

INFCON24



Infcon 2024

Zbornik sažetaka znanstvenog skupa
doktorskih studenata informatike



Sveučilište u Rijeci
**Fakultet informatike
i digitalnih tehnologija**





ZBORNIK SAŽETAKA

3. ZNANSTVENI SKUP DOKTORSKIH
STUDENATA INFORMATIKE: INFCON24

Rijeka, studeni 2024.

Impresum

Naslov: ZBORNIK SAŽETAKA - ZNANSTVENI SKUP DOKTORSKIH STUDENATA INFORMATIKE: INFCON24

Nakladnik: Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija

Urednici:
prof. dr. sc. Ana Meštrović
prof. dr. sc. Božidar Kovačić
doc. dr. sc. Slobodan Beliga

Naziv skupa: 3. ZNANSTVENI SKUP DOKTORSKIH STUDENATA INFORMATIKE:
INFCON24

Vrijeme održavanja konferencije: 8. i 9. studenog 2024.

Mjesto održavanja konferencije: Rijeka

Učestalost izdavanja: jednom godišnje

Postavljeno na mrežu: 7. studenog 2024.

Dizajn i oblikovanje: doc. dr. sc. Slobodan Beliga

ISBN: 978-953-7720-84-1 (*online*)

3. ZNANSTVENI SKUP DOKTORSKIH STUDENATA INFORMATIKE: INFCON24

Organizator skupa:

Fakultet informatike i digitalnih tehnologija, Sveučilište u Rijeci

Programski i znanstveni odbor:

prof. dr. sc. Ana Međtrović, Sveučilište u Rijeci, Hrvatska
prof. dr. sc. Patrizia Poščić, Sveučilište u Rijeci, Hrvatska
prof. dr. sc. Bojan Čukić, Sveučilište Sjeverne Karoline, Charlotte SAD
prof. dr. sc. Jordi Gonzalez Sabaté, Autonomno sveučilište u Barceloni, Španjolska
prof. dr. sc. Francesco Guerra, Sveučilište Modena i Reggio Emilia, Italija
prof. dr. sc. Mirjana Kljajić Borštnar, Sveučilište u Mariboru, Slovenija
prof. dr. sc. Ivan Luković, Sveučilište u Beogradu, Srbija
prof. dr. sc. Gorgji Madjarov, Sveučilište sv. Ćirila i Metoda u Skopju, Makedonija
prof. dr. sc. Adrian Muskat, Sveučilište na Malti, Malta
prof. dr. sc. Peter Peer, Sveučilište u Ljubljani, Slovenija
prof. dr. sc. Slobodan Ribarić, Sveučilište u Rijeci, Hrvatska
prof. dr. sc. Marko Robnik Šikonja, Sveučilište u Ljubljani, Slovenija
prof. dr. sc. Jože Rugelj, Sveučilište u Ljubljani, Slovenija
prof. dr. sc. Marcin Woźniak, Silesiansko tehničko sveučilište, Poljska
izv. prof. dr. sc. Marina Ivašić-Kos, Sveučilište u Rijeci, Hrvatska
izv. prof. dr. sc. Innar liiv, Tehničko sveučilište u Tallinu, Estonija
izv. prof. dr. sc. Martina Holenko Dlab, Sveučilište u Rijeci, Hrvatska
doc. dr. sc. Maja Gligora Marković, Sveučilište u Rijeci, Hrvatska
doc. dr. sc. Slobodan Beliga, Sveučilište u Rijeci, Hrvatska
doc. dr. sc. Lucia Načinović Prskalo, Sveučilište u Rijeci, Hrvatska

Organizacijski odbor:

prof. dr. sc. Ana Međtrović, Sveučilište u Rijeci, Hrvatska
doc. dr. sc. Slobodan Beliga, Sveučilište u Rijeci, Hrvatska
doc. dr. sc. Martina Ašenbrener Katić, Sveučilište u Rijeci, Hrvatska
doc. dr. sc. Lucia Načinović Prskalo, Sveučilište u Rijeci, Hrvatska
Marina Žunić, Sveučilište u Rijeci, Hrvatska

Uvodno slovo

Zadovoljstvo nam je bilo organizirati skup doktorskih studenata informatike INFCON24 koji se održao na Fakultetu informatike i digitalnih tehnologija Sveučilišta u Rijeci 8. i 9. studenog 2024. godine.

Posebno nam je drago zbog velikog interesa i odaziva na INFCON24. Skup se održao već treću godinu za redom te u ovogodišnjem, trećem izdanju, bilježi najveći broj radova do sada. Doktorski studenti prijavili su 24 sažetka s pregledom njihovih trenutnih istraživanja vezanih uz doktorski rad. Time smo ispunili očekivanja i uspjeli u ideji da INFCON postane znanstveni skup koji će okupljati doktorske studente informatike i srodnih područja i polja te im omogućiti razmjenu znanja, iskustva i informacija.

Dodatno želimo istaknuti kako je ovogodišnji skup okupio doktorande s različitih institucija pa su na skupu, osim doktorskih studenata FIDIT-a, izlagali svoje radove i doktorandi s Tehničkog fakulteta i Pomorskog fakulteta Sveučilišta u Rijeci, a izlagali su i doktorandi Sveučilišta u Zagrebu s Fakulteta elektrotehnike i računarstva te Fakulteta organizacije i informatike.

Središnja aktivnost skupa INFCON24 jesu izlaganja znanstveno-istraživačkih radova doktorandica i doktoranada. Radovi su prezentirani u šest sekcija, a tematski su obuhvaćena različita područja. Veći broj radova istražuje potencijal i izazove primjene umjetne inteligencije u različitim domenama i zadacima. Prikazana istraživanja obuhvaćaju trenutno vrlo aktualne teme kao što se primjena velikih jezičnih modela, metode za predviđanje u obrazovnim i ekološkim domenama, optimizacija sustava u pomorskom prometu, te pristupi za povećanje privatnosti i sigurnosti u digitalnom okruženju. Značajan broj radova usmjerjen je na istraživanja vezana uz obrazovne inovacije, uključujući korištenje generativne umjetne inteligencije za evaluaