptual design and its application to system architecting of mechatronics products. *Computer-Aided Design*, 44(10), 931-946.
- [2] Colombo, P., Khendekb, F., & Lavazza, L. (2012). Bridging the gap between requirements and design: an approach based on problem frames and SysML. *Journal of Systems and Software*, 85(3), 717-745.
- [3] Holmgren, J., Persson, J., & Davidsson, P. (2008). Agent based decomposition of optimization problems. *First International Workshop on Optimization in Multi-Agent Systems*.
- [4] Löwy, J. (2019). *Righting software*. Addison-Wesley Professional.
- [5] Chiriac, N. (2011). Three approaches to complex system decomposition. *DSM 2011: Proceedings of the 13th International DSM Conference 2011*.
- [6] Koopman, P.J.A. (1995). A taxonomy of decomposition strategies based on structures, behaviours, and goals. *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, 17179, 611-618.
- [7] Sheard S.A., & Mostashari A. (2010). A complexity typology for systems engineering. *Systems Engineering. INCOSE International Symposium*, 20(1), 933-945.
- [8] Sinha, K., & De, W.O.L. (2013). A network-based structural complexity metric for engineered complex systems. *IEEE International Systems Conference*, 426-430.
- [9] Luo A. (2019). A structural complexity metric method for complex information systems. *JSW*, 14(7), 332-339.
- [10] Sinha, K., & de Weck, O. L. (2016). Matrix energy as a measure of topological complexity of a graph. *arXiv preprint arXiv:1608.08456*.
- [11] Hornby G. (2007). Modularity, reuse, and hierarchy: measuring complexity by measuring structure and organization. *Complexity*, 13(2), 50-61.
- [12] Tamaskar, S., Neema, K., & DeLaurentis, D. (2014). Framework for measuring complexity of aerospace systems. *Research in Engineering Design*, 25(2), 125-137.
- [13] Eppinger, S.D., Whitney, D.E., Smith, R.P., & Gebala, D.A. (1994). A model-based method for organizing tasks In product development. *Research in Engineering Design*, 6(1), 1-13.
- [14] Akao, Y. (2004). *QFD: quality function deployment – integrating customer requirements into product design*. Productivity Press.
- [15] Chan, L.K., & Wu, M.L. (2002). Quality function deployment: a literature review. *European journal of operational research*, 143(3), 463-497.

Anglų kalbos mokymo nuotoliniu būdu metodika ir jos taikymas

Ingrida Lisinskiėnė, Ramūnas Kubiliūnas

Kauno technologijos universitetas,
K. Donelaičio g. 73, LT-44249 Kaunas
ingrida.lisinskiene@ktu.edu

Santrauka. Anglų kalbos mokytojai nuolat turi tobulinti savo nuotolinio mokymo kompetencijas, peržiūrėti savo darbo metodiką, nes nuotolinis mokymas reikalauja naujų metodikų išbandymo. Straipsnyje nagrinėjami nuotolinio mokymo ir mokymosi metodų taikymo anglų kalbos pamokose aspektai, pristatoma susisteminta nuotolinio anglų kalbos mokymo metodika sinchroninėms bei asinchroninėms pamokoms, aptariami mokytojų poreikio naudoti šią metodiką tyrimo rezultatai.

Raktiniai žodžiai: Anglų kalba, anglų kalbos mokymas, anglų kalbos mokymas nuotoliniu būdu, anglų kalbos mokymo metodika.

1 Įvadas

Mokslo pažanga ir globalizacijos procesai, keičiantys visuomenės poreikius, šalies raida ir jos perspektyvos kelia naujus uždavinius ugdymo turiniui ir jo įgyvendinimui. Siekti visapusės ugdymo(si) pažangos, užtikrinant ugdymo kokybę ir skiriant tinkamą dėmesį kiekvieno vaiko ugdymo(si) poreikiams, tampa bene svarbiausiu mokyklos tikslu. Lietuvoje, prasidėjus ugdymo turinio atnaujinimo procesams bei ugdymo turinio skaitmenizavimui, akcentuojami personalizuoti ugdymo turinio ir organizavimo principai (pvz., daugiau dėmesio skiriama integruotam, personalizuotam ugdymui, mokytojo vaidmens kaitai, perėjimui prie mokymosi paradigmos, duomenimis grįstam ugdymui, skaitmeninių technologijų naudojimui ugdyme). Savivaldybės ir mokyklos skatinamos imtis pokyčių, tačiau mokyklų bendruomenėms ir specialistams trūksta vidinės parengties, reikiamų kompetencijų, praktinių gebėjimų, išteklių bei daugelyje mokyklų nėra vieningų virtualiajam mokymui pritaikytų platformų [1]. Šios problemos išryškėjo karantino laikotarpiu, kai mokyklose mokytojai naudojo skirtingas virtualiąsias mokymosi platformas ir priemones. Mokslinėje literatūroje, kaip teigia Rutkauskienė ir

kt. (2012), taip pat pažymima, jog didelė nuotolinio mokymosi platformų ar priemonių įvairovė nėra gerai ir mokykloms rekomenduojama pasiūlyti tik kelias taikytinas platformas su nesudėtingu valdymu [2]. Taigi, reikalingas sutarimas ir vieninga strategija mokyklų bendruomenėse.

Technologijų panaudojimas įgalina ir naujų mokymosi metodų taikymą. Simonson ir Zvacek [3] analizuoja nuotolinio mokymo metodikos bei platformų taikymą. Clardy pažymi skirtumus tarp sinchroninio ir asinchroninio mokymo, aptaria abu komunikavimo aspektus [4]. Varlamis akcentuoja nuotolinio mokymosi privalumus bei tiria nuotolinio mokymo metodų taikymą įvairių dalykų, tarp jų ir užsienio kalbų, pamokose [5]. Nuotolinio mokymosi priemonių bei metodų taikymas aktualus ir anglų kalbos pamokose.

Didžiausia problema yra mokytojų per didelė apkrova nuotolinėse anglų kalbos pamokose. Mokytojai jaučiasi pasimetę savo darbe, bando perkelti tradicinio darbo metodikas į nuotolinį ugdymą, bet tai dar labiau apsunkina juos pačius bei mokinius. Pastarieji pasimeta metodikų ir platformų gausybėje. Apžvelgus Simonson ir Zvacek (2019) atliktus nuotolinio mokymo metodikos tyrimus, galima daryti išvadą, jog mokykloms tikslinga pateikti ne atskirą sąrašą įvairių nuotoliniam mokymui skirtų platformų ar priemonių, o dvi ar tris nuotoliniam ugdymui skirtas nuotolinio ugdymo platformas, turinčias nesudėtingas valdymo funkcijas.

Galimas problemos sprendimas būtų susistemintos nuotolinio anglų kalbos mokymo metodikos taikymas praktikoje. Pokytis būtų įvertinamas apklausiant mokinius apie darbą taikant naują metodiką. Tačiau problema yra ta, kad nėra sukurtos vieningos nuotolinio anglų kalbos mokymo metodikos, skirtos mokytojams, ir trūksta praktinių taikymo pavyzdžių. Virtualūs sinchroniniai mokymo moduliai turi stipresnį poveikį nei nuotolinis mokymas, grįstas asinchronine komunikacija. Nustatyta, jog būtina sukurti kalbų mokymui skirtas virtualias mokymo laboratorijas, bet nėra nagrinėjama, kokia metodika remiantis jas sukurti. Taip pat tvirtinama, jog nuotolinis virtualusis mokymas turėtų remtis individualizuoto turinio kiekvienam mokiniui pateikimu, atskira metodika. Tačiau tada kyla klausimas, kodėl nėra kuriama nuotolinio mokymo metodika konkrečiai mokinių amžiaus grupei? Šiame straipsnyje nagrinėjami nuotolinio mokymo ir mokymosi metodų taikymo anglų kalbos pamokose aspektai, pristatoma susisteminta nuotolinio anglų kalbos mokymo metodika sinchroninėms bei asinchroninėms pamokoms, aptariami mokytojų poreikio naudoti šią metodiką tyrimo rezultatai.

2 Nuotolinio mokymo ir mokymosi metodų taikymas anglų kalbos pamokose

Anot Grakausko (2013), anglų kalbos metodai gali būti skirstomi į tradicinius metodus, tokius kaip aiškinimas, pasakojimas, pokalbis, paskaita, dialogai, gramatikos užduočių atlikimas su paaiškinimais, euristinis pokalbis, probleminis dėstymas, darbą su literatūra ir šiuolaikinius, tokius kaip mokymąsi bendradarbiaujant, projektus, darbą grupėse, komandose, žaidimus vaidmenimis, darbą su kompiuteriniais šaltiniais [6].

Vienas pagrindinių šiuolaikinio mokymo principų yra komunikacinis kalbos mokymosi principas. Pagal šią metodiką visi anglų kalbos besimokantieji, anot Erlickaitės (2014), ruošiami komunikuoti gyvenimiškose situacijose [7]. Suteikiami tvirti gramatinių struktūrų vartojimo pagrindai, o žodžių mokomasi palaipsniui, natūraliai. Taigi dėmesys sutelkiamas ne į trumpalaikį išmokimą, bet į realią kalbos vartoseną kasdienėse situacijose. Todėl didelis dėmesys skiriamas pastoviam žodžių, pagrindinių gramatinių struktūrų kartojimui.

Anglų kalbos mokymo specialistė Cowley (2006) teigia, kad kitas šią metodiką papildantis principas yra imersinis kalbos mokymo principas, kai mokiniai natūraliai tarsi panardinami į kalbą, kalbama tik angliškai nuo pat pradžių. Pradžioje tik gramatika paaiškinama lietuviškai, bet nuo septintos klasės lietuvių kalba anglų kalbos pamokose eliminuojama ir bendraujama tik angliškai [8].

Iš šių dviejų metodų palaipsniui pereinama prie kitų aktyvių mokymo ir mokymosi metodų: darbo grupėse, komandose, diskusijų, debatų, atpasakojimų, animuotų vaizdo įrašų panaudojimo ir kūrimo, komandinių situacinių žaidimų, rašto darbų, aktyvaus klausimo, projektų metodo taikymo vienai pamokai ar ilgalaikių projektų kūrimo.

Apibendrinant galima teigti, jog mokytojas pats renkasi mokomąją literatūrą, darbo metodus, darbo stilių, siekdamas ugdyti mokinių kalbines kompetencijas, vertybines nuostatas, sąmoningumą, plėtodamas bendravimo ir bendradarbiavimo kultūrą. Mokytojas taip pat renkasi nuotolinio mokymo metodus bei priemones pagal mokinių amžių, gabumus, sąmoningumą, vertybines nuostatas. Atsižvelgiant į tai, tikslinga apžvelgti nuotolinio mokymosi metodus ir jų panaudojimo anglų kalbos mokymesi galimybes.

2.1 Sinchroninio ir asinchroninio mokymo galimybės

Kaip nurodo Vilkonis ir kt. (2013), priklausomai nuo naudojamo komunikavimo būdo, išskiriami sinchroninio, asinchroninio ir multi-dimensinio nuotolinio mokymosi metodai [9].

Sinchroninis nuotolinis mokymasis remiasi mokytojo ir mokinio sinchronine komunikacija. Komunikavimo priemonėmis (vaizdo konferencijos) imituojamos tradicinio mokymosi veiklos (paskaita, seminaras, konsultacija, kt.). Naudojami ir nauji virtualiosios aplinkos mokymosi metodai. Privalumas – operatyvi komunikacija, trūkumas – mokiniai turi prisitaikyti prie mokymosi laiko bei mokymosi spartos. Sinchroninis mokymasis yra efektyvus, tačiau problema – turi būti visiems tinkamas tvarkaraštis.

Asinchroninio nuotolinio mokymosi atveju mokiniai mokosi savarankiškai, komunikuoja su mokytoju asinchroniškai (užklauso ir atsakymo laikai gali skirtis). Naudojamos asinchroninio komunikavimo priemonėmis (e. paštas, forumai, socialiniai tinklai, kt.) paremtos mokymosi veiklos. Privalumas – galimybė mokytis patogiu laiku ir sparta, trūkumas – neoperatyvi komunikacija. Asinchroninis mokymasis patogus užimtiems žmonėms, problema – kokybė, motyvacija.

Vis dėlto, labai skiriasi besimokančiųjų poreikiai, mokymosi tikslai, sąlygos, galimybės, motyvacija. Vieni nori mokytis klasėje, kiti – kokioje nors kitoje vietoje. Vieniems patogus sinchroninis mokymasis, kai galima iš karto viską išsiaiškinti, klausiti ir diskutuoti, o kitiems labiau tinka asinchroninis mokymasis dėl jų charakterio, būdo savybių.

Multi-dimensinio mokymosi atveju mokymąsi reikia organizuoti taip, kad mokiniai galėtų individualiai pasirinkti mokymosi vietą, laiką ir spartą. Pavyzdžiui, mokytojas dirba klasėje, veda pamoką, ją transliuoja į internetą ir daro vaizdo įrašą. Vieni mokiniai dalyvauja akivaizdžiai, kiti prisijungia virtualiai. Kas negali dalyvauti pamokoje, peržiūri vaizdo įrašą po pamokų.

Anot virtualaus mokymo specialisto Ala-Mutka ir kt. (2010), dar yra vadinamas pseudo-sinchroninis mokymasis, akcentuojantis sinchroninį mokymąsi, nes sinchroninis mokymasis yra efektyvesnis [10]. Tačiau mokiniams, negalintiems prisitaikyti prie įprasto sinchroninio mokymosi pagal tvarkaraštį, sinchroninį mokymąsi keičia pseudo-sinchroninis, kai sinchroninis procesas išsitiesia laike, t.y. imituojamas sinchroninis procesas. Pavyzdžiui, peržiūrėjus vaizdo įrašą, prašoma išsakyti nuomonę vykusiose diskusijose, atsakyti į pamokoje užduotus klausimus, kitu laiku sudalyvauti apklausose ir pan.

Minėti nuotolinio mokymo metodai taikomi universitetuose, kolegijose, tačiau mokykla skiriasi nuo universiteto pirmiausia tuo, kad joje ugdomi vaikai, paaugliai, kurių fiziologiniai, psichologiniai mokymosi aspektai skiriasi nuo suaugusiųjų mokymosi poreikių, spartos, vertybių ir galimybių. Pirmiausia, mokymas universitete orientuotas į akademinį dėstymą, profesinių žinių ir gebėjimų ugdymą konkrečioje srityje, o mokymas mokykloje orientuotas į bendrųjų gebėjimų ugdymą.

Mokykloje anglų kalbos pamokose yra įmanomas sinchroninis ir asinchroninis nuotolinis mokymas, parinkus tinkamą mokymui virtualią mokymosi aplinką, kurioje būtų talpinama visa reikalinga mokymosi medžiaga, žinių vertinimo priemonės, atliekamas mokymosi proceso stebėjimas ir nuolatinė kontrolė, naudojamos bendravimo priemonės, tokios kaip elektroninis paštas, forumai, diskusijos. Tačiau mokytojui labai svarbu parinkti tinkamą mokymo medžiagą, ją patraukliai pateikti besimokančiajam, užtikrinti, kad mokinys jaustųsi saugus ir nuolat gautų grįžtamąjį ryšį apie daromą pažangą, tobulintinas sritis.

2.2 Elektroninės mokymosi medžiagos paruošimo iššūkiai

Mokytojui, norint kokybiškai parengti elektroninę mokymosi medžiagą, reikia puikiai išmanyti IKT pagrindinius principus, žinoti ISO standartus, mokymosi objektų kūrimo principus, anglų kalbos mokytojas turi mokėti naudoti tokias programėles, kaip H5P, Scratch, Canvas, Ed Puzzle. Tekstai, paveikslukai, garso ir vaizdo įrašai, animacijos elementai gali tapti puikiais mokymosi objektais, jei parengiami tinkamu formatu.

Anot Targamadžės (2020), elektroninėje knygoje medžiaga kartais išdėstoma hierarchiškai, o pateiktyje pateikiama medžiagos santrauka, pritaikyta ją panaudoti pamokos metu [11]. Atvaizduojamos medžiagos tipai gali būti įvairūs: statiniai ar dinaminiai elementai, garso ar vaizdo įrašai, diagramos. El. mokymosi aplinka leidžia naudoti daug žiniasklaidos elementų: vaizdo įrašus, įvairias diagramas, realaus laiko skaičiuokles, pateiktis, nuotraukas, garsus ir kitą medžiagą. El. mokymosi sistemos valdymas skiriasi priklausomai nuo sistemos lygio. Paprastesnės sistemos reikalauja geresnių kompiuterinio raštingumo įgūdžių, o sudėtingesnių sistemų valdymas dažnai yra paprastesnis.


Rutkauskienė ir kt. (2003) atvirojo nuotolinio mokymosi modelį išanalizavo panaudodama „Daugiasluoksnės ruletės“ principą [12], kuriame lai-

komasi vaizdumo, sąmoningumo ir aktyvumo, prieinamumo, nuoseklumo, teorijos ir praktikos ryšio principų. Mokytojas, kurdamas savo pamokas virtualioje mokymosi aplinkoje, turi laikytis būtent šių principų. Mokinys turi turėti galimybę peržiūrėti medžiagą. Tuo tikslu vaizdo medžiagą (vaizdo įrašus) galima įkelti savo „Youtube“ kanale, pasidalinti nuoroda virtualiojoje mokymosi aplinkoje (VMA). Taip pat labai naudingi yra skenuoti elektroniniai vadovėliai, medžiaga pateikta skaidrėse. Kūrybingas mokytojas gali paskatinti savo mokinius taip pat kurti mokomąją medžiagą, ją dalintis su klasės draugais, čia labai tiktų projekto metodas.

Kūriant mokomąją medžiagą, galima panaudoti tokią mokymosi medžiagos kūrimo programą kaip Exelearning. Programa medžiagą pateikia xml formatu, todėl patogu medžiagą redaguoti, papildyti, keisti.

3 Susistemintos nuotolinio anglų kalbos mokymo metodikos poreikio tyrimas

Dirbant nuotoliniu būdu, pastebėta, kad mokytojai naudoja skirtingas nuotolinio mokymo metodikas, blaškosi tarp skirtingų virtualių mokymosi aplinkų, todėl buvo atliktas tyrimas, kurio tikslas – išsiaiškinti anglų kalbos mokytojų IKT taikymo kompetencijas ir išanalizuoti susistemintos nuotolinio anglų kalbos mokymo(si) metodikos, pagrįstos „Google classroom“ bei „Google meet“ naudojimu, poreikį bei dalinimąsi gerąja patirtimi.



1 pav. Pedagogų pasiskirstymas pagal amžių

Apklausoje dalyvavo 70 Kauno miesto anglų kalbos mokytojų, dirbančių nuotoliniu būdu. 1 pav. Pedagogų pasiskirstymas pagal amžių parodytas tyrimo dalyvių pasiskirstymas pagal amžių. Daugiausia dalyvavo vidutinio mažiaus anglų kalbos mokytojų.


Dauguma mokytojų savo gebėjimą dirbti kompiuteriu įvertina labai gerai (1 lentelė). Tačiau tik mažiau nei trečdalis mokytojų moka dirbti „Google classroom“ virtualiaja mokymosi aplinka ir „Google meet“ vaizdo konferencijų programa.

Paklausus mokytojų, ar jaučia nepasitikėjimą dirbdami kompiuteriu, beveik pusė respondentų teigia, jog vis dar jaučiasi nedrąsiai dirbdami kompiuteriu. Tačiau beveik visi, net 96 % apklaustųjų, norėtų mokytis savo dalyką virtualioje mokymo aplinkoje „Google classroom“ bei naudotis „Google meet“ vaizdo konferencijomis?

1 lentelė. Gebėjimas dirbti su specialiomis priemonėmis kompiuteriu

	Puikiai	L. gerai	Gerai	Silpnai	Nemoku
El. pašto programomis bei interneto naršykle	11	39	14	6	0
„Google classroom“ platforma bei „Google meet“ vaizdo pokalbių programa	2	17	17	24	30
Kompiuteriu apskritai (Windows, Word, Excel)	20	7	32	11	30

2 pav. Kas motyvuotų kurti nuotolinį užsienio kalbos mokymo(si) kursą? parodyta, kad pagrindiniai motyvatoriai kurti nuotolinį užsienio kalbos kursą būtų darbas karantino sąlygomis, noras kelti savo kategoriją bei tinkamas atlygis už papildomą darbą. Tik septintadalis apklaustųjų respondentų nenorėtų kurti savo virtualaus mokymosi kurso.



2 pav. Kas motyvuotų kurti nuotolinį užsienio kalbos mokymo(si) kursą?

Apklausa parodė, kad dauguma mokytojų (37 %) savo pamokose naudoja virtualiąją mokymosi aplinką „Edmodo“, ketvirtadalis naudoja „Moodle“ (14 %) ir „Eduka“ (15 %). Tačiau dauguma mokytojų (84 %) nėra sukūrę

savo virtualaus mokymo kurso ar svetainės. Tik nedidelė dalis mokytojų (3 %) moka kurti internetinius puslapius arba programuoti. Gerai yra tai, kad beveik visi mokytojai (99 %) teigia turintys galimybę bendrauti su IKT specialistais.

Dauguma respondentų (46 %) nenaudoja jokių interaktyvių programų anglų kalbos užduotimis kurti ir nėra girdėję (91 %) apie susistemintą anglų kalbos mokymo metodiką. Tik nedidelė dalis mokytojų naudoja tokias priemones kaip „Quizlet“ (9 %) bei „Edpuzzle“ (15 %) interaktyvioms anglų kalbos užduotims kurti. Tačiau beveik visi mokytojai norėtų dirbti pagal susistemintą nuotolinio anglų kalbos mokymo metodiką ir beveik visi (93 %) sutiktų dalintis gerąja tos metodikos taikymo patirtimi.

4 Susistemintos nuotolinio anglų kalbos mokymo metodikos sukūrimas ir taikymas

Anglų kalbos mokytojams siūloma naudoti nuotolinio mokymo organizavimui tinkamą platformą „Google for Education“, joje teikiamą „Google classroom“ sistemą, skirtą asinchroniniam mokymui, medžiagos talpinimui, mokinių vertinimui ir grįžtamojo ryšio užtikrinimui, ir „Google meet“ priemonę, skirtą vaizdo konferencijų transliavimui. Susisteminta nuotolinio anglų kalbos mokymo metodika yra pagrįsta „Google for Education“ platformos naudojimu ir tinka sinchroninėms bei asinchroninėms pamokoms.

Mokytojams, sutikusiems savo pamokose taikyti siūlomą nuotolinio anglų kalbos mokymo metodiką, gali būti teikiamos nuotolinės konsultacijos, išmokoma įsidiesti „Google classroom“ sistemą ir „Google meet“ programėlę, parodomi tų programų dažniausiai naudojami įrankiai pamokos medžiagai kurti, pateikti, vertinti, išmokyti. Taip pat gali būti išmokoma susikurti vaizdo konferencijų nuorodas „Google calendar“ virtualiajame kalendoriuje. Būtina kuo skubiau gerinti situaciją ir atsižvelgti į mokinių ir mokytojų psichologinę savijautą, palengvinti jų kasdieninį darbą parenkant vieną VMA.

2020 m. liepos – rugpjūčio mėnesiais Lietuvos mokytojams Ingrida Lisinskienė vedė konferenciją tema „Nuotolinio mokymo galimybės naudojant „Google for Education“ priemones“. Konferencijoje dalyvavo 220 pedagogų iš įvairių Lietuvos mokyklų. Mokytojams buvo pristatyta Ingridos Lisinskienės sukurta susisteminta nuotolinio anglų kalbos mokymo metodika. Metodika remiasi autorės pamokose išbandytais nuotolinio darbo metodais bei gerais mokinių ir kolegų atsiliepimais.

Mokinių sinchroniniam mokymui siūloma taikyti šiuos metodus:

1. Sinchroninė 30 minučių pamoka skirta gramatikos temų mokymui.
2. Sinchroniniai dialogai ir monologai.
3. Projektų metodo panaudojimas darbui porose ar atskirai.
4. Aiškinamosios sinchroninės gramatikos ar fonetikos pratybos.
5. Tekstų analizavimas individualiai apverstos klasės metodu, aptarimą darant sinchroniniu būdu.
6. Mokinių ekspertinis metodas įvairių temų analizei.
7. Probleminis rašymas-esė, laiškai, pranešimai grupėse ir individualiai.
8. Savaiminio mokymosi metodika nuotoliniame mokymesi.
9. Imersinio metodo taikymas, panardinant mokinius į anglų kalbą, kuriant istorijas, legendas, pasakas, sakmes bei jas pristatant individualiai pamokoje ar porose.

Mokinių asinchroniniam mokymui siūloma taikyti šiuos metodus:

1. Individualių užduočių atlikimas.
2. Klausymo užduočių atlikimas.
3. Rašto darbai – istorijų, legendų, pasakų ar dienoraščių kūrimas ir animavimas.
4. Pasiruošimas sinchroniniam atsiskaitymui – teksto išmokimas pasakoti ar teksto klausimų paruošimas.
5. Mokytojo vaizdo įrašų peržiūrėjimas, užduočių atlikimas.
6. Mokinio užduočių atlikimas parengiant animacijas, skaidres, animuotas istorijas, balso įrašai monologų ir dialogų pristatymui.
7. Probleminio klausimo sprendimas filmuojant problemos sprendimo eigą.

Meninių filmų peržiūra pagal iš anksto gautas mokytojos užduotis.

Siūloma taikyti susistemintą nuotolinio anglų kalbos mokymo metodiką, kad mokytojams būtų paprasčiau ir aiškiau dirbti. Grįžtamajam ryšiu su mokytojais užtikrinti numatoma sukurti internetinę svetainę, kurioje mokytojai galės rasti susistemintos anglų kalbos mokymo metodikos užduočių pavyzdžių, mokinių darbų pavyzdžių, interaktyvių užduotėlių pagrindinio ir vidurinio ugdymo pakopos mokiniams.

5 Išvados

Anglų kalbos mokymo tikslas – įgyti ne tik komunikavimo, bet ir kultūrinę kompetencijas. Didelis dėmesys skiriamas ilgalaikiam išmokimui per nuolatinį kartojimą. Pamokų metu bendraujama angliškai, taikomi tradiciniai metodai (pasakojimas, pokalbis, dialogai, gramatikos užduočių atlikimas ir kt.) bei aktyvaus mokymosi metodai (projektai, darbas grupėse, vaidmenų žaidimai, darbas su el. šaltiniais ir kt.). Apžvelgus sinchroninį, asinchroninį, multi-dimensinį bei pseudo-sinchroninį mokymo būdus, galima teigti, kad mokykloje yra įmanomas sinchroninis bei asinchroninis nuotolinis mokymas, parinkus mokymui tinkamą virtualiąją mokymosi aplinką, kurioje būtų talpinama visa reikalinga mokymosi medžiaga, žinių vertinimo priemonės, atliekamas mokymosi proceso stebėjimas ir kontrolė, naudojamos bendravimo priemonės, tokios kaip forumai, diskusijos, grupinis bei individualus darbas.

Susisteminta nuotolinio anglų kalbos mokymo metodika galėtų būti taikoma sinchroninėms ir asinchroninėms anglų kalbos pamokoms organizuoti. Vis dėlto, mokytojams vis dar trūksta IKT žinių bei gebėjimų įgyvendinti šią metodiką, todėl reikalingi reguliarūs mokytojų mokymai bei veiklos grįžtamojo ryšio užtikrinimas. Tuo tikslu numatoma sukurti internetinę svetainę, kurioje mokytojai galės rasti susistemintos nuotolinio anglų kalbos mokymo metodikos užduočių, mokinių darbų pavyzdžių, interaktyvių užduotėlių pagrindinio ir vidurinio ugdymo pakopos mokiniams. Pritaikius metodiką ir sulaukus grįžtamojo ryšio iš mokytojų, rekomenduojama atlikti papildomą susistemintos nuotolinio anglų kalbos mokymo metodikos taikymo efektyvumo tyrimą.

Literatūra

- [1] Kampylis, P., Punie, Y., Devine, J. (2015). Kaip padėti veiksmingai mokytiis skaitmeniniame amžiuje: Europos metmenys skaitmeninę kompetenciją turinčioms švietimo organizacijoms, ISBN 978-92-79-54005-9, 2015, P. 122 – 134.
- [2] Rutkauskienė, D., Gudonienė, D., Afonin, A., Ostreika, A., Cibulskis, G. (2012). Saitynas 2.0 ir atvirieji švietimo ištekliai. Kaunas. ISBN 978-609-02-0816- 8, P. 56 – 61.
- [3] Simonson, M., Zvacek, S. (2019). Teaching and learning at a distance. The seventh edition. <https://books.google.lt/books?hl=lt&lr=&id=qh-3DwAAQBAJ&oi=fnd&pg=PR1&dq=distance+education+key>.
- [4] Clardy, A. (2009). Distant, online education. Effects, principles and practices. <https://eric.ed.gov/?id=ED506182>.

- [5] Varlamis, I. (2016). The present and future of standarts for e- learning technologies. <https://www.learntechlib.org/p/44814/?fbclid=IwAR0x-tOnFeL0y8ZpEEz47UzDg-q3EcNCQ9ojcJYXkcHUH>.
- [6] Grakauskas, Z. (2013). Lietuvos švietimo raidos vizija. Lietuva – sumani šalis.
- [7] Erlickaitė, Š. (2014). Informacinių technologijų taikymas mokymo procese- situacijos analizė ugdymo kokybės atžvilgiu. <https://gs.elaba.lt/object/elaba:2127267/>.
- [8] Cowley, S. (2006). Mokymo klinika. ISBN 9986-16-526-1, P. 87 – 94.
- [9] Vilkonis, R., Targamadžė, A., Borisenko, I., Mušankovienė, V., Petrauskienė, R. Butrimė, E., Kančialskytė, A. ir Oželienė, D. (2013) E-mokymosi metodai. internete: http://www.esparama.lt/es_parama_pletra/failai/ESFproduktai/2014_E_mokymo_metodai.pdf.
- [10] Ala-Mutka, K., Redecker, C., Punie, Y., Ferrari, A., Cachia, R., Centeno, C. (2010). The Future of Learning: European Teachers' Visions. JRC59775, P. 198.
- [11] Targamadžė, A. (2020).Virtualusis mokymasis. Teorija ir praktika. ISBN 978 - 609 – 454 – 494 – 1, P. 77-94.
- [12] Rutkauskienė, D., Targamadžė, A., Mušankovienė, V. R., Simonaitienė, B., Abarius, P., Mačiulis, M., Kulvietienė, R., Cibulskis, G., Kubiliūnas, R., & Žvinienė, V. (2003). Nuotolinis mokymasis: mokomoji knyga (p. 256). Technologija, P. 56.

IT priemonių panaudojimo galimybės profesiniam kvalifikacijos kėlimui nuotoliniu būdu

Algirdas Litvinas

Kauno technologijos universitetas, Informatikos fakultetas,
Studentų g. 50, LT - 51368 Kaunas
algirdas.litvinas@ktu.edu

Santrauka. Technologinė pažanga lemia vis naujų IT priemonių nuotoliniam mokymuisi atsiradimą, didinant jų pritaikomumą ir panaudojimo galimybes. Vis dėlto, pastebima, kad dažniausiai informacinės technologijos mokymuisi suprantamos tik kaip įvairios nuotolinio mokymosi platformos. Šiame straipsnyje apibūdinamos įvairios IT priemonės, nuotoliniam profesiniam kvalifikacijos kėlimui ir pateikiamos jų panaudojimo galimybės. Taip pat apžvelgiami pagrindiniai iššūkiai, su kuriais susiduriama diegiant naujausius IT sprendimus, bei kokios jų suteikiamos galimybės.

Raktiniai žodžiai: informacinės technologijos, kvalifikacija, profesinis kvalifikacijos kėlimas, nuotolinis mokymasis, nuotolinis kvalifikacijos kėlimas.

1 Įvadas

Nuotolinis darbas ir mokymasis tapo neatsiejama gyvenimo dalimi. Spartus technologijų vystymasis sudarė galimybes nuotoliniam mokymuisi ir profesiniam kvalifikacijos kėlimui. Todėl didelė dalis mokslinių tyrimų šiuo metu yra nukreipti į nuotolinio mokymosi privalumus ir trūkumus. Dažniausiai pateikiami iššūkiai, kalbant apie nuotolinį mokymąsi ir profesinį kvalifikacijos kėlimą yra atskirties jausmas, tiesioginio kontakto trūkumas ir nepasitikėjimas savimi naudojantis su studijomis susijusiomis technologijomis, dėl nepakankamo skaitmeninio raštingumo [1]. Taigi, siekiant išnaudoti visas nuotolinio mokymosi ir profesinio tobulėjimo galimybes, svarbu ieškoti patogiausių, prieinamiausių ir geriausiai pritaikytų IT priemonių bei jų panaudojimo galimybių.

Tyrimo tikslas – apibūdinti naujausias IT priemones ir jų panaudojimo galimybes bei perspektyvas profesiniam kvalifikacijos kėlimui nuotoliniu būdu.

Šiam tikslui pasiekti analizuojami naujausi moksliniai tyrimai bei mokslinė literatūra apie technologijas ir jų pritaikomumą, galimybes nuotoliniam profesiniam kvalifikacijos kėlimui.

2 IT priemonės nuotoliniam profesiniam kvalifikacijos kėlimui

Dažniausiai pasitaikanti mokslinių tyrimų kryptis yra bendras nuotolinio mokymosi vertinimas bei informacinių technologijų ir komunikacijos platformų pritaikomumo bei privalumų ar trūkumų identifikavimas. Taip yra tikriausiai todėl, kad tokios technologijos yra ypatingai paprastos naudoti, reikalauja nedidelių investicijų, mažo pasiruošimo ir kt., tad yra plačiausiai paplitusios [2]. Vis dėlto, tai yra tik nedidelė dalis nuotolinio mokymosi technologijų srityje. IT priemonės yra kur kas platesnė sąvoka ir apima įvairias daug sudėtingesnes technologijas, pavyzdžiui, telebuvimo robotai ar virtuali realybė.

Telebuvimo robotai (angl. telepresence robots), kartais vadinami mobiliuoju nuotoliniu būvimu yra sistema, įgalinanti abipuses garso ir vaizdo konferencijas ir navigaciją tolimoje aplinkoje. Šie robotai suteikia galimybę realiuoju metu dalyvauti mokymuose, įgyti kvalifikaciją, tobulinti įgūdžius, ši technologija turėtų ateityje išspręsti paskaitų ir mokymų lankomumo problemas, kadangi tai sprendimas kaip dalyvauti paskaitose nuotoliniu būdu. Ši technologija sukuria „dalyvio būvimo šalia“ jausmą. Patobulinus robotus, pridėjus papildomų kamerų ir jutiklių, bei naujų savimonės bei saviraiškos funkcijų, telebuvimo robotai netrukus gali būti pasirengę užmegzti simbiotinius santykius su asmenimis, kurie fiziškai negali dalyvauti mokymuose [3][4].

Virtuali realybė – virtualios ekskursijos. Virtuali pažintinė kelionė (angl. virtual field trips - VFT) gali įkvėpti besimokančiuosius ir atverti daug mokymosi galimybių. VFT suteikia galimybę aplankyti vietas, kuriose įprastai apsilankyti būtų labai sudėtinga arba neįmanoma, pvz. planetose kosminėje erdvėje ar įvairių šalių muziejuose. Taip tyrinėjamas turinys išplečia besimokančiųjų akiratį, keičia supratimą apie veikimo principą ir pagerina įsigilinimą bei mokymąsi [5]. Kalbant apie profesinį kvalifikacijos kėlimą, naudojantis tokiomis technologijomis būtų galima parodyti kokių nors įrengimų veikimo principą, įvairias panaudojimo ir pritaikymo galimybes ir kt.

Taigi, telebuvimo technologijos ir virtuali realybė yra tikrai perspektyvios ir daug naudos besimokantiesiems galinčios suteikti technologijos, tačiau ir

šios technologijos yra tik dalis viso IT priemonių spektro. Daugiau informacinių technologijų panaudojimo nuotoliniam kvalifikacijos kėlimui pavyzdžių pateikiama 1 lentelėje.

1 lentelė. Informacinių technologijų panaudojimo nuotoliniam kvalifikacijos kėlimui pavyzdžiai [6]

Įrankiai	Apibūdinimas	Technologijų pavyzdžiai	Nauda
Virtuali aplinka	Virtuali aplinka yra 3D erdvė, kurioje naudojami avatarai, kad besimokantieji galėtų bendrauti su kitais dalyviais. Vykdomos skirtingos edukacinės veiklos, o besimokantieji turi daug laisvės jomis naudotis.	<i>In Touch With Molecules</i> <i>Second Life</i> <i>World of Warcraft</i> <i>Google Expedition</i>	Suteikia galimybę išsiugdyti tokias kompetencijas kaip empatija, savimonė, emocinė savireguliacija, socialinis supratimas, bendradarbiavimas, problemų sprendimas, strateginis mąstymas ir bendravimas, sustiprinami pažinimo įgūdžiai.
Žaidimai	Mokomieji žaidimai yra technologinės priemonės, leidžiančios besimokantiems kurti strategijas, patikrinti hipotezes ir spręsti problemas. Jie apima tikslų nustatymą, prizų laimėjimą ir pažangą per skirtingus sudėtingumo lygius.	<i>Minecraft Education Edition</i> <i>SimSE</i> <i>Quantum Moves</i>	Suteikia galimybę susidurti konkrečiomis situacijomis. Galima analizuoti skirtingus atsakymus ir bandyti procesą iš naujo, labiau įsigilinant į mokymąsi. Žaidimai padeda ugdyti tokias kompetencijas kaip empatija, savimonė, emocinis reguliavimas, socialinis supratimas, bendradarbiavimas, problemų sprendimas, kritinis mąstymas ir sprendimų priėmimas. Jie skatina gilų supratimą ir idealiai tinka lavinti aukštesnio lygio mąstymo įgūdžius. Žaidimai taip pat gerina besimokančiųjų įsitraukimą ir motyvaciją.
Internetinės mokymosi platformos	Internetinės mokymosi platformos yra švietimo priemonės, pagrįstos internetu ar kitų internetinių tinklų naudojimu.	<i>MOOC</i> <i>SPOC's</i> <i>Intellipath</i>	Šie įrankiai suteikia galimybę savarankiškai mokytis ir padėti ugdyti skaitmeninio raštingumo kompetenciją. Šios priemonės skatina įsitraukimą. Besimokantieji gali efektyviau įgyti žinių, sukonzentruoti dėmesį ir padidinti mokymosi produktyvumą.

Įrankiai	Apibūdinimas	Technologijų pavyzdžiai	Nauda
Robotai	Robotai yra mašinos, kurios yra užprogramuotos spręsti sudėtingas užduotis ir gali padėti mokyti kompiuterinio programavimo, gamtos mokslų, fizikos ir matematikos.	<i>Robot-Assisted Language Learning in Education (RALL-E)</i> <i>LEGO Mindstorms NXT</i> <i>Thymio Robot</i>	Didėja motyvacija. Galima ugdyti tokias kompetencijas kaip problemų sprendimas, bendravimas, kūrybiškumas, kultūrinis sąmoningumas, prisipažinimas ir kritinis mąstymas matematinės ir inžinerijos srityse.
Virtualios laboratorijos/ simuliacijos	Šios priemonės imituoja tikrus procesus, kurių metu besimokantieji gali analizuoti kintantį elgesį ir sąveiką bei kontroliuoti įvairius veiksmus.	<i>Mr. Vetro RobUAlab</i> <i>Virtual Laboratory, Tecnológico de Monterrey OLabs</i>	Simuliacijos yra naudingos lavinant problemų sprendimo įgūdžius. Virtualios laboratorijos mažina netikrumą, skatina įgyti konceptualių žinių ir padeda ugdyti samprotavimo gebėjimus, kritinį mąstymą ir novatoriškumo bei kūrybines kompetencijas.
Mobilūs įrenginiai	Švietimo kontekste mobilieji įrenginiai naudojami atliekant užduotis ir bendradarbiaujant ar vykdančią veiklą, atliekant darbą.	<i>Mobilūs telefonai</i> <i>Planšetiniai kompiuteriai</i> <i>Nešiojamieji kompiuteriai</i>	Mobilieji prietaisai yra novatoriškos mokymosi veiklos skatintojai. Jie palaiško žinių įgijimo procesą, taip pat bendravimo, problemų sprendimo, kūrybiškumo ir įvairių aukšto lygio ugdymą.
Socialiniai tinklai	Socialiniai tinklai suteikia galimybę profesoriams dalytis ir gauti informaciją su studentais ar kitais akademikais ir iš jų. Be to, socialiniai tinklai gali būti dalijimosi ir vertingų duomenų gavimo šaltiniai.	<i>Facebook</i> <i>Twitter</i> <i>YouTube/YouTube EDU</i>	Socialiniai tinklai skatina geresnę lektorių ir besimokančiųjų sąveiką ir bendravimą. Jie taip pat gerina mokinių rezultatus, motyvaciją mokytis ir įsitraukimą.
Internetinės platformos	Tai internetinės programos, prie kurių galima prisijungti per internetą ir kurios padeda lektoriams transliuoti paskaitas, vykdyti mokymo veiklą.	<i>Ed Tech Rapid Cycle Evaluation</i> <i>Coach</i> <i>TED-Ed</i> <i>Curatr</i> <i>Moodle</i>	Internetinės platformos suteikia galimybę lektoriams sukurti gilesnį mokymosi procesą ir surengti kursų patraukliu formatu.
Daiktų internetas (angl. <i>Internet of things</i>)	„Daiktai“ yra bet kokie prietaisai, serveriai, įrenginiai ir kt., kurie yra prijungti prie interneto ir yra autonominiai įrankiai.	<i>Išmanieji klasės aplinkos įrenginiai</i> <i>Lankomumo sistemos</i> <i>Realaus laiko atsiliepimai apie paskaitos kokybę</i>	DI palengvina besimokančiųjų ir lektorių sąveiką ir gali pagreikinti sąvokų supratimą. Tai taip pat gali pagerinti švietimo kokybę ir studentų pasitenkinimą, nes dėstytojai gali pasiūlyti jiems patrauklesnę, pritaikytą edukacinę veiklą, pavyzdžiui, įvertindami jų reakcijas.

Pagal 1 lentelėje pateiktus duomenis matyti, kad egzistuoja daugybė įvairių informacinių technologijų priemonių, įrankių, sprendimų, kurie gali suteikti daug naudos, pagerinti mokymosi patirtį, sustiprinti žinias ir t.t. Tačiau jų populiarumas ir naudojimo dažnis vis dar nėra didelis. Kodėl? Pripažįstama, kad IT priemonės yra ateitis ir jų perspektyva didžiulė, tačiau vis dar kyla iššūkių įdiegiant, pritaikant ir naudojantis technologiniais mokymosi sprendimais.

3 IT priemonių keliami iššūkiai ir galimybės

Naudojimas informacinėmis technologijomis mokantis dažnai kelia įvairių iššūkių, dėl kurių nuotolinis mokymasis ir kvalifikacijos kėlimas ne visuomet yra vertinamas palankiai ir ne visuomet norima jomis kuo greičiau pradėti naudotis. Dažniausiai kylantys iššūkiai yra [7]:

- Perėjimas prie mokymosi nuotoliniu būdu yra gali būti sudėtingas žmonėms, kurių skaitmeninis raštingumas yra žemas.
- Taip pat pastebima, kad pradėjus mokytis nuotoliniu būdu, iš pradžių mokymosi pasiekimai būna žemesni nei įprastai, kol įvyksta adaptacija prie technologijų.
- Svarbu, kad informacinės technologijos būtų pritaikomos ir naudojamos taip, kad didintų besimokančiųjų įsitraukimą, o ne blaškytų jų dėmesį ir keltų susirūpinimą dėl jų naudojimo teisingumo.
- Taip pat, kalbant apie informacines technologijas svarbu nepamiršti kylančių iššūkių dėl prieinamumo įvairiuose skirtinguose įrenginiuose, kas kartais sukelia barjerus ir didelius nepatogumus tiek lektoriams, tiek ir besimokantiejiems.
- Trumpuoju laikotarpiu, infrastruktūra ir priemonės, reikalingos nuotoliniam profesiniam kvalifikacijos kėlimui gali pareikalauti didelių piniginių investicijų, kas dažnai lemia atidėliojimą jomis naudotis.
- IT sprendimai dažnai reikalauja papildomo pasiruošimo ir mokymų prieš pradėdant jais naudotis.

Nepaisant šių iššūkių, technologijos suteikia galimybę paruošti darbuotojus naujiems verslo procesams organizacijose, kur įgūdžių įgyjimo prieinamumas tapo raktu siekiant inovacijų ir tvaraus sėkmingo verslo subjektų egzistavimo užtikrinimo. Virtuali realybė leidžia kurti situacijas, kurių neįmanoma ar sunku imituoti realiame pasaulyje, ir suteikia galimybę darbuo-

tojams mokytis temų ir lavinti savo įgūdžius, kurių įprastai įgyti galimybių nebūtų. Technologijų taikymas ir svarba švietimo tikslais didėja verslo organizacijose, kadangi jie gali kelti darbuotojų kvalifikaciją aplinkoje, kuri yra artima realioms sąlygoms, atsirandančioms jų būsimoje darbo aplinkoje. Kai kurioms pramonės šakoms virtualios realybės technologijos yra ir bus reikšminga mokymosi dalimi, pvz. pilotų mokymai skraidyti, chirurginių intervencijų imitacija medicinoje, robotų valdymas nuotoliniu būdu gaminant ir montuojant. Taigi informacinės technologijos, skirtos nuotoliniam kvalifikacijos kėlimui, ypatingai pasiteisintų tokiuose ekonomikos sektoriuose kaip gamyba, technika, sveikata ar oro transportas. Informacinės technologijos, kartu su internete esančia informacija yra neišsemiamas žinių šaltinis, skatinantis darbuotojų kūrybiškumą, motyvuojantis nuolat gilinti žinias, tobulinti kvalifikaciją ir mokytis visą gyvenimą. O tai yra labai svarbu organizacijų inovatyvumo lygiui palaikyti, plėtrai užtikrinti ir būti konkurencingais rinkoje [8].

4 Išvados

Informacinės technologijos yra galinga jėga keičianti švietimą ir mokymąsi visame pasaulyje. Vis dėlto, didelė dalis naujausių technologijų dar stokoja pritaikomumo. Kartais dėl technologijų neišbaigtumo, kartais dėl vartotojų vidinių barjerų, o kartais ir dėl abiejų aspektų. Vis dėlto, švietimo sistema ir jos dalyviai turi prisitaikyti prie sparčiai besikeičiančios aplinkos, o technologijų vystytojai savo ruožtu – pritaikyti technologijas taip, kad jas būtų patogu naudoti tiek studentams, tiek ir vyresniems žmonėms, siekiantiems atnaujinti, gilinti ar įgyti profesines žinias ir kelti kvalifikaciją. Šiuo metu jau esama įvairių informacinių technologinių įrankių, kuriuos galima panaudoti nuotoliniam kvalifikacijos kėlimui, pavyzdžiui: virtuali aplinka, žaidimai, internetinės mokymosi platformos, robotai, virtualios laboratorijos, soc. tinklai, daiktų internetas ir kt. Išnaudojus beribes informacinių technologijų galimybes keliant profesinę kvalifikaciją nuotoliniu būdu, galima tikėtis padidinti darbuotojų darbo efektyvumą, sumažinti įmonės sąnaudas ar padidinti konkurencinį pranašumą.

Literatūra

- [1] Owens, J., Hardcastle, L., & Richardson, B. (2009). Learning from a distance: The experience of remote students. *Journal of Distance Education*, 23(3), 53-74.
- [2] Wong, J., Baars, M., Davis, D., Van Der Zee, T., Houben, G. J., & Paas, F. (2019). Supporting self-regulated learning in online learning environments and MOOCs: A systematic review. *International Journal of Human-Computer Interaction*, 35(4-5), 356-373.
- [3] Fitter, N. T., Raghunath, N., Cha, E., Sanchez, C. A., Takayama, L., & Matarić, M. J. (2020). Are we there yet? Comparing remote learning technologies in the university classroom. *IEEE Robotics and Automation Letters*, 5(2), 2706-2713.
- [4] Yepez, J., Guevara, L., & Guerrero, G. (2020). AulaVR: Virtual Reality, a telepresence technique applied to distance education. 2020 15th Iberian Conference on Information Systems and Technologies (CISTI)
- [5] Morgan, H. (2020). Best Practices for Implementing Remote Learning during a Pandemic. *The Clearing House: A Journal of Educational Strategies, Issues and Ideas*, 93(3), 134-140.
- [6] Hernandez-de-Menendez, M., & Morales-Menendez, R. (2019). Technological innovations and practices in engineering education: a review. *International Journal on Interactive Design and Manufacturing (IJDeM)*.
- [7] Ali, W. (2020). Online and remote learning in higher education institutes: A necessity in light of COVID-19 pandemic. *Higher Education Studies*, 10(3), 16-25.
- [8] Dávideková, M., Mjartan, M., & Greguš, M. (2017). Utilization of virtual reality in education of employees in slovakia. *Procedia computer science*, 113, 253-260.

Privačios informacijos išsaugojimas taikant dirbtinio intelekto technologijas

Paulius Milmantas

Vilniaus universitetas, Matematikos ir informatikos fakultetas,
Naugarduko g. 24, LT-03225 Vilnius
pauliusmilmantas@gmail.com

Santrauka. Straipsnyje yra atliekamas apmokymui skirtų duomenų saugumo tyrimas su skirtingais mašininio mokymosi modeliais. Modelių lyginimui apibrėžta metrika DMDK, kuri leidžia palyginti skirtingus modelius pagal jų pradinį mokymosi duomenų saugumo išsaugojimą. Maža DMDK reikšmė reiškia, kad tiriamas modelis yra linkęs atskleisti pradinį mokymosi duomenį ir nėra saugus. Atliktame tyrime pastebėta, kad „PyTorch neuroniniai tinklai“ yra saugesni, nei homomorfiniu šifravimu grįstas „gradientinio nusileidimo modelis“. Su visais analizuotais modeliais, išskyrus „PyTorch neuroninį tinklą“, didėjant modelio tikslumui, didėja vidutinė DMDK reikšmė – modelis tampa saugesnis, o su „PyTorch neuroniniu tinklu“, mažėja - modelis tampa mažiau saugus.

Raktiniai žodžiai: Mašininis mokymasis, duomenų saugumas, homomorfinis šifravimas.

1 Įvadas

Mašininis mokymas yra dirbtinio intelekto sritis, kuri pasitelkia statistinius algoritmus, kad apibrėžtų duomenų generavimo mechanizmą, ar egzistuojančius sąryšius, priklausomybes. Modelis dažnai turi didelį kiekį nežinomų parametrų, kuriuos reikia įvertinti iš duomenų, todėl modelio apmokymui dažniausiai reikia turėti daug duomenų. Kai kurie uždaviniai reikalauja duomenų, kurie nėra laisvai prieinami ir yra privatūs. Mašininio mokymo tyrimų srityje yra kilusi problema dėl jų saugojimo [1].

Šią problemą išspręsti siekia įvairūs tyrimai ir naujai pasiūlyti metodai privatumą saugančio dirbtinio intelekto srityje. Šią problemą galima išskaidyti į kelias atskiras sritis:

- Analizuojamų duomenų privatumas [2]. Algoritmas apmoko modelį atpažinti duomenis. Turint sukurtą modelį, neturi būti galima atgaminti duomenų, pagal kuriuos jis buvo mokomas, bei negali būti identifikuo-

ti asmenys. Taip nukentėtų žmonių privatumas ir būtų pažeistas Europos duomenų apsaugos reglamentas. Šio pažeidimo pavyzdys gali būti ir paprastas teksto atkūrimo modelis. Duodama sakinio pradžia, modelis nuspėja jo pabaigą. Jeigu suvedus tam tikras detales modelis užbaigia sakinį naudodamas asmeninius duomenis, kurie atskleidžia žmonių tapatybę, šis modelis nėra saugus [3].

- Duomenų įvesties privatumas. Trečios šalys neturi matyti įvedamų duomenų. Tai gali būti tinklo saugumo spragos, duomenų surinkimo aplikacijų spragos ir t.t...
- Modelio išvesties privatumas. Modelio išvesties neturi matyti asmenys, kuriems šie duomenys nepriklauso. Šis punktas yra sąlyginis, priklauso nuo modelio svarbos. Jeigu tai yra svarbūs asmeniniai duomenys, negalima rizikuoti. Tačiau jeigu tai yra viešai prieinami duomenys, šis punktas negalioja.
- Modelio apsauga. Sukurtas modelis negali būti niekieno pasisavintas. Šis punktas yra skirtas apsaugoti programos kūrėją.

Darbo tikslas – ištirti ir palyginti privatumą saugančius dirbtinio intelekto algoritmus pagal jų saugumą, našumą ir panaudojamumą, bei pateikti rekomendacijas.

2 Tyrimo metodika

Siekiant palyginti, kaip modeliai gerai saugo privačius duomenis, apibrėžiame metriką DMDK (didžiausias modelio duomenų nuokrypis). Kuo metrika yra mažesnė, tuo tiksliau galima nuspėti, kokie duomenys buvo naudojami modelio mokymui. Ši metrika leidžia lyginti skirtingus modelius su skirtingais duomenimis.

DMDK metrika yra išvesta 1 lygtyje. Prieš DMDK skaičiavimą reikia paimiti visus modelio mokymui skirtus duomenis ir kiekvienai duomenų eilutei apskaičiuoti modelio išvestį. Skaičiavimus reikia atlikti tik su tomis eilutėmis, su kuriomis modelis išvedė teisingą atsakymą. Turint tik tas eilutes, su kuriomis modelis išvedė teisingą atsakymą, galima į nelygybę įstatyti kintamuosius. Lygtyje yra naudojami tokie kintamieji: m – duomenų eilučių skaičius, h – parametrų skaičius (stulpeliai), ϵ – ieškomas didžiausias galimas kintamasis, su kuriuo modelis nepakeičia išvesties rezultatų, $D_{eilut.:n, stulp.:k}$ – duomenys n eilutėje ir k stulpelyje.

$$DMDK = \sum_{n=0}^m \left(\sum_{k=0}^h \left(\max \left((|\epsilon| + D_{eilut.:n, stulp.:k}) : \epsilon \in R \right) \right) / h \right) / m$$

1 lygtis. DMDK reikšmės skaičiavimas.

3 Tyrimo metodikos verifikavimas

Siekiant pademonstruoti, kad algoritmas teisingai įvertina skirtingus modelius ir galima juos palyginti tarpusavyje, paimkime kelis skirtingus modelių pavyzdžius

Tarkime, kad pirmas modelis turi viena parametą – KMI. Pagal šį parametą, modelis prognozuoja, ar žmogus serga cukriniu diabetu ar ne. Modelio tikslumas yra 54 %, jis visą laiką prognozuoja, kad žmogus serga cukriniu diabetu. Skaičiuojant DMDK, reikia pasirinkti tik tuos duomenis, su kuriais buvo išvesta teisinga prognozė. Modelis visą laiką prognozuoja, kad žmogus serga cukriniu diabetu, todėl, nėra tokios reikšmės, kurią pridėjus prie duomenų, pasikeis modelio prognozė. Todėl DMDK reikšmė yra ∞ ir tai reiškia, kad modelis negali būti saugesnis. Kai modelio prognozė visą laiką yra tapati, neįmano atgaminti pradinių duomenų, su kuriais modelis buvo mokomas.

Antras pavyzdinis modelis prognozuoja ar žmogus serga cukriniu diabetu, pagal 2 parametrus: KMI ir gimdymų skaičiumi. Modelio tikslumas yra 72 %, modelio DMDK reikšmė yra 0,00134. Sprendžiant pagal DMDK, modelis yra nesaugus ir yra labai priklausomas nuo pradinių duomenų, su kuriais modelis buvo mokomas. Modelio nesaugumui įrodyti, paimkime kelias savo sugalvotas duomenų eilutes ir pabandykime atgaminti pradinius duomenis. Tarkime, kad mūsų sugalvotos duomenų eilutės yra 1 lentelėje.

1 lentelė. Sugalvotos reikšmės modelio tikrinimui.

KMI	Gimdymų skaičius
25	3
25	2

Kiekvienai sugalvotai duomenų eilutei, analizuojame kiekvieną stulpelį. Prie stulpelio reikšmės pridedame ϵ ir didiname ϵ reikšmę tol, kol pasikeičia

modelio rezultatas. Analizuojame kiekvieną stulpelį ir pasirenkame stulpelį su mažiausia ϵ reikšme. Pakeičiame analizuojamos duomenų eilutės stulpelio reikšmę, su kuria gauname mažiausią ϵ reikšmę. Išanalizuokime pirmą duomenų eilutę 1 lentelėje. Po pirmos iteracijos, gauname pakeistą duomenų eilutę: KMI – 26, gimdymų skaičius – 3. Atliekame iteracijas tol, kol gaunamų naujų reikšmių skirtumas tampa labai mažas. Atlikus visų duomenų analizę, gauname duomenis, kurie buvo gauti iš sugalvotų duomenų eilučių. Jeigu modelio DMDK yra mažas, šie duomenys turi būti artimi pradiniais duomenims, kurie 12 buvo naudojami modelio mokymui. Atlikus analizę buvo gauti duomenys 2 lentelėje. Duomenys yra labai panašūs pradiniais modelio duomenims. Tai reiškia, kad DMDK matavimo algoritmas pasiteisino.

2 lentelė. Tikri modelio duomenys.

KMI	Gimdymų skaičius
26	1
22	2

Siekiant įsitikinti, kad algoritmas yra teisingas ir neduoda rezultatų, kurie tiesiogiai priklauso nuo duomenų, atlikti du eksperimentai.

1. Skaitant duomenis, jų visų reikšmės yra padalintos iš 10. Sukūrus modelį, apskaičiuota nauja DMDK reikšmė. Ji yra labai artima DMDK reikšmei, kai duomenys nebuvo dalijami iš 10. Tai reiškia, kad algoritmas nėra tiesiogiai priklausomas nuo duomenų, kuriais modelis yra mokomas.
2. Skaitant duomenis, prie jų reikšmių yra pridamas atsitiktinai sugeneruotas triukšmas – skaičius nuo -1 iki 1. Naujo modelio DMDK reikšmė yra panaši į modelio, prieš duomenų keitimą. Tendencijos išlieka panašios.

4 Tyrimo rezultatai

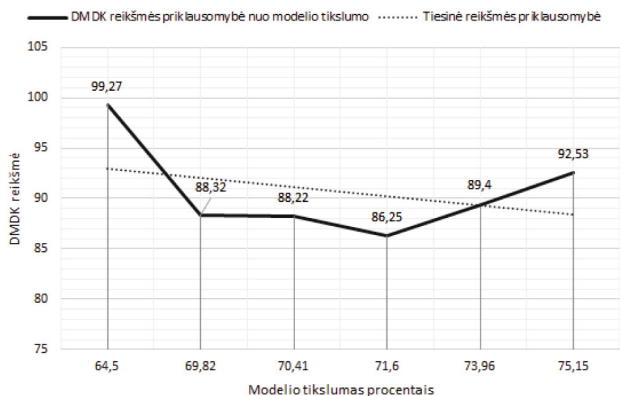
Tyrimo tikslams, buvo sukurti modeliai ir, skaičiuojant DMDK metriką, jie lyginami tarpusavyje. Tyrimui paimti diabetu sergančių žmonių duomenys iš „Sklear“ bibliotekos viešai prieinami duomenys. Gauti rezultatai pateikti 3 lentelėje.

3 lentelė. Tyrimo rezultatai.

Modelis	Nuostolių f-jos reikšmė (MSE)	Tikslumas	DMDK
„PyTorch neuroninis tinklas“	103.9837813	81.1 %	87.419
„Gradientinio nusileidimo algoritmas“	2272.06	63.78 %	0.051792
„Pallier homomorfiniu šifravimu grįstas modelis“	2185.37	63.52 %	0.1416

Pagal gautus tyrimo rezultatus, gauname tokias išvadas:

1. „PyTorch neuroninis tinklas“ greičiau artėja prie nuostolių funkcijos minimumo, nei kiti modeliai. Esant 70 % modelių tikslumui, „PyTorch modelis“ yra saugiausias. Mažiausiai saugus yra „gradientiniu nusileidimu grįstas modelis“.
2. „Pallier kriptografija grįstas modelis“ yra saugesnis už „gradientinio nusileidimo metodą“.
3. Didėjant „PyTorch modelio“ tikslumui, jis pradeda labiau prisirišti prie duomenų ir vidutinė galima maksimalaus nuokrypio reikšmė smarkiai krenta – modelis tampa vis mažiau saugus. Priklausomybė atvaizduota pav. 1. Jeigu uždavinio tikslas yra sukurti labai tikslų modelį, vertėtų apgalvoti ar „Pallier sistema grįstas modelis“ nėra geriau.
4. Su visais modeliais, išskyrus „PyTorch neuroninį tinklą“, didėjant modelio tikslumui, didėja vidutinė maksimalaus nuokrypio reikšmė – modelis tampa saugesnis, o su „PyTorch neuroniniu tinklu“, mažėja – modelis tampa mažiau saugus.



1 pav. DMDK reikšmės priklausomybė nuo „PyTorch modelio“ tikslumo

Tas pats tyrimas buvo atliktas su MNIST rašytinių skaitmenų nuotraukomis. Tik „PyTorch neuroninis tinklas“ su vienu paslėptu sluoksniu ir VGG16 konvergavo minimumo link. Pasiekus 74 % ir 82 % tikslumus, „PyTorch neuroninio tinklo“ DMDK reikšmės išlieka vienoda - 0.04999, MSE nuostolių funkcijos reikšmės atitinkamai 266.66730 ir 203.6602. VGG16 tinklui pasiekus 72 % tikslumą, MSE nuostolių funkcijos reikšmė - 2.59, DMDK reikšmė - 0.17. Reiškia, kad VGG16 modelis yra saugesnis už paprastą vieno paslėpto sluoksniu „PyTorch neuroninį tinklą“.

5 Išvados

Lyginant „PyTorch neuroninį tinklą“, „gradientinio nusileidimo algoritimą“ ir „Pallier homomorfiniu šifravimu grįstą modelį“, jeigu visi minėti modeliai vykdant tyrimą konverguoja minimumo link, pats saugiausias modelis yra „PyTorch neuroninis modelis“. Mažiausiai duomenis saugantis yra „gradientinio nusileidimo metodas“.

Naudojant „Pallier homomorfiniu šifravimu grįstą modelį“, egzistuoja koreliacija tarp modelio nuostolių funkcijos reikšmės ir DMDK rodiklio. Vidutiniškai, kuo nuostolių funkcijos reikšmė yra mažesnė, tuo DMDK rodiklis yra didesnis ir modelis yra saugesnis.

„Pallier homomorfiniu šifravimu grįstas modelis“, naudojantis „gradientinio nusileidimo algoritimą“, diverguoja su MNIST rašytinių skaičių nuotraukomis.

Paprastas „PyTorch neuroninis tinklas“ vienintelis iš minėtų modelių konverguoja minimumo link, su MNIST rašytinių skaičių nuotraukomis. Šiuo atveju, DMDK rodiklis vidutiniškai nukrenta iki 0.049 ir modelis tampa mažiau saugus, nei „Pallier algoritmu grįstas modelis“.

Literatūra

- [1] Ho Bae, Jaehee Jang, Dahuin Jung, Hyemi Jang, Heonseok Ha, and Sungroh Yoon. Security and privacy issues in deep learning. CoRR, abs/1807.11655, 2018.
- [2] Patricia Thaine. Perfectly privacy-preserving ai, Jan 2020
- [3] Nicholas Carlini, Florian Tramèr, Eric Wallace, Matthew Jagielski, Ariel HerbertVoss, Katherine Lee, Adam Roberts, Tom Brown, Dawn Song, Ulfar Erlingsson, Alina Oprea, and Colin Raffel. Extracting training data from large language models, 2020.

Automatinė pilvo aortos atsišakojimų paieška kompiuterinės tomografijos nuotraukoje

Vladyslav Palkevič

Vilniaus universiteto Duomenų mokslo ir skaitmeninių technologijų institutas,
Akademijos g. 4, LT-08412 Vilnius
vladyslav.palkevic@gmail.com

Santrauka: Pilvo aortos modelio detalumas yra labai svarbus, vertinant šio organo kraujotaką bei galimų ligų simptomus. Aortos analizė vykdoma naudojant kompiuterinės tomografijos (CT) vaizdus. Siekiant automatiškai sužymėti pilvo aortos ribas CT vaizduose, naudojami tradiciniai vaizdų apdorojimo metodai, leidžiantys vaizde aptikti organo ribas (sienas). Tokie algoritmai turi trūkumą, susijusį su aortos atsišakojimų sekimu (pavyzdžiui, ties inkstais ar kojomis) – jie žymi tik vieną iš atšakų ir ignoruoja kitą. Šiame straipsnyje siūlomas problemos sprendimas – DBSCAN klasterizavimo algoritmo integravimas į ribų aptikimo algoritmus. Klasterizavimas aptinka, ar prasideda aortos atsišakojimas. Sprendimas priimamas pagal du vienas paskui kitą einančius CT nuotraukos vaizdus. Po atsišakojimo aptikimo kiekvienas klasteris kituose CT nuotraukos vaizduose gali būti analizuojamas atskirai. Todėl straipsnyje pateiktas atsišakojimo paieškos problemos sprendimo būdas leidžia ne tik rasti atsišakojimą naujame vaizde, bet ir toliau jį sekti kituose vaizduose.

Raktiniai žodžiai: kompiuterinė tomografija, pilvo aorta, aortos atsišakojimas, DBSCAN, klasterizavimas, aortos ribos.

1 Įvadas

Aorta – tai pati stambiausia organizme esanti arterija, kuri atsišakoja į gyvybiškai svarbius organus. Aorta skirstoma į šias dalis: 1) krūtinės (nuo širdies iki aortos lanko), aortos lanką ir nusileidžiančią (nuo aortos lanko išilgai stuburo priekinės dalies žemyn, iki diafragmos), 2) pilvo (abdominalinė) aorta – aortos dalis nuo diafragmos iki išsišakojimo (bifurkacijos) į dvi klubines arterijas dubens srityje. Tokios pilvo aortos ligos, kaip aneurizmos arba aortos sienų atsislauksniavimai, gali sukelti labai rimtų pasekmių pa-

cientui. Šios ligos diagnozuojamos analizuojant kompiuterinės tomografijos (CT) nuotraukas. Kompiuterinės tomografijos nuotrauką sudaro daugelio vaizdų (angl. *slice*) rinkinys, kuris „supjausto“ tiriamą kūno dalį į daug sluoksnių. Pažymėkime vaizdų skaičių CT nuotraukoje m . Dažnai m būna net artimas 300. CT nuotraukų darymo metu pacientui į veną yra suleidžiamas kontrastas, kuris, patekęs į aortą, išryškina jos sienas nuotraukose. Siekiant automatizuoti aortos aptikimą, naudojami tiek neuroniniai tinklai, tiek tradiciniai vaizdų apdorojimo metodai [1], [2], [3], [4]. Dauguma tradicinių vaizdų apdorojimo metodų susiduria su atsišakojimų sekimo problema analizuojant daugiau nei vieną kompiuterinės tomografijos nuotrauką. Taikant tradicinius metodus žmogaus organams aptikti reikia 1) pradinės taškų aibės tiriamo organo vaizdo viduje ar aplink jį, arba 2) pradžios taško, nuo kurio algoritmas pradeda analizę. Tačiau šie algoritmai nenumato atšakų sekimo, t. y. į kitą vaizdą pateks tik viena pradinė taškų aibė (klasteris) arba vienas pradžios taškas. Šiuo darbu siekiama išspręsti organo vaizdo atsišakojimo radimo problemą, analizuojant pilvo aortos CT nuotrauką.


2 Siūlomas metodas

Šio darbo tikslas – pristatyti metodą, skirtą pilvo aortos atsišakojimui rasti kompiuterinės tomografijos nuotraukoje. Sprendimas priimamas pagal du vienas paskui kitą einančius CT nuotraukos vaizdus. Vadinkime juos $k-1$ -as ir k -sis vaizdai. Žinome, kad $k-1$ -me vaizde atsišakojimo nėra. Reikia atsakyti į klausimą, ar atsišakojimas yra k -jame vaizde, ir nustatyti aortos ribas tame vaizde.

Metodas susideda iš šių etapų:

1. Lokalizuojama naujų klasterių paieškos sritis k -jame vaizde remiantis $k-1$ -ojo vaizdo informacija.
2. Nustatytos srities taškai suskirstomi į klasterius.
3. Nustatoma, kiek yra klasterių vaizde (jei klasteris vienas, reiškia k -jame vaizde atsišakojimo nėra, o jei jų keli – atsišakojimas yra).
4. Aptinkamos aortos ribos naudojant ribos aptikimo algoritmą kiekvienam rastam klasteriui.

Pirmame metodo etape norint gauti lokalizuotą naujų klasterių paieškos sritį k -jam vaizdai, reikia apdoroti $k-1$ -jo kadro pažymėtus duomenis. $k-1$ -jo kadro pažymėtų taškų aibėje randamos minimalios ir maksimalios koordinatų x ir y reikšmės, kurios ir sudarys stačiakampę naujų klasterių paieškos sritį.




1 pav. Raudonai pažymėta aorta, mėlyna spalva aplink ją apibrėžta paieškos sritis klasterizavimo algoritmui

1 pav. pažymėta aorta (raudonai) ir būsima paieškos sritis (mėlynai), kuri suformuota remiantis koordinatinių minimumo ir maksimumo reikšmėmis. Mažas realus atstumas tarp vaizdų (tarpas tarp jų dažniausiai būna apie 1–4 mm) staigaus pokyčio kitame vaizde nesudarys, todėl naujų klasterių galima ieškoti toje pačioje, arba keliais pikseliais padidintoje paieškos srityje. Dviem poromis vienas paskui kitą einantys vaizdai parodyti 2 pav.



Vaizdas nr. 60



Vaizdas nr. 60





Vaizdas nr. 200



Vaizdas nr. 201

2 pav. Vienas paskui kitą einančių vaizdų pavyzdžiai

Antrajame metodo etape taikomas erdvinis klasterizavimas. Eksperimentuose naudotas DBSCAN [5] klasterizavimo algoritmas. DBSCAN – tai tankiu pagrįstas algoritmas. Jis grupuoja duomenis į klasterius, kurie tankiai tarpusavyje išsidėstę. DBSCAN algoritmas turi du parametrus, kuriuos nustato vartotojas. *Eps* – tai maksimalus paieškos atstumas nuo nepriskirto taško. Šis parametras atsakingas už paieškos apskritimo dydį. *MinPts* – tai minimalus kaimynų skaičius, kurie yra artimi nepriskirtam taškui. Klasterizavimas prasideda nuo nepriskirto taško pasirinkimo nurodytoje paieškos srityje. Jei aplink pasirinktą tašką spinduliu *Eps* yra ne mažiau nei *MinPts* kaimynų, kurių reikšmės yra artimos pasirinkto taško reikšmei, formuojamas naujas klasteris arba taškas prijungiamas prie jau egzistuojančio kaimynų klasterio. Jei taškas netenkina nurodytų parametrų – jis priskiriamas triukšmo taškams, kurių reikšmės yra nutolusios nuo kitų ir jie nebuvo priskirti nei vienam klasteriui. Po klasterizavimo triukšmas pašalinamas.



3 pav. DBSCAN klasterizavimo principo ir tomografijos nuotraukos po pradinio apdorojimo pavyzdžiai

Pateiktame klasterizavimo pavyzdyje (3 pav.) jau yra suformuoti du klasteriai, jie atskirti spalvomis – žalia ir mėlyna. Sprendžiama, kuriems klasteriams priklausys taškai 1, 2 ir 3. Taškas 1 bus priskirtas mėlynųjų taškų klasteriui, o taškas 2 – žaliųjų, nes abu atitinka nustatytus parametrus – *Eps* spinduliu turi nustatytą minimalų *MinPts* kaimynų skaičių su artima reikšme, lygų 3. Taškas 3 nebus priskirtas nei vienam klasteriui, nes jis neatitinka reikalavimų pagal *MinPts* parametą – jis bus priskirtas triukšmui ir pašalintas.

Toks klasterizavimo būdas geras tada, kai nėra iš anksto žinomas būsimų klasterių skaičius ir yra ryškus taškų reikšmių pokytis. Sprendžiamame uždavinyje klasterizuojami vaizdo pikseliai, kurių spalva atitinka aortos kontrasto baltą spalvą. Kadangi po pirminio vaizdo apdorojimo (triukšmo naikinimo ir kontrasto koregavimo) vizualios ribos tarp aortos ir kitų organų gana ryškios, klasterizavimo paklaida minimali. Paklaidą galima sumažinti keičiant parametrų *Eps* ir *MinPts* reikšmes.

Galvęs pradinę naujų klasterių paieškos sritį, *Eps* ir *MinPts* parametrus, DBSCAN algoritmas gali pradėti klasterizavimą. CT vaizduose aorta matoma labai ryškiai dėl savo baltos spalvos, todėl klasterizavimui atrenkami tik tos spalvos pikseliai. Proceso rezultatas: gaunama n klasterių bei jiems priskirti pikseliai.

Trečiasis metodo etapas – atsišakojimų atpažinimas, kuris įgyvendinamas klasterizavimo metu. Klasterizuojant vaizdą k su vaizdo $k-1$ lokalizuota paieškos sritimi, galima gauti n klasterių. Jei klasterių skaičius viršija 1, šiame vaizde įvyko atsišakojimas.


Ketvirtame metodo etape randami klasterių vidurio taškai, kurių reikia norint vaizdą apdoroti ribų aptikimo algoritmu. Vidurio taškas randamas taip: aplink atrastą klasterį apibrėžiamas keturkampis ir jame nustatomas vidurio taškas. Naudojant gautus klasterių vidurio taškus atliekamas tų klasterių ribų aptikimas. Randamos aortos bei jos atsišakojimų, jei tokių yra, ribos k -jame vaizde.

Kai k prabėga nuo 2 iki m , randamos visos aortos ir jos atšakų ribos. Problema yra atrasti aortos ribas pirmame CT vaizde ($k=1$). Pirmame taške aortos atsišakojimų nebūna. Norint rasti CT vaizde tašką aortoje ir pagal jį nustatyti aortos ribas, galima interaktyviai jį nurodyti. Automatiškai tokį tašką galima rasti metodu, pasiūlytu [6].


3 Rezultatai

Pristatytas metodas iliustruojamas dviem pavyzdžiais: kai aortoje nėra atsišakojimų ir kai aorta atsišakoja į kojas (4 pav.). Atsišakojime pavyko sėkmingai aptikti du klasterius ir juos sekti dar 30 toliau einančiuose vaizduose. Tyrimo metu naudoti nuasmeninti vaizdai, DBSCAN algoritmo parametrai: $Eps = 2$ (pikseliai) ir $MinPts = 3$.


Vaizdas nr. 20




Vaizdas nr. 21




Vaizdas nr. 51




Vaizdas nr. 200



Vaizdas nr. 201



Vaizdas nr. 230



4 pav. Aortos radimo CT vaizduose pavyzdžiai: atsišakojimo dar nėra vaizduose nr. 20, 21, 51 ir 200; aorta atsišakojusi vaizduose nr. 201 ir 230

4 Išvados

Norint objektyviai vertinti žmogaus pilvo aortos kraujotaką, labai svarbus aortos modelio detalumas. Jei joje yra kokie nors ligų simptomai, būtina juos laiku aptikti ir pradėti gydyti. Tokią galimybę suteikia DBSCAN klasterizavimo algoritmo integravimas į aortos ribų aptikimo algoritmus. Šiame straipsnyje pristatytas metodas leidžia nustatyti ne tik aortos ribas, bet ir aortos atšakas, taip pat sekti tų atšakų ribas CT nuotraukoje.

Literatūra

- [1] F. Lareyre, C. Adam, M. Carrier, C. Dommerc, C. Mialhe, J. Raffort. (2019). A fully automated pipeline for mining abdominal aortic aneurysm using image segmentation. *Scientific Reports* 9, 13750. <https://doi.org/10.1038/s41598-019-50251-8>
- [2] R. J. Hemalatha, T.R. Thamizhvani, A.J.A. Dhivya, J.E. Joseph, B. Babu, R. Chandrasekaran. (2018). Active Contour Based Segmentation Techniques for Medical Image Analysis. doi: 10.5772/intechopen.74576
- [3] L. Álvarez, L. Baumela, P. Henríquez, P. Márquez-Neila (2010). Morphological snakes, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Francisco, CA, USA, 2010, pp. 2197-2202, doi: 10.1109/CVPR.2010.5539900
- [4] J. Raffort, C. Adam, M. Carrier, A. Ballaith, R. Coscas, E. Jean-Baptiste, R. Hassen-Khodja, N. Chakfé, F. Lareyre. (2020) Artificial intelligence in abdominal aortic aneurysm. *Journal of Vascular Surgery*. Jul;72(1):321-333.e1. doi: 10.1016/j.jvs.2019.12.026.
- [5] M. Ester, H.-P. Kriegel, J. Sander, X. Xu. (1996). A density-based algorithm for discovering clusters in large spatial databases with noise. *Proceedings of Second International Conference on Knowledge Discovery and Data Mining*, Portland (1996) pp. 226–231.
- [6] A. Šubonienė. (2020). Pilvo aortos vietos nustatymas krūtinės ląstos tomografinėje nuotraukoje. *Bakalauro baigiamasis darbas*. Vilniaus universitetas.

YouTube vaizdo įrašų populiarumo vertinimas naudojant viešai prieinamus metaduomenis

Gabrielė Ruminavičiūtė

Vilniaus Universitetas, Matematikos ir informatikos fakultetas,
Naugarduko g. 24, LT-03225 Vilnius
gabriele.ruminaviciute@mif.stud.vu.lt

Santrauka. YouTube vaizdo įrašų duomenų augimo tempai kelia daug problemų sprendžiant vaizdo įrašų populiarumo vertinimo ir klasifikavimo uždavinius. Vis dar nėra nusistovėjusios metodologijos, kokiais kriterijais remiantis, turi būti apibrėžiamas įrašų populiarumas. Šiame darbe analizuojami YouTube duomenų programos programavimo sąsajos pagalba surinkti vaizdo įrašų metaduomenys ir išvestiniai jų parametrai. Įvertinus reikšmingus vidurkių skirtumus tarp populiarumo grupių statistiniais testais, atliktas vaizdo įrašų populiarumo grupių klasifikavimas naudojant tris mašininio mokymosi metodus: atraminių vektorių, atsitiktinio miško ir daugialypės logistinės regresijos klasifikatorius. Atlikta algoritmų lyginamoji analizė bei atrinkti populiarumo lygį tiksliausiai klasifikuojantys požymių rinkiniai.

Raktiniai žodžiai: YouTube, populiarumas, klasifikavimas, atraminių vektorių klasifikatorius, atsitiktinis miškas, daugialypė logistinė regresija, mašininis mokymasis, statistinė analizė

1 Įvadas

YouTube tinklalapis yra viena populiariausių vaizdo įrašų platinimo platformų, turinčių virš dviejų milijardų naudotojų, žiūrinčių vaizdo įrašų turinį virš milijardo valandų kiekvieną dieną. Taip pat kiekvieną minutę į šį tinklalapį yra įkeliama apie 500 valandų vaizdo įrašų turinio [1]. Neabejotina, kad toks greitai augantis vaizdo įrašų duomenų kiekis sudaro vis sunkesnes galimybes vaizdo įrašus surūšiuoti ir atskirti, kurie vaizdo įrašai yra populiarūs bei nustatyti, kokiais kriterijais remiantis turi būti apibrėžiamas populiarumas. Taip pat nėra aiškiai apibrėžtos populiarumo sąvokos - kiekvienas tyrėjas tyrime populiarumo apibrėžimą pateikia savaip. Tiek vaizdo įrašo kūrėjams, tiek YouTube kompanijai informacija apie įrašų populiarumą yra svarbi, ka-

dangi abi šalys uždirba iš reklamų – kuo vaizdo įrašas populiariesnis ir pasiekia daugiau auditorijos, tuo daugiau pinigų uždirbama iš tame vaizdo įrašė leidžiamos reklamos. Ši informacija reikalinga ir įvairioms reklamos kompanijoms – populiariuose vaizdo įrašuose rodoma reklama matoma daugiau kartų gali padidinti įmonės pelną.

Viena iš pagrindinių metrikų, pagal kurią vaizdo įrašas yra laikomas populiariu yra vaizdo įrašo peržiūros. Kita vertus, populiarumas ir vaizdo įrašų peržiūrų skaičius nėra sinonimai. Labai svarbus kriterijus populiarumui nusakyti yra ir laikas. Dviejų vaizdo įrašų klasifikavimas į tą pačią populiarumo grupę, turint tą patį įrašų peržiūrų skaičių, bet skirtingą įrašų gyvavimo vietoje erdvėje trukmę, būtų neteisingas. Dėl šios priežasties, populiarumas gali būti apibrėžtas skirtingomis kategorijomis (nepopuliarūs, populiarūs, labai populiarūs ir t.t.) atsižvelgiant į vaizdo įrašo peržiūrų skaičių bei gyvavimo trukmę. Tačiau kyla ir kitas klausimas - kokie kiti papildomi požymiai gali daryti įtaką vaizdo įrašo populiarumui?

Šio darbo tikslas yra klasifikuoti YouTube vaizdo įrašus pagal populiarumo grupes, naudojant viešai prieinamus metaduomenis bei atlikti įvairių klasifikavimo algoritmų lyginamąją analizę.

2 Literatūros apžvalga

YouTube vaizdo įrašų populiarumo klausimas nagrinėjant papildomus metaduomenis nėra lengva užduotis. Daugelis svarbių metrikų, kurios iš dalies galėtų pasakyti kokie požymiai lėmė konkretaus vaizdo įrašo populiarumą, nėra viešai prieinami, todėl publikuoti tyrimai atlikti panašia tema taip pat yra labai riboti. Kita vertus, vaizdo įrašų populiarumas įtraukiant įvairius metaduomenis yra plačiai nagrinėjama tema. Vienas iš klasifikatorių, naudojamas YouTube vaizdo įrašų populiarumo prognozavimui, yra atraminių vektorių klasifikatorius (angl. Support Vector Machine, SVM). [2] pateiktas tyrimas parodė, kad naudojant vizualinius vaizdo įrašų požymius (vaizdo įrašų trukmė, kadru skaičius, rezoliucija, spalvos, veido ir teksto pasirodymas kadruose, miniatiūros kokybė ir t.t.) galima nuspėti vaizdo įrašo populiarumą, o norint pagerinti šio klasifikatoriaus prognozavimo tikslumą, dinaminiai požymiai, tokie kaip peržiūrų, „patinka“, pasidalijimų ir komentarų skaičius taip pat turėtų būti įtraukti. Naudojant įvairius mašininio mokymosi metodus, nustatyta, jog penki požymiai daro įtaką vaizdo įrašų

populiarumui – peržiūros pirmąją dieną, kanalo prenumeratorių skaičius, miniatiūros kontrastas, paieškos sistemos „Google“ paspaudimai ir raktinių žodžių kiekis [3]. Kita vertus, populiarumo prognozavimas yra labai svarbi užduotis ankstyvajame vaizdo įrašo gyvavimo laikotarpyje, todėl [4] naudojama daugialypės tiesinės regresijos modeliai, skirti nuspėti ateities vaizdo įrašo peržiūras, naudojant praeities reikšmes. Vaizdo įrašų populiarumas yra vertinamas ir neturint apie vaizdo įrašus jokios istorijos arba dinaminių požymių. Tokiam populiarumo prognozavimui naudojami sudėtingesni mašininio mokymosi klasifikatoriai [5]: klasifikatorių junginys (angl. Ensemble of Classifiers) tiksliau nustato populiarumo klases negu individualūs Naiviojo Bajeso, SVM, logistinės regresijos, neuroninių tinklų ir atsitiktinio miško (angl. Random Forest, RF) klasifikatoriai.

Nagrinėjant mokslinę literatūrą pastebėta, kad vaizdo įrašų metaduomenų požymių rinkiniai skiriasi, todėl apibendrinti gautus rezultatus sudėtinga. Metaduomenų rinkiniai yra labai įvairūs jie rūšiuojasi į dinامينius – kintančius laike – požymius (peržiūrų, komentarų, „patinka“, „nepatinka“ skaičius), miniatiūrų kokybės vertinimo požymių grupę (miniatiūros kokybė, šviesumas, išsiliesimas ir kontrastas), ir tekstinio turinio kokybės vertinimo požymių grupes (simbolių skaičius pavadinime, aprašymas, raktinių žodžių kiekis). Todėl analizė gali būti atliekama naudojant bendrus požymių rinkinius, arba pasirenkant tik vieną tikslią požymių grupę, pvz. [6] naudojami tekstiniai metaduomenys (aprašymas ir pavadinimas).

3 Duomenys

Darbe naudojami YouTube video įrašų platformos duomenys, surinkti YouTube Data API (angl. Application Programming Interface) – viešai prieinama YouTube duomenų programos programavimo sąsaja. Iš surinktų metaduomenų sukonstruoti papildomi kintamieji, kurie naudojami darbe (žr. 1 lentelę).

Taigi, iš viso turima 14 kintamųjų, kurių 12 - kiekybiniai, o likę 2 - kategoriniai. Visą duomenų imtį sudaro virš 130 tūkstančių vaizdo įrašų, patalpintų 629-iuose kanaluose. 2-oje lentelėje pateikta duomenų rinkinio apibendrinimas.

1 lentelė. Duomenų aprašymas

Apibūdinimas	Tipas	Galimos reikšmės (imties plotis)
Kanalo prenumeratorių skaičius	Kiekybinis	[0, 54800000]
Vaizdo įrašo amžius dienomis	Kiekybinis	[1, 5569]
Vidutinis vaizdo įrašo peržiūrų skaičius per dieną	Kiekybinis	[0, 3543465]
Vidutinis "patinka" paspaudimų skaičius per dieną	Kiekybinis	[0, 207945,46]
Vidutinis "nepatinka" paspaudimų skaičius per dieną	Kiekybinis	[0, 24109,057]
Vidutinis komentarų skaičius per dieną	Kiekybinis	[0, 20660,382]
Egzistuoja vaizdo įrašo aprašymas	Dichotominis	1 arba 0
Simbolių pavadinime skaičius	Kiekybinis	[1, 100]
Raktinių žodžių skaičius	Kiekybinis	[0, 115]
Miniatiūros kokybė	Kiekybinis	[0,0028; 99,9595]
Miniatiūros išsiliejimas	Kiekybinis	[0, 42075]
Miniatiūros kontrastas	Kiekybinis	[0, 124,72]
Miniatiūros šviesumas	Kiekybinis	[0, 255]
Populiarumo grupė	Nominalus	0, 1, 2, 3

2 lentelė. Duomenų rinkinio apibendrinimas

Vaizdo įrašai	132321
Kanalai	629
Vidutinis vaizdo įrašo amžius (dienos)	1089
Vidutinis peržiūrų skaičius (vienam vaizdo įrašui)	4064744

Visa duomenų imtis yra suskirstyta į keturias populiarumo grupes, naudojant vidutinio vaizdo įrašo peržiūrų skaičiaus per dieną kvartilius tam, kad išvengtų nesubalansuotos duomenų imties, jog kiekviena grupė duomenyse nepasitaikytų dažniau negu kita. Pirmąją grupę – nepopuliarią – sudaro vaizdo įrašai, kurių vidutinės peržiūros yra ne didesnės negu 48.6. Antrosios – vidutinio populiarumo – grupės vidutinės peržiūros per dieną patenka tarp (48,6012; 494,3954]. Populiarių vaizdo įrašų vidutinės peržiūros per dieną (trečiosios grupės) patenka į intervalą (494;3954, 3209;4048]. Visi likusieji vaizdo įrašai sudaro ketvirtąją – labai populiarią – grupę, kurių vidutinės peržiūros per dieną yra didesnės už 3209,4048. Tačiau tam, kad išvengtų tiesinio

ryšio tarp populiarumo grupių ir vaizdo įrašo amžiaus bei peržiūrų skaičiaus, pastarieji kintamieji į mašininio mokymosi algoritmus nėra įtraukiami.

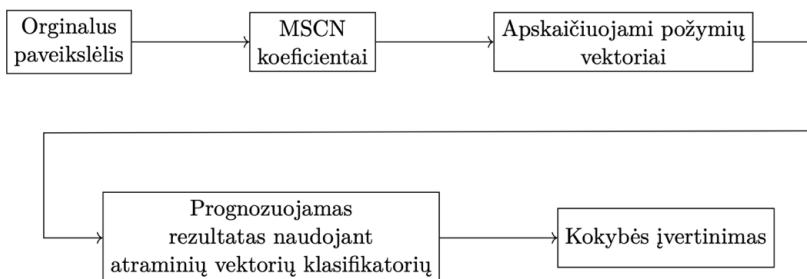
4 Tyrimo metodologija

Metaduomenų konstravimas

Pagrindinių kintamųjų, paaiškinančių vaizdo įrašo žiūrovų įsitraukimą, apskaičiavimas:

- vidutinės peržiūros per dieną: santykis visų vaizdo įrašo peržiūrų ir vaizdo įrašo amžiaus (skirtumas tarp vaizdo įrašo duomenų nusiskaitymo dienos ir vaizdo įrašo publikavimo viešai dienos);
- vidutinis komentarų skaičius per dieną: santykis visų komentarų ir vaizdo įrašo amžiaus;
- vidutinis „patinka“ paspaudimų skaičius per dieną: santykis visų „patinka“ paspaudimų skaičiaus ir vaizdo įrašo amžiaus;
- vidutinis „nepatinka“ paspaudimų skaičius per dieną: santykis visų „nepatinka“ paspaudimų skaičiaus ir vaizdo įrašo amžiaus;

Miniatiūrų įvertinimui fiksuojami kokybės, išsiliejimo, kontrasto ir šviesumo požymiai. Miniatiūros kokybė įvertinta naudojant aklojo/be nuorodų vaizdų erdvinės kokybės vertinimo metodiką (angl. Blind/Referenceless Image Spatial Quality Evaluator, BRISQUE) [7]. Šis kokybės vertinimas remiasi algoritmu (žr. 1 pav.)



1 pav. BRISQUE algoritmas

Miniatiūros išsiliejimas skaičiuojamas naudojant Laplaso operatorių [8]. Laplaso operatorius naudojamas briaunų nustatymui, nes pabrėžia atvaizdo regionų staigų kitimą, todėl aukštesnės dispersijos paveikslukai turi

daugiau staigių kitimų, o tai reiškia didesnę skaičių briaunų. Kuo daugiau nustatoma paveikslėlyje kraštinių, tuo paveikslėlis yra ryškesnis ir mažiau išsiliejęs.

Paveikslėlio kontrastas ir šviesumas apskaičiuojamas atitinkamai pikselio intensyvumo ir pikselio šviesumo vidurkio kvadratine šaknimi [9]:

$$\text{Kontrastas} = \sqrt{\frac{1}{MN} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (I(i,j) - \bar{I})^2},$$

$$\text{Šviesumas} = \sqrt{\frac{1}{MN} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (\delta(i,j) - \bar{\delta})^2},$$

$i \in \{0, 1, \dots, M-1\}; j \in \{0, 1, \dots, N-1\}; M$ ir N miniatiūros aukštis ir plotis atitinkamai, I pikselio intensyvumas, \bar{I} – pikselių intensyvumo vidurkis, δ – pikselio šviesumas, $\bar{\delta}$ – pikselių šviesumo vidurkis.

Statistiniai testai

Skirtumams tarp vidurkių populiarumo grupėse įvertinti naudojamas MANOVA testas. MANOVA testą galima naudoti esant tam tikroms sąlygoms: priklausomi kintamieji turi būti normaliai pasiskirstę grupėse (daugiamatis normalumas), dispersijų homogeniškumas bei tiesiškumas tarp visų priklausomų kintamųjų porų. Tikrinama nulinė hipotezė:

$$\begin{cases} H_0: \mu_1 = \mu_2 = \mu_3 = \mu_4 \\ H_1: \mu_i \neq \mu_j \text{ nors vienai porai } (i, j), \end{cases}$$

čia $\mu'_s = (\mu_{s1}, \mu_{s2}, \dots, \mu_{sk})$ – grupės $s \in \{1, 2, 3, 4\}$ vidurkių vektorius, $k \in \{1, 2, \dots, p\}$ – kintamasis.

Tyrimo skaičiuojama Wilks MANOVA testo statistika [10]. Tyrimo duomenims daroma prielaida, kad daugiamačio normalumo ir tiesiškumo prielaidos yra tenkinamos.

Vienmatė ANOVA naudojama ištirti kiekvieną priklausomą kintamąjį. Kadangi dispersijos homogeniškumo prielaidą duomenys pažeidė (tikrinama Levene testu [11]), naudojamas ANOVA Welch kriterijus [12]. Post-hoc analizėje poriniai palyginimai atlikti Games-Howell kriterijumi [13].

Taikomi klasifikatoriai

1. Atraminų vektorių klasifikatorius, naudojant radialinį branduolį. Pagrindinė klasifikatoriaus idėja yra apmokymo duomenų projektavimas į bendrą požymių erdvę ir hiperplokštumos sukūrimas, kuri atskiria skirtingas požymių klases. Radialinio branduolio SVM klasifikatoriui parinktas C – parametras, apibrėžiantis tolerantiškumą klaidingam klasifikavimui ir γ – parametras, atsakingas už sprendimo ribos sklandumą ir kontroliuoja modelio dispersiją [14]. Prieš atliekant SVM, duomenys yra standartizuojami. Kintamųjų standartizacija yra būtina SVM klasifikatoriui, kadangi tokiu būdu visų kintamųjų režiai turės panašią įtaką skaičiuojant atstumus hiperplokštumos konstravimui.
2. Atsitiktinis miškas – klasės formuojamos apjungiant sprendimus daugumos balsu iš sprendimų medžių, sukurtų sujungiant skirtingus duomenų poaibius iš visos duomenų aibės naudojant atsitiktinai parinkus požymių poaibius iš požymių aibės. Atlikus atsitiktinio miško klasifikatorių, įvertinta požymių svarba, remiantis Gini indekso:

$$I_G(p) = \sum_{i=1}^J p_i(1 - p_i),$$

čia $i \in \{1, 2, \dots, J\}$, J – imtyje esančių kategorijų skaičius, o p_i yra i -tosios kategorijos proporcija imtyje, pokyčiu, kuomet medyje atliekamas atskyrimas remiantis tam tikru požymiu. Požymio svarbumas yra visų medžių sprendimų vidurkis, tai reiškia, kad požymio svarba yra vidutinė tarp visų medžių [14]. RF parinkti šie parametrai: sprendimų medžių kiekis miške, kiekvieno padalijimo metu atsitiktinai atrinktų požymių skaičius, maksimalus lygių skaičius kiekviename sprendimų medyje, minimalus duomenų kiekis taškų, reikalingas toliau skaidyti medžio lapams bei minimalus duomenų taškų kiekis lapui.

3. Daugialypės logistinės regresijos modelis (angl. Multinomial Logistic Regression, MLR) – dvinarės logistinės regresijos apibendrinimas, kuomet priklausomas kintamasis įgyja daugiau nei dvi skirtingas reikšmes. Kategorijų priskyrimui yra skaičiuojamos visų galimų Y kategorijų įgijimo tikimybės ir Y prognozuojame tą reikšmę, kurios įgijimo tikimybė yra didžiausia. Matematinis modelis yra nusakomas tikimybėmis:

$$P(Y_i = j | x_i) = \frac{\exp\{z_j\}}{1 + \sum_{h=1}^{J-1} \exp\{z_h\}},$$

čia $j \in \{1, 2, \dots, J\}$ – imtyje esančių kategorijų skaičius, $z_j = \alpha_j + \beta_j x_i$, x_i – požymiai. Kaip ir atsitiktiniame miške, taip ir daugialypėje logistinėje regresijoje galima apskaičiuoti požymių svarbą. Ji apskaičiuojama sudedant gautas kiekvieno kintamojo z reikšmes kiekvienoje kategorijoje [14]. Prieš atliekant MLR, duomenys yra standartizuojami bei kiekybiniais priklausomiems kintamiesiems pritaikoma kvadratinės šaknies transformacija, kadangi kintamieji yra stipriai asimetriški.

Klasifikatorių tikslumo vertinimui naudojamas k -dalių kryžminis patikrinimas (angl. k -fold Cross Validation), duomenų imtis yra padalinama į lygiai $k = 10$ dalių.

Klasifikatorių įvertinimas

Klasifikavimo algoritmų įvertinimui naudojamos trys metrikos:

$$\text{Bendras klasifikavimo tikslumas} = \frac{\text{Teisingi spėjimai}}{\text{Visi spėjimai}} \quad (\text{angl. general accuracy}),$$

$$\text{jautrumas (klasė = } J) = \frac{TT}{TT + KN} \quad (\text{angl. recall}),$$

$$\text{tikslumas (klasė = } J) = \frac{TT}{TT + KT} \quad (\text{angl. precision}),$$

čia TT – visi klasės J objektai priskiriami klasei J , KT – visi ne klasės J objektai priskiriami klasei J , TN – ne klasės J objektai nepriskiriami klasei J , KN – visi klasės J objektai nepriskiriami klasei J .

5 Eksperimentinis tyrimas

Statistinės analizės rezultatai

Priklausomų kokybinių kintamųjų vidurkiai grupėse skiriasi (MANOVA: $F(3, 127) = 3801,1$; $\Lambda = 0,35$; p – reikšmė = $2,2 \times 10^{-16}$). Tolesnės vienmatės ANOVA rezultatai, naudojant Welch kriterijų, pateikti 3 lentelėje. Taigi, yra statistiškai reikšmingi skirtumai visuose kintamuosiuose tarp vaizdo įrašų populiarumo grupių.

3 lentelė. ANOVA Welch kriterijaus rezultatai

Kintamasis	Laisvės laipsniai, n	Laisvės laipsniai, d	F statistika	p -reikšmė
Vidutinis komentarų skaičius per dieną	3	38329	23775,41	<0,05
Vidutinis „nepatinka“ paspaudimų skaičius per dieną	3	38354	27842,65	<0,05
Vidutinis „patinka“ paspaudimų skaičius per dieną	3	38252	32180,52	<0,05
Kanalo prenumeratorių skaičius	3	41121	15670,81	<0,05
Simbolių pavadinime skaičius	3	49148	240,81	<0,05
Raktinių žodžių skaičius	3	49198	1472,09	<0,05
Miniatiūros kokybė	3	48920	375,04	<0,05
Miniatiūros išsiliejimas	3	49364	1122,26	<0,05
Miniatiūros šviesumas	3	48821	915,8	<0,05
Miniatiūros kontrastas	3	48913	149,81	<0,05

Atlikus porinius palyginimus naudojant Games-Howell kriterijų, nereikšmingi skirtumai tarp vidurkių yra šiuose požymiuose: simbolių pavadinime skaičiaus pirmoje ir antroje bei pirmoje ir trečioje populiarumo grupėse; miniatiūros kokybė antroje ir trečioje populiarumo grupėse; miniatiūros išsiliejime trečioje ir ketvirtoje bei miniatiūros kontraste antroje ir trečioje populiarumo grupėse. Kitur visi poriniai palyginimai, tarp populiarumo grupių reikšmingi kiekvienam rezultato kintamajam.

Klasifikavimo rezultatai


SVM, atsitiktinio miško ir daugialypės regresijos klasifikatoriams apmokyti naudojama atsitiktiniu būdu parinkta subalansuota (kiekvieną klasę sudaro vienodas skaičius vaizdo įrašų) imtis, sudaranti 70 % duomenų. Rezultatų patikrinimui naudojama 10 dalių kryžminis patikrinimas. Likusi 30 % duomenų imtis sudaro testavimo aibę, ji skirta patikrinti, kaip gerai klasifikatorius klasifikuoja nematytus duomenis. Visiems klasifikatoriams naudota ta pati duomenų aibė, sudaryta iš vienuolikos požymių: kanalo prenumeratorių skaičius, vidutinis „patinka“, „nepatinka“ paspaudimų skaičius per dieną, vidutinis komentarų skaičius per dieną, vaizdo įrašo aprašymo egzistavimas, simbolių pavadinime skaičius, raktinių žodžių skaičius, miniatiūros kokybė, išsiliejimas, kontrastas ir miniatiūros šviesumas.

Atraminių vektorių klasifikatoriaus parametrai: $C = 1000$ ir $\gamma = 1$. Pritaikant šį klasifikatorių testavimo imčiai su parinktais minėtais C ir γ parametrais, gautas 0,67 bendras klasifikavimo tikslumas klasifikuojant populiariumo grupes. Testavimo imčiai pritaikytas klasifikatorius pasiekė 0,68 bendrą klasifikavimo tikslumą. SVM klasifikatoriumi prasčiausiai identifikuojama antra klasė, o tiksliausiai ketvirta (žr. 4 lentelę).

4 lentelė. Klasifikavimo rezultatai


Klasė	SVM		Atsitiktinis miškas		MLR	
	Jautrumas	Tikslumas	Jautrumas	Tikslumas	Jautrumas	Tikslumas
1	0,71	0,63	0,93	0,91	0,91	0,86
2	0,57	0,54	0,83	0,83	0,77	0,77
3	0,62	0,68	0,82	0,82	0,77	0,77
4	0,81	0,89	0,90	0,92	0,86	0,91
Bendras klasifikavimo tikslumas	0,68		0,87		0,83	

Atsitiktinio miško klasifikatorius, įgyjantis aukščiausią tikslumą yra sudarytas iš 600 medžių, turintis 20 lygių kiekviename sprendimų medyje. Testavimo imties bendras klasifikavimo tikslumas yra 0,87 (4 lentelė). Įvertinus klasifikatoriaus jautrumą ir tikslumą, galima daryti išvadą, kad RF yra gana tiksliai suskirstė objektus į reikiamas klases. RF požymių svarba klasifikatoriaus bendram tikslumui matoma 2 pav. Pagal šį paveikslėlį matoma, kad vidutinis „patinka“ ir „nepatinka“ skaičius turi didžiausią svarbą.



2 pav. Atsitiktinio miško požymių svarba klasifikatoriaus bendram tikslumui

Atliekant daugialypę logistinę regresiją mokymo duomenims, gautas 0,83 bendras klasifikavimo tikslumas. Pritaikius MLR testavimo duomenims, gautas toks pats bendras klasifikavimo tikslumas kaip ir mokymo duomenims – 0,83 (žr. 4 lentelę). Nagrinėjant klasifikatoriaus jautrumą, matome, kad MLR klasifikatorius yra mažiau jautrus antros ir trečios populiarumo klasės atžvilgiu, tačiau gana tiksliai klasifikuoja kitas klases. Daugialypės regresijos požymių svarba matoma 3 pav. Kaip ir atsitiktinio miško klasifikatoriuje, taip ir čia, didžiausią svarbą turi tie patys pirmi du kintamieji.



3 pav. Daugialypės logistinės regresijos požymių svarba bendram klasifikatoriaus tikslumui

Lyginant visų atliktų klasifikatorių rezultatus testavimo imčiai, efektyviausias yra atsitiktinio miško klasifikatorius, kurio bendras klasifikatoriaus tikslumas yra 0,87. Žemiausią tikslumą turi SVM klasifikatorius – testavimo duomenims šis klasifikavimo algoritmas pasiekė 0,68 bendrą klasifikavimo tikslumą.

6 Išvados

Darbe atliktas vaizdo įrašų populiarumo tyrimas paremtas YouTube duomenų programos programavimo sąsajos pagalba surinktais vaizdo įrašų metaduomenimis ir išvestiniais jų parametrais. Įvertintas jungtinių kokybinių požymių vidurkių reikšmingas skirtumas tarp populiarumo grupių naudojant MANOVA statistinį testą ($F(3, 127) = 380,1; \Lambda = 0,35; p$ – reikšmė = $2,2 \times 10^{-16}$)

bei nustatyti reikšmingi vidurkių skirtumai daugumoje požymių tarp kiekvienos populiarumo grupės porų naudojant Games-Howell kriterijų.

Pasirinkus populiarumo klasių žymėjimą, naudojant vidutinio peržiūrų per dieną skaičiaus kvartilius, atliktas vaizdo įrašų klasifikavimas naudojant tris mašininio mokymosi algoritmus: atraminių vektorių klasifikatorių, atsitiktinį mišką ir daugialypę logistinę regresiją. Geriausi klasifikavimo rezultatai gauti atsitiktinio miško klasifikatoriumi (bendras klasifikavimo tikslumas yra 0.87).

Didžiausią įtaką klasifikavimo tikslumui daro dinaminiai požymiai - „patinka“ ir „nepatinka“ paspaudimų skaičius. Tačiau nagrinėti požymiai nepasako apie tai, ar vaizdo įrašų turinys atitinka kūrėjų pateiktus tekstinius duomenis (aprašymas, pavadinimas, raktiniai žodžiai), todėl tolimesniuose tyrimuose planuojama pasinaudojus natūralios kalbos apdorojimo algoritmais panaudoti įrašų turinio kontekstinę informaciją ir įvertinti jos įtaką populiarumui.

Taip pat vaizdo įrašų populiarumo klasių suskirstymas šiame darbe parinktas naudojant statistinius metodus, todėl ateities darbuose prasminga įvertinti, ar šis būdas yra efektyvus. Planuojama panaudoti grupavimo algoritmus ir įvertinti klasių susidarymo tendencijas bei ryšį su vaizdo įrašų populiarumu. Apibendrinus grupavimo rezultatus siekiama patikslinti populiarumo kriterijaus apibrėžimą ir tyrimą pakartoti naudojant tikslesnį populiarumo kriterijų. Taip pat planuojami papildomi tyrimai išplečiant klasifikatorių aibę, panaudojant rekurentinius neuroninius tinklus ir palyginti rezultatus.

Literatūra

- [1] YouTube, „YouTube for Press,“ [Tinkle]. Available: <https://blog.youtube/press/>. [Kreiptasi 14 03 2021].
- [2] T. Trzcinski ir P. Rokita, „Predicting popularity of online videos using Support Vector Regression,“ *IEEE Transactions on Multimedia*, 10 2015.
- [3] W. Hoiles, A. Aprem ir V. Krishnamurthy, „Engagement dynamics and sensitivity analysis of YouTube videos,“ *IEEE Transactions on Knowledge and Data Engineering*, t. PP, 11 2016.
- [4] H. Pinto, J. Almeida ir M. Gonçalves, „Using early view patterns to predict the popularity of YouTube videos,“ *WSDM 2013 - Proceedings of the 6th ACM International Conference on Web Search and Data Mining*, 02 2013.
- [5] Y.-L. Chen ir C.-L. Chang, „Early prediction of the future popularity of uploaded videos,“ *Expert Systems with Applications*, t. 133, nr. 0957-4174, pp. 59-74, 2019.
- [6] G. Kalra, R. Kathuria ir A. Kumar, „YouTube Video Classification based on Title and Des-

cription Text," įtraukta 2019 *International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)*, 2019.

- [7] A. Mittal, A. Moorthy ir A. Bovik, „No-Reference Image Quality Assessment in the Spatial Domain," *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society*, t. 21, 2012.
- [8] J. L. Pech Pacheco, G. Cristobal, J. Chamorro-Martinez ir J. Fernandez-Valdivia, „Diatom autofocusing in brightfield microscopy: A comparative study," įtraukta *Pattern Recognition, Proceedings. 15th International Conference on*, 2000.
- [9] R. A. Frazor ir W. S. Geisler, „Local luminance and contrast in natural images," *Vision Research*, t. 46, pp. 1585-1598, 2006.
- [10] R. A. Johnson ir D. W. Wichern, *Applied Multivariate Statistical Analysis*, Prentice-Hall, Inc., 2007.
- [11] J. Gastwirth, Y. Gel ir W. Miao, „The Impact of Levene's Test of Equality of Variances on Statistical Theory and Practice," *Statistical Science*, t. 24, 2010.
- [12] B. L. Welch, „On the Comparison of Several Mean Values: An Alternative Approach," *Biometrika*, t. 38, pp. 330-336, 1951.
- [13] P. A. Games ir J. F. Howell, „Pairwise Multiple Comparison Procedures with Unequal N's and/or Variances: A Monte Carlo Study," *Journal of Educational Statistics*, t. 1, pp. 113-125, 1976.
- [14] G. James, D. Witten, T. Hastie ir R. Tibshirani, *An Introduction to Statistical Learning: With Applications in R*, Springer Publishing Company, Incorporated, 2017.

Investigation of text data augmentation for transformer training via translation technique

Dominykas Šeputis

Vilnius University, Faculty of Mathematics and Informatics,
Institute of Computer Science,
Didlaukio str. 4, LT-08303 Vilnius
dominykas.seputis@mif.stud.vu.lt

Abstract. Data augmentation can improve model's final accuracy by introducing new data samples to the dataset. In this paper, text data augmentation using translation technique is investigated. Synthetic translations, generated by Opus-MT model are compared to the unique foreign data samples in terms of an impact to the transformer network-based models' performance. The experimental results showed that multilingual models like DistilBERT in some cases benefit from the introduction of the addition artificially created data samples presented in a foreign language.

Keywords: Data Augmentation, Transformer, Fine-tuning, Machine Translation, DistilBERT, Opus-MT

1 Introduction

Over-paramterised models like neural networks, tend to benefit from large datasets in computer vision [1, 2] and natural language processing fields [3]. The work of Zhu *et al.* [4] and alike suggest that given the size of existing datasets, it appears that the current state-of-the-art will need significant additional data (perhaps exponentially larger sets) to continue producing consistent improvements in performance.

Since the publication of the work of Vaswani *et al.* [5] a substantial improvement has been achieved by scaling up the size of the transformers as well as the size of the training data used for training [6, 7, 8, 9, 3]. GPT-2 [10], one of the largest NLP model was trained on over 8 million documents for a total of 40 GB of text. The creation of public datasets like Pile [11] - an 800 GB text dataset confirms the mentioned growth of data samples size. There also exists a critics for the enormous (in term of parameters) networks.

Work of Bender *et al.* [12] suggests that weighing the environmental and financial costs, investing resources into curating and carefully documenting datasets rather than ingesting everything on the web should be done and encourages the research directions beyond ever larger language models.

In the work of Ciolino *et al.* [13] acknowledged the problem of data-hungry transformer network-based models and suggested a back-translation process of translating text from English to another language and then back to English. In the mentioned work it is concluded that back translation shows a significant ability to move the various Natural language processing (NLP) metrics in many transformer architectures and the text augmentation technique empirically shows back-translation acts as a generalizable strategy.

Motivated by the text augmentation problem, in this work the idea of using text translations as a data augmentation technique is explored. First it is tested if adding an alternative language samples to the training data enhances the performance. Then a technique for fine-tuning multilingual transformers is presented. In contrast to Ciolino *et al.* [13], back-translations is not used and the translations are kept as additional samples in the training data.

2 Datasets Configuration

2.1 Data Samples Selection

Before making any augmentations, it has be made sure that appending different languages to the dataset can improve the metrics. For this purpose a dataset that already has multilingual samples in it has to be used. "The Multilingual Amazon Reviews Corpus" [14] is the dataset that meets the requirements and is therefore the dataset used for the experiments. The dataset's corpus contains reviews in English, Japanese, German, French, Spanish, and Chinese, which were collected between 2015 and 2019. Each record in the dataset contains the review text, the review title, the star rating, an anonymized reviewer ID, an anonymized product ID, and the coarse-grained product category (e.g., 'books', 'appliances', etc.) The corpus is balanced across the 5 possible star ratings, so each rating constitutes 20% of the reviews in each language.

In order for the dataset to be suitable for our experiments, the following changes were made. As the training task was set to classify reviews to posi-

tive and negative ones, one and two star reviews got a “negative” label and four-star and five-star reviews were assigned a “positive” label. Three-star reviews were removed from the dataset for being in between the positive and negative review type. As the dataset was balanced across all the 5 possible ratings, removing one of them did not change the balance.

The next step was selecting the main and alternative languages of the review. English was selected as the main one and German, French, Spanish languages were selected as the alternative ones. We did not use Japanese and Chinese languages due to the alphabet and language structure differences.

As the computational resources were limited (one Nvidia Tesla P100 GPU) and finite time was allotted, the experiment was made doable by capping the maximum reviews count. The final number of samples was selected: 30 000 reviews (15 000 positive, 15 000 negative). To see if the alternative languages had any impact on the overall accuracy, 30 000 reviews in three alternative languages (10 000 for each language) were selected. These samples were selected at random, keeping the same item category distribution. Validation dataset was changed to have only English text (4000 samples), and did the same to the test set (4000 samples).

2.2 Text Translation

Once the dataset was selected, the next step was to make translations. There are two ways to translate text:

- Online cloud solutions (provided by Google, Microsoft, etc.)
- Local neural machine translation models

For this research, models were selected for the price per word efficiency. The exact implementation used was EasyNMT tool - wrapper for neural machine translation models. The Opus-MT [15] model was selected for being the fastest and the most accurate solution to choose from. The translations were applied to the English dataset, translating 30 000 unique reviews.

2.3 Final Datasets

The final data selection resulted in three different datasets: English language (30 000 samples), English and alternative languages (60 000 samples), English language and translated text (60 000 samples). The graphical representation of datasets configuration is given in Fig. 1.




Figure 1: Datasets configuration

3. Training Pipeline

3.1 Making a Fare Comparison

To test the validity of the set hypothesis variability in between training runs has to be accounted. It is done so by averaging the results from multiple training runs with varying hyperparameters as follows:

- Variations of model's hyperparameters:
 - Batch size: 16, 32
 - Max sequence length: 128, 256, 512
- Data sample variations:
 - English dataset:
 - 5 000 samples took three times with three unique random states
 - 30 000 samples
 - English and alternative languages dataset:
 - 5 000 samples sampled three times with three unique random states
 - 30 000 samples sampled three times with three unique random states
 - 60 000 samples
 - English and translations dataset:
 - 5 000 samples took three times with three unique random states
 - 30 000 samples took three times with three unique random states
 - 60 000 samples

In the end 114 training runs with varying hyperparameters were run (each dataset variation was combined with each possible max sequence length and batch size parameter). The training pipeline's scheme is presented in the Fig. 2.




Figure 2: Training pipeline with appended translated text to the dataset

3.2 Transformer Network Architecture

For this experiment a DistilBERT [16] transformer network implementation was selected. The implementation offers a pre-trained multilingual model weights (distilbert-base-multilingual-cased), is a reduced size (40% smaller) of a BERT model but retains 97% of its language understanding capabilities and is 60% faster.

4 Experiment Results

An experimental investigation consisted of evaluation of text augmentation techniques for transformer training. To evaluate the model performance, results were grouped by samples count and the averaged F1 score of each group was calculated. The obtained results are given in Table 1.

Table 1: Experimental investigation's results. Mean F1 score of different group of samples count presented.

Dataset name	Samples count	F1 score (mean)
English dataset	5 000	86.2%
English dataset	30 000	89.2%
English + alternative languages dataset	5 000	84.2%
English + alternative languages dataset	30 000	88.8%
English + alternative languages dataset	60 000	90.8%
English + translations dataset	5 000	84.3%
English + translations dataset	30 000	89.2%
English + translations dataset	60 000	90.6%

The results showed that replacing English language samples with alternative language samples or translation samples did not improve the F1 score. The better results can be seen only by appending (30 000 English samples + 30 000 samples in different language) alternative language or translation samples to the dataset: the data augmentation technique moved the F1 score metric by 1.77% when appending alternative languages to the dataset and by 1.58% when appending translations to the dataset.

The biggest findings were that translated text addition action performs exactly the same as the alternative language addition. A graphical representation of the results is given in Fig. 3. This finding can suggest that if alternative language addition can improve performance of the model, translated text addition can do it too.




Figure 3: F1 score comparison between model trained with English language and translated text and model trained with English and alternative languages text.

5 Limitations of the Study

Model selection. The work focused only on one transformer type network. Bigger (in term of parameter number) or different architecture models could be impacted by the augmented data differently.

Alternative language selection. As the main language of the dataset selected was English and alternative ones Spanish, French and German. In the work of Aharoni *et al.* [17] suggests that different language families are located in a different places of encoded representation's space, so different main and alternative languages combinations could be explored.

Dataset diversity and data sample selection issues. The whole study was done only on one dataset. If a different dataset would be selected, there are multiple factors that could change, thus influencing the results: content of the text (during the experiments only the item reviews were presented in the text), different language groups (see Fig. 4), count of data samples. Furthermore, the selected dataset was not fully explored as only a fraction of the available data was explored.




Figure 4: Visualization of the clustering of the encoded representations of different languages, based on representational similarity. Languages are color-coded by their linguistic family. Product, by, Google AI Blog (<https://ai.googleblog.com/2019/10/exploring-massively-multilingual.html>), 2019

Text translation efficiency and technique variety. Text translations for the data augmentation were translated using only one tool - Opus-MT. The whole text translation process was not efficient and required a lot of computing power. Different types of available translation models should be tested too. Cloud-based services should be also investigated as they could offer a more accurate and faster translation process.

6 Conclusions and Future Work

In this paper data augmentation via text translation technique for the NLP tasks was investigated. The main insight of the experiment is that multilingual transformer architecture based models in some cases can acquire a slight advantage from the addition of alternative language samples. Another insight is that translation models like Opus-MT can perform high quality translations of simple sentences that can be used as an alternative to the generated text by native speakers.

Checking the hypothesis of beneficial data augmentation technique via text translations on one transformer-based models is only the first step. To fully complete the work, all the mentioned shortcomings of the paper would have to be addressed. Coulombe [18] and the works alike suggest that other types of text augmentation like textual noise injection, spelling errors injection, word replacement using a thesaurus, and paraphrases generation using a regular expression, paraphrases generation using syntactic tree transformations can help to overcome the fact of not having enough data, so a combination of multiple augmentation techniques could be also explored.

References

- [1] Chen Sun, Abhinav Shrivastava, Saurabh Singh, and Abhinav Gupta. Revisiting unreasonable effectiveness of data in deep learning era. In Proceedings of the IEEE international conference on computer vision, pages 843–852, 2017.
- [2] Dhruv Mahajan, Ross Girshick, Vignesh Ramanathan, Kaiming He, Manohar Paluri, Yixuan Li, Ashwin Bharambe, and Laurens Van Der Maaten. Exploring the limits of weakly supervised pretraining. In Proceedings of the European Conference on Computer Vision (ECCV), pages 181–196, 2018.
- [3] Jared Kaplan, Sam McCandlish, Tom Henighan, Tom B Brown, Benjamin Chess, Rewon Child, Scott Gray, Alec Radford, Jeffrey Wu, and Dario Amodei. Scaling laws for neural language models. arXiv preprint arXiv:2001.08361, 2020.
- [4] Xiangxin Zhu, Carl Vondrick, Charless C. Fowlkes, and Deva Ramanan. Do We Need More Training Data? International Journal of Computer Vision, 119(1):76–92, August 2016.
- [5] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. arXiv preprint arXiv:1706.03762, 2017.
- [6] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805, 2018.
- [7] VictorSanh, LysandreDebut, JulienChaumond, and ThomasWolf. Distilbert, a distilled version of bert: smaller, faster, cheaper and lighter. arXiv preprint arXiv:1910.01108, 2019.

- [8] Tom B Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, et al. Language models are few-shot learners. arXiv preprint arXiv:2005.14165, 2020.
- [9] Alec Radford, Jeffrey Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are unsupervised multitask learners. OpenAI blog, 1(8):9, 2019.
- [10] Alec Radford, Jeffrey Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are unsupervised multitask learners. 2018.
- [11] Leo Gao, Stella Biderman, Sid Black, Laurence Golding, Travis Hoppe, Charles Foster, Jason Phang, Horace He, Anish Thite, Noa Nabeshima, Shawn Presser, and Connor Leahy. The Pile: An 800GB Dataset of Diverse Text for Language Modeling. arXiv:2101.00027 [cs], December 2020. arXiv: 2101.00027.
- [12] Emily M. Bender, Timnit Gebru, Angelina McMillan-Major, and Shmargaret Shmitchell. On the Dangers of Stochastic Parrots: Can Language Models Be Too Big?; In Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency, FAccT '21, pages 610–623, Virtual Event, Canada, March 2021. Association for Computing Machinery.
- [13] Matthew Ciolino, David Noever, and Josh Kalin. Multilingual Augmenter: The Model Choices. arXiv:2102.09708 [cs], February 2021. arXiv: 2102.09708.
- [14] Phillip Keung, Yichao Lu, György Szarvas, and Noah A. Smith. The multilingual amazon reviews corpus, 2020.
- [15] Jörg Tiedemann and Santhosh Thottingal. OPUS-MT — Building open translation services for the World. In Proceedings of the 22nd Annual Conference of the European Association for Machine Translation (EAMT), Lisbon, Portugal, 2020.
- [16] VictorSanh, LysandreDebut, JulienChaumond, and ThomasWolf. Distilbert, a distilled version of bert: smaller, faster, cheaper and lighter. ArXiv, abs/1910.01108, 2019.
- [17] Ankur Bapna. Exploring Massively Multilingual, Massive Neural Machine Translation. <http://ai.googleblog.com/2019/10/exploring-massively-multilingual.html>. Accessed: 2021-03-28.
- [18] Claude Coulombe. Text Data Augmentation Made Simple By Leveraging NLP Cloud APIs. arXiv:1812.04718 [cs], December 2018. arXiv: 1812.04718.

Pilvo aortos vietos nustatymas krūtinės laštos tomografinėje nuotraukoje

Aušra Šubonienė

Vilniaus universitetas, Duomenų mokslo ir skaitmeninių technologijų institutas,
Akademijos g. 4, LT-08412 Vilnius
ausra.suboniene@mif.vu.lt

Santrauka. Kompiuterinė tomografija, kuri naudojama pilvo aortos aneurizmos diagnostikai ir stebėjimui, leidžia vartotojams stebėti aneurizmos būseną paciento kūno skerspjūvio nuotraukų sekoje. Dažnai kompiuterine tomografija grįžtiems diagnostikos įrankiams aortos vieta turi būti nurodoma vartotojo. Darbe aprašomas pilvo aortos vidinių taškų identifikavimo būdas be pradinės aortos vietos išankstinio žymėjimo. Darbe sprendžiami uždaviniai: medicinos vaizdų analizės metodų apžvalga bei parinkimas, pirminis vaizdų apdorojimas pašalinant triukšmą bei išskiriant vaizde esančių objektų kontūrus, aortos aptikimo metodo pasiūlymas. Taip pat pasiūlomas aortos trombo aptikimo metodas, kuriam vartotojas turi pateikti sekos vaizdą, kuriame trombas yra matomas, bet jam nereikia nurodyti tikslios ar apytikslės trombo vietos.

Raktiniai žodžiai: Pilvo aortos aneurizma, aortos trombas, medicininių vaizdų analizė, kompiuterinė tomografija.

1 Įvadas

Pilvo aortos aneurizma yra lėtinė liga, pasireiškianti pilvo aortos išplatėjimu nusilpus jos sienelei, kurios diagnozei bei stebėsenai naudojama kompiuterinė tomografija. Esant pilvo aortos aneurizmai aortos sienelės išsiplėtimas gali būti 1.5 ar daugiau kartų didesnis už normalų aortos skersmenį [1]. Ligai progresuojant išplatėjusi aortos sienelė pasidengia kraujo komponentų sluoksniu, kuris vėliau padidėja iki trombo. Per daug išsiplėtusi aorta gali spausti aplinkinius organus arba plyšti ir sukelti stiprų kraujavimą. Nesukeliančios simptomų, nedidelės aneurizmos yra tik stebimos, periodiškai atliekant tyrimus. Jei aneurizma didelė, didėja ar sukelia simptomus, siekiant išvengti komplikacijų, ligonis būna operuojamas. Plyšus pilvo aortos aneurizmai mirštamumas siekia 85% to 90% [1]. Tokiu atveju atliekama skubi operacija. Plyšus pilvo aortos aneurizmai ir spėjus atlikti operaciją mirtingu-

mas vis tiek išlieka aukštas, apie 33-36% [2], tačiau jei plyšimo išvengiama atliekant operaciją, mirtingumas ženkliai sumažėja iki 1-6% [3].

Šiuo metu pilvo aortos aneurizmos diagnostikoje naudojami metodai užima daug laiko, nes dažnai analizuojant kompiuterinės tomografijos nuotraukas vartotojai nurodo pradinę vietą ar zoną, kurioje yra aorta kiekvienai kompiuterinės tomografijos nuotraukai vaizdų sekoje. Tuomet sukuriamas trimatis aortos modelis, skirtas aneurizmos diagnostikai. Remiantis kraujagyslių chirurgijos draugijos praktikos gairėmis [4] trūksta standartizavimo, nustatančio ligos progresavimo laipsnį ir greitį, o matuojant aortos skersmenį yra didelės paklaidos, nes skersmuo matuojamas rankiniu būdu pagal tam tikrą vartotojo pasirinktą vaizdą. Naudojant šiuo metu pasiekiamus diagnostikos įrankius gaunamas aortos kontrasto trimatis modelis, tačiau į jį neįtraukiamas trombas. Taip sudėtinga įvertinti aortos išsiplėtimą, nes aortos aneurizmos atveju aortos kontrastinę dalį iš šonų dengia susidaręs trombas, kuris plečia aortos sienelę. Taip pat dabartiniai įrankiai netiksliai segmentuoja aortos vidaus taškus, kuomet nuotraukose matosi iš aortos išsišakojančios arterijos ir venos. Kartais kontrasto segmentacijos metu po išsišakojimo toliau sekami ne aortos, o iš aortos išeinančios arterijos ar kontrastu užsipildžiusios venos taškai. Šio darbo tikslas yra aortos bei trombo vidinių taškų identifikacija naudojant vien tik kompiuterinės tomografijos nuotraukas, vartotojui nurodant pradinę aortos vietos. Tai sutrumpintų laiką, skirtą vieno paciento pilvo aortos aneurizmos diagnostikai, kurį gydytojas skiria vienam pacientui naudojant šiuo metu prieinamus aneurizmos diagnostikos įrankius.

Šiame darbe bus naudojami kompiuterinės tomografijos vaizdai, kuriuose pavaizduota aorta bei ją supantis trombas iki aortos išsišakojimo į dvi klubines arterijas. Siekiama aptikti aortos kontrasto bei aplink aortą esančio trombo vidinius taškus iki aortos išsišakojimo į dvi arterijas, bei atskirti ją nuo aplink arteriją esančių kitų struktūrų, tokių kaip stuburas.

2 Literatūros apžvalga

Medicininį vaizdų analizėje taikomi įvairūs metodai kompiuterinių tyrimų metu gautų vaizdų segmentacijai atlikti- slenksstinės reikšmės taikymas siekiant išskirti sričių kontūrus ar kontūrų aptikimas taikant diferenciaciją, regiono plėtimas, klasterizavimas, klasifikavimas, neuroniniai tinklai ar matematiniai modeliai. Sprendžiant segmentavimo problemas dažnai naudojami ir keli metodai, siekiant pagerinti segmentavimo rezultatus.

Per ilgą laiką buvo pasiūlyta daug slenkstinės reikšmės metodų, naudojamų biomedicininį vaizdų analizėje bei objektų aptikime ([5], [6]). Tarp jų, vienas efektyviausių vaizdų segmentavimo būdų yra entropija pagrįsti optimizavimo metodai, tokie kaip entropijos maksimizavimas (Kapur metodos) [7] ir kryžminės entropijos minimizavimo metodas [8]. Skaičiavimo efektyvumui pagerinti buvo pasiūlyta daugybė daugiapakopio slenkščio uždavinio metodų ([9], [10]), tačiau tinkamai pasirinkti slenkstines vertes yra sudėtinga. Tai ypač aktualu kompiuterinės tomografijos nuotraukose, kur rezultatai vaizduojami skirtingo intensyvumo pilkais pikseliais ir skirtingi organai gali turėti labai panašias pikselių vertes. Todėl medicininių vaizdų segmentavimui kartu su slenkstinės reikšmės metodu dažnai yra taikomi ir kontūrų aptikimu pagrįsti metodai.

Kontūrų aptikimu pagrįsti segmentavimo metodai yra kuriami remiantis greitu paveikslėlio pikselių intensyvumo vertės pasikeitimu, nes viena intensyvumo vertė nepateikia geros informacijos apie kontūrus. Dažnai kontūrų aptikimo būdai išskiria kontūrus, kur pirmoji išvestinė yra didesnė už tam tikrą slenkstį. Gradiento metodai yra dažnas pasirinkimas kontūrų aptikimui ([11], [12]). Kiti naudojami metodai: Roberts [13], Sobel [14], Prewitt ar Canny [15].

Vaizduose radus kontūrus, segmentacija gali būti atliekama taikant regiono plėtimo metodą. Regiono plėtimas yra paprastas regionu grįstas vaizdų segmentavimo metodas, naudojamas medicininių vaizdų analizėje ([16], [17]). Palyginus su pikselių intensyvumo histograma grįstais segmentavimo metodais, kurie nesuteikia erdvinės informacijos, tik pilkos spalvos intensyvumo lygių pasiskirstymą, taikant regiono plėtimo metodą galima tuo pačiu metu pritaikyti ir erdvinius apribojimus. Pagrindinis regiono plėtimo metodu paremtos segmentacijos trūkumas yra tai, kad regiono plėtimui reikalingas teisingai parinktas pradinis taškas, kas dažnai reikalauja vartotojo veiksmų. Šiai problemai spręsti yra sukurti ir automatiniai pradinio taško parinkimo sprendimai, nors dažnai tai sumažina segmentacijos tikslumą, jei metodas nesuteikia vartotojui klaidų taisymo galimybės ([18], [19]).

Kadangi medicinos vaizdų analizėje analizuojamų objektų formos gali būti iš anksto žinomos (vidaus organų formos, šonkaulių išsidėstymas bei jų kontūras, kraujagyslių skerspjūvis, kaulo forma ir pan.), medicinos vaizdų analizėje geri rezultatai pasiekiami ir naudojant modeliais paremtus metodus. Tokių metodų prielaida yra ta, kad analizuojamose struktūrose vyrauja

iš anksto žinomos formos, todėl galima ieškoti tikimybinio modelio, apibūdinančio tą formą ir jos kitimą.

Kompiuterinės tomografijos vaizdų registracijos problema yra sėkmingai sprendžiama taikant matematinius modelius šonkauliais apriboto ploto identifikacijai bei vaizdų registracijai ([20], [21]). Sukurtas modelis leidžia atlikti sėkmingą kompiuterinės tomografijos vaizdų registraciją net esant posūkio kampo, skalės bei postūmio skirtumams tarp analizuojamų vaizdų. Tai yra ypač aktualu, kuomet kompiuterinės tomografijos nuotraukos daromos naudojant skirtingus kompiuterinės tomografijos įrenginius ar pacientui šiek tiek keičiant poziciją tyrimo metu. Toks modelis taip pat gerai veikia nepriklausomai nuo kontrastinės medžiagos naudojimo ar nenaudojimo tyrimuose. Kiti sėkmingi medicininių vaizdų analizės modeliais paremti metodai apima aktyvių kontūrų modelius (angl. active contour model) ir aktyvios formos modelius (ang. active appearance models) [22], [23], [24].

Atliekant aortos ir trombo segmentaciją aukščiau minėti metodai apjungiami kartu, taip sukuriant aukšto patikimumo vartotojui patogų metodą. Tokio metodo pavyzdys yra [25] sukurtas aortos ir trombo segmentavimo metodas, kuris naudoja ribų sklidimo ir aktyvaus kontūro metodus. Sukurtas metodas buvo įvertintas naudojant 40 kompiuterinės tomografijos vaizdų sekų. Buvo pasiekta stipri koreliacija tarp segmentavimo metu gautų rezultatų ir vertinimui naudotų eksperto segmentuotų vaizdų.

3 Duomenys

Analizei buvo naudojami 3 pacientų vaizdai, gauti kompiuterinės tomografijos metu. Kiekvienos kompiuterinės tomografijos nuotraukos dydis 512x512, nuotraukos darytos 2.5 mm intervalu. Nuotraukose ryškiai pavaizduoti šonkauliai, gulimasis paviršius, taip pat aorta bei kitos kraujagyslės, nes tyrimų metu buvo naudota kontrastinė medžiaga.

Kompiuterinės tomografijos metu radiacijos absorbuojamas matuojamas Hounsfield vienetais (HU), kuriuos vėliau reikia perskaičiuoti į pikselių intensyvumą. Taip skirtingo tankio organai, kuriems yra būdingas skirtinga radiacijos sugertis, ekrane atvaizduojami skirtingo intensyvumo pikseliais. Tyrimų metu gauti vaizdai buvo normalizuoti į [0, 255] intervalą, išreiškiant gautus HU į pikselių pilkos spalvos intensyvumą, kuris buvo skaičiuojamas naudojant reikšmes $L=40$ ir $W=350$.

4 Aortos ir trombo aptikimo metodai

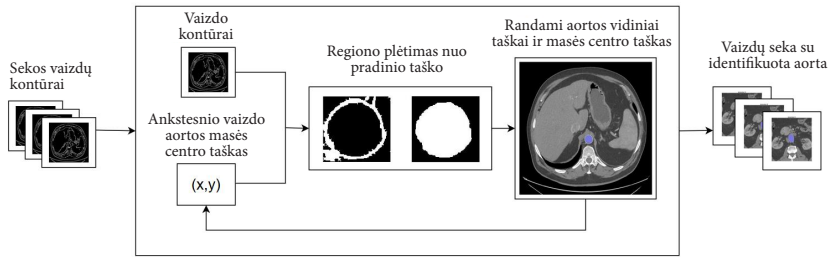
4.1 Aortos aptikimas

Aortos ir trombo aptikimui pritaikomi standartiniai vaizdų apdorojimo metodai, tokie kaip triukšmo vaizde pašalinimas naudojant Gauso, medianos, dvišalį bei nelokaliųjų vidurkių filtrus, kontūrų išskyrimas Sobel metodu, morfologinės operacijos, tokios kaip išplėtimas, erozija bei skeletonizacija. Darbe taip pat naudojami klasterizavimo, Hough transformacijos bei regiono plėtimo metodai.

Aortos identifikavimo problemai spręsti buvo pasirinktas regiono plėtimo metodas. Regiono plėtimui reikalingas gerai parinktas pradinis taškas, priklausantis norimam regionui, nuo kurio regionas ir būtų plečiamas. Siekiant išvengti vartotojo įsikišimo ir aortos vidinius taškus rasti automatiškai, pradinis aortos taškas buvo rastas pasinaudojant nuosekliais kompiuterinės tomografijos duomenimis bei aortos anatomija. Atliekant pradinio taško paiešką analizuojant pirmus 10 sekos vaizdų, kiekviename vaizde naudojant Hough transformaciją apskritimams buvo rasti visi apskritimai, kurių spindulys yra tarp 30 ir 70 taškų. Taip buvo rasti ne tik aortą žymintys apskritimai, bet ir kiti apskritimai, žymintys stuburo slankstelius bei organų apvalias dalis. Šie rasti apskritimai buvo klasterizuojami naudojant aglomeratyvų hierarchinį klasterizavimą. Dėl aortos anatominių savybių aortą žymintys apskritimai sudaro klasterį, turinį didžiausią elementų kiekį.

Ne sekos pradžioje esančiuose vaizduose aortos kontūrai gali būti deformuoti apskritimą šiek tiek suplojant. Taip pat vaizduose tampa matomos iš aortos išeinančios kraujagyslės, kurios iškreipia aortos kontūrą. Dėl šių priežasčių tolimesniuose sekos vaizduose naudojant tik Hough transformaciją kontrastui aptikti būtų gaunami netikslūs rezultatai, nes būtų ieškoma tik apskritimų. Todėl segmentacijai buvo pasirinktas regiono plėtimo metodas nuo pradinio taško. Aukščiau minėtos Hough transformacijos bei klasterizacijos metu gautas taškas buvo naudojamas kaip pradinis regiono plėtimo taškas primam sekos vaizdui.

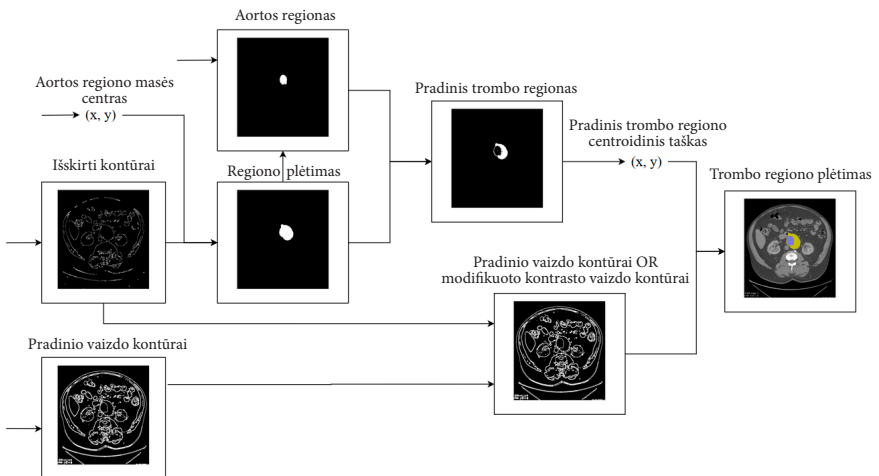
Radus aortos vidinius taškus regiono kontūras buvo patikslintas morfologinėmis operacijomis pašalinant pavienius pikselius, įsiterpusius į regiono vidų. Tuomet buvo randamas segmentuoto regiono masės centro taškas, kuris buvo naudojamas kaip sekančio sekos vaizdo regiono plėtimo pradžios taškas. Aortos kontrasto segmentavimo schema pavaizduota 1 pav.



1 pav. Aortos kontrasto aptikimo schema.

4.2 Trombo aptikimas

Trombo identifikavimui buvo nurodytas pradinis vaizdas, kuriame trombo forma aiškiai matoma. Iš pradžių buvo išskirti aortos vidinius taškus bei aortos trombą atitinkančio regiono bendri kontūrai. Tam pradiniam vaizde buvo pašalintas triukšmas naudojant tuos pačius metodus, kaip ir aortos vidinių taškų išskyrimo atveju. Tuomet buvo pakeistas vaizdo taškų intensyvumo reikšmių pasiskirstymas. Turint anksčiau rastą aortos vidinių taškų matricą jos masės centras buvo naudotas bendram trombo ir aortos regionui rasti regiono plėtimo būdu. Iš šio bendro aortos bei trombo regiono



2 pav. Aortos trombo aptikimo schema.

atėmus trombo regiono taškus gautas pradinis trombą žymintis regionas. Radus šio regiono centroidinį tašką, jis buvo panaudotas kaip pradinis taškas trombui rasti.

Kontūrų taškų matrica trombo radimui buvo gauta sudedant pradinio vaizdo kontūrus, naudotus aortos radimui, bei išryškinto trombo regiono kontūrus. Tai buvo reikalinga trombo regiono uždarymui, nes pradiniuose regionuose dėl aplink aortą ir trombą esančių detalių trombo sienelės ne visada buvo teisingai identifikuojamos ir kontūrai buvo neuždari. Esant neuždariems kontūrams regiono plėtimo būdu trombas nebūtų teisingai identifikuojamas, įtraukiant į analizuojamą regioną didžiąją dalį visų vaizdo taškų.


5 Rezultatai

Pritaikius aortos aptikimo metodą pacientų kompiuterinės tomografijos vaizdų sekoms buvo segmentuotas aortos kontrasto regionas. Sėkmingai identifikavus aortos vidinius taškus pirmame sekos vaizde, sekančiuose vaizduose aortos vidiniai taškai randami naudojant rasto regiono taškus žyminčią binarinę matricą. Kiekvienam n -tajam sekos vaizdai naudojama prieš tai buvusio $n-1$ -ojo vaizdo regiono matrica, kurios svorio centro koordinatės naudojamos kaip n -tojo vaizdo pradinis taškas regiono plėtimo metodui.

Aortos segmentavimo rezultatai pavaizduoti 3 pav. Matoma, kad algoritmas sugebėjo sėkmingai segmentuoti aortos kontrasto regioną vaizdų sekoje iki aortos išsišakojimo. Sėkmingai atpažįstamas ne tik apskritimo formos aortos vaizdas, bet ir deformuotas į ovalą ar vaizdas su matomu aortos išsišakojimu į kitas kraujagysles. Tirtuose vaizduose atliekant aortos segmentavimą atpažintas regionas nenuklysta į šalia esančias besijungiančias kraujagysles.

3 pav. pirmame vaizde aortos taškai aiškiai matomi ir gerai išskirti. Aorta yra beveik taisyklingo apskritimo formos, jai rasti buvo naudojamas Hough transformacijos būdu gautų apskritimų hierarchinės klasterizacijos rezultatai. Dešimtame vaizde aorta yra šiek tiek deformuotos formos, iš šonų suspausta viršutinėje jos dalyje, tačiau taškų radimas taip pat buvo sėkmingas, nes nebuvo reikalaujama, kad artos regionas būtų panašus į taisyklingą apskritimą. Regionui rasti buvo naudotas prieš tai sekoje buvusio 9 vaizdo aortos regioną identifikuojančios matricos masės centras. 20 vaizde matoma aorta bei iš jos išsišakojanti kraujagyslė. Ieškant aortos vidinių taš-


kų kraujagyslės pradžia taip pat buvo identifikuota kaip priklausanti aortai. 30 vaizde matomas aortos linkio skerspjūvis, dėl kurio aortos forma vaizde tampa labai suspausto apskritimo formos, tačiau jos vidinių taškų identifikacija buvo taip pat sėkminga. 40 vaizde pavaizduota aortos vidinis regionas bei jį supančio trombo pradžia, kuris gerai matomas 50 ir 60 vaizduose. Paskutiniame 75 vaizde atvaizduotas sėkmingai atpažintas paskutinis aortos skerspjūvis iki jos išsišakojimo.



3 pav. Aortos kontrasto regiono segmentavimo rezultatai.

Turint anksčiau rastą aortos vidinių taškų matricą jos masės centras buvo naudotas bendram trombo ir aortos regionui rasti regiono plėtimo būdu. Iš šio bendro aortos bei trombo regiono atėmus trombo regiono taškus gautas pradinis trombą žymintis regionas. Radus šio regiono centroidinį tašką, jis buvo panaudotas kaip pradinis taškas trombui rasti.

Kontūrų taškų matrica trombo radimui buvo gauta sudedant pradinio vaizdo kontūrus, naudotus aortos radimui, bei išryškinto trombo regiono kontūrus. Tai buvo reikalinga trombo regiono uždarymui, nes pradiniuose regionuose dėl aplink aortą ir trombą esančių detalių trombo sienelės ne visada buvo teisingai identifikuojamos ir kontūrai buvo neuždari. Esant neuždariems kontūrams regiono plėtimo būdu trombas nebūtų teisingai identifikuojamas, įtraukiant į analizuojamą regioną didžiąją dalį visų vaizdo taškų. Naudojant išryškinto aproksimuoto trombo regiono centroidinį tašką kaip regiono plėtimo pradžios tašką pradinio vaizdo kontūruose buvo gautas rezultatas, pavaizduotas 4 pav. violetine spalva pažymėti rasti aortos vidaus taškai, o geltona – aplink aortos vidų esantis trombas. 4 pav. matomas teisingai segmentuotas aortos kontrasto regionas bei beveik teisingai segmentuotas trombo regionas.



4 pav. Aortos kontrasto ir trombo regiono segmentavimo rezultatas.

Trombo segmentavimo rezultatai nėra tokie tikslūs kaip kontrasto segmentavimo atveju. Segmentuojant trombą jo vaizdo taškų intensyvumas yra labai panašus į kitų šalia esančių anatominių struktūrų, tokių kaip rau-

menys ar kiti organai. Todėl trombo kai kur trombo kraštai nėra pilnai segmentuojami. 4 pav. trombo regiono apačioje aortos sienelė nėra vientisai sujungta su trombu, atsiranda nenatūralus banguotas kraštas. Taip pat trombo regionui jo viršuje priskiriami ne jam priklausantys taškai, kurių intensyvumas yra labai panašus į trombo taškų intensyvumą.

6 Išvados

Šiame darbe buvo sukurtas aortos vidaus taškų identifikavimo būdas, nereikalaujant vartotojo įsikišimo. Aortos centras randamas automatiškai pasinaudojant Hough transformacija apskritimams, hierarchiniu klasterizavimu bei regiono plėtimo metodu. Tokiam aortos aptikimui reikalinga informacija iš kelių vienas po kito sekoje esančių kompiuterinės tomografijos vaizdų, siekiant rasti aortos centrą bei atskirti jį nuo stuburo. Šis aortos radimas yra patogesnis vartotojui, nes nereikalauja jo laiko, žinių ir pastangų sėkmingam aortos identifikavimui, tačiau aortos radimui reikia daugiau duomenų – neužtenka tik pirmo vaizdo kompiuterinės tomografijos vaizdų sekoje.

Taip pat buvo sėkmingai išskirtas aortos trombas, nurodant pradinį vaizdą sekoje, nuo kurio jo reikia ieškoti. Trombui išskirti buvo panaudota informacija apie anksčiau rastą aortos vidaus taškų centrą, todėl trombas taip pat buvo identifikuojamas be vartotojo nurodymo, kuri vaizdo dalis žymi trombą, ar kokiu pikselių intensyvumu trombas yra atvaizduojamas. Tolimesniuose tyrimuose siekiant trombo išskyrimą atlikti be vartotojo įsikišimo (kaip tai buvo daroma aortos vidaus taškų atveju) būtų būtina rasti sprendimą, kaip atpažinti vaizdą, kuriame yra aiškiai matomas trombas. Galbūt tai būtų galima padaryti naudojant pikselių intensyvumo histogramą regionui, esančiam aplink aortos vidinius taškus, ir ieškant vaizdo, kuriame pikseliai būtų aiškiai suskirstyti į vieną ar dvi klases. Aplink aortą esančios kitos struktūros bei vaizdo fonas lemia didelius pikselių intensyvumo skirtumus. Tačiau vaizdo su trombu atveju aplink aortos vidaus taškus tam tikru spinduliu esantys pikseliai turėtų beveik vienodas intensyvumo reikšmes didžiąjai daliai tokių pikselių. Šiam metodui pilnai ištirti reikia atlikti detalesnę analizę, tačiau potencialiai jis leistų identifikuoti trombą kompiuterinės tomografijos vaizdų sekoje be vartotojo įsikišimo.

Tolimesniuose tyrimuose šioje temoje bus siekiama tobulinti aortos vidaus taškų bei aortos trombo aptikimo metodus. Šiame darbe naudoti vaizdai, kuriuose aorta vaizduojama iki išsišakojimo į dvi klubines arterijas. Atei-

tyje planuojama tęsti tyrimus bei identifikuoti aortos vidaus taškus po jos išsišakojimo, bei sukurti trimatę aortos bei joje esančio trombo vizualizaciją.

Literatūra

- [1] Kent, K. C. (2014). Abdominal aortic aneurysms. *New England Journal of Medicine*, 371(22), 2101-2108.
- [2] Ramkumar, N., Suckow, B. D., Arya, S., Sedrakyan, A., Mackenzie, T. A., Goodney, P. P., & Brown, J. R. (2020). Association of Sex With Repair Type and Long-term Mortality in Adults With Abdominal Aortic Aneurysm. *JAMA Network Open*, 3(2), e1921240-e1921240.
- [3] Greenhalgh, R. M., Brown, L. C., Epstein, D., Kwong, G. P. S., Powell, J. T., & Sculpher, M. J. (2005). Endovascular aneurysm repair and outcome in patients unfit for open repair of abdominal aortic aneurysm (EVAR trial 2): randomised controlled trial. *Lancet*, 365(9478), 2187-2192.
- [4] Chaikof, E. L., Dalman, R. L., Eskandari, M. K., Jackson, B. M., Lee, W. A., Mansour, M. A., Mastracci, T.M., Mell, M., Murad, M.H., Nguyen, L.L. and Oderich, G.S. & Starnes, B. W. (2018). The Society for Vascular Surgery practice guidelines on the care of patients with an abdominal aortic aneurysm. *Journal of vascular surgery*, 67(1), 2-77.
- [5] Barbieri, A. L., De Arruda, G. F., Rodrigues, F. A., Bruno, O. M., & da Fontoura Costa, L. An entropy-based approach to automatic image segmentation of satellite images. *Physica A: Statistical Mechanics and its Applications*, 390(3), 512-518, 2011.
- [6] Maitra, M., & Chatterjee, A. A novel technique for multilevel optimal magnetic resonance brain image thresholding using bacterial foraging. *Measurement*, 41(10), 1124-1134, 2008.
- [7] Kapur, J. N., Sahoo, P. K., & Wong, A. K. A new method for gray-level picture thresholding using the entropy of the histogram. *Computer vision, graphics, and image processing*, 29(3), 273-285, 1985.
- [8] Kullback, S. *Information theory and statistics*. Courier Corporation, 1997.
- [9] Sathya, P. D., & Kayalvizhi, R. Optimal multilevel thresholding using bacterial foraging algorithm. *Expert Systems with Applications*, 38(12), 15549-15564, 2011.
- [10] Chander, A., Chatterjee, A., & Siarry, P. A new social and momentum component adaptive PSO algorithm for image segmentation. *Expert Systems with Applications*, 38(5), 4998-5004, 2011.
- [11] Jain, A. K. *Fundamentals of digital image processing*. Englewood Cliffs, NJ: Prentice Hall, 2004.
- [12] Kekre, H. B., Sarode, T. K., & Raul, B. (2008). Color image segmentation using Kekre's algorithm for vector quantization. *International Journal of Computer Science (IJCS)*, 3(4), 287-292.
- [13] Roberts, L. G. *Machine perception of three-dimensional solids* (Doctoral dissertation, Massachusetts Institute of Technology), 1963.
- [14] Gupta, S., & Mazumdar, S. G. Sobel edge detection algorithm. *International journal of computer science and management Research*, 2(2), 1578-1583, 2013.
- [15] Kumar, M., & Saxena, R. Algorithm and technique on various edge detection: A survey. *Signal & Image Processing*, 4(3), 65, 2013.
- [16] Pan, Z., & Lu, J. A Bayes-based region-growing algorithm for medical image segmentation. *Computing in science & Engineering*, 9(4), 32-38, 2007.

- [17] Mubarak, D. M. N., Sathik, M. M., Beevi, S. Z., & Revathy, K. A hybrid region growing algorithm for medical image segmentation. *International Journal of Computer Science & Information Technology*, 4(3), 61, 2012.
- [18] Shan, J., Cheng, H. D., & Wang, Y. A novel automatic seed point selection algorithm for breast ultrasound images. In *2008 19th International Conference on Pattern Recognition* (pp. 1-4). IEEE, 2008.
- [19] Mohammed, M. A., Ghani, M. K. A., Hamed, R. I., Abdullah, M. K., & Ibrahim, D. A. Automatic segmentation and automatic seed point selection of nasopharyngeal carcinoma from microscopy images using region growing based approach. *Journal of Computational Science*, 20, 61-69, 2017.
- [20] Bilinskas, M. J., Dzemyda, G., & Trakymas, M. Feature-Based Registration of Thorax CT Scan Slices. *Informatica*, 28(3), 439-452, 2017.
- [21] Bilinskas, M. J., Dzemyda, G., & Trakymas, M. Approximation of the ribs-bounded contour in a tomography scan slice. *International Journal of Information Technology & Decision Making*, 17(01), 83-102, 2018.
- [22] Geurts, A., Sakas, G., Kuijper, A., Becker, M., & von Landesberger, T. Visual comparison of 3d medical image segmentation algorithms based on statistical shape models. In *International Conference on Digital Human Modeling and Applications in Health, Safety, Ergonomics and Risk Management*, pp. 336-344, Springer, Cham, 2015.
- [23] Schmid, J., Kim, J., & Magnenat-Thalmann, N. Robust statistical shape models for MRI bone segmentation in presence of small field of view. *Medical image analysis*, 15(1), 155-168, 2011.
- [24] Albrecht, T., Lüthi, M., Gerig, T., & Vetter, T. Posterior shape models. *Medical image analysis*, 17(8), 959-973, 2013.
- [25] Lareyre, F., Adam, C., Carrier, M., Dommerc, C., Mialhe, C., & Raffort, J. (2019). A fully automated pipeline for mining abdominal aortic aneurysm using image segmentation. *Scientific reports*, 9(1), 1-14.

Viršelio dailininkė *Jurga Tėvelienė*
Maketuotoja *Vida Vaidakavičienė*

Vilniaus universiteto leidykla
Saulėtekio al. 9, LT-10222 Vilnius
info@leidykla.vu.lt, www.leidykla.vu.lt
Knygos internete: www.knygynas.vu.lt
Mokslo periodikos žurnalai: www.zurnalai.vu.lt

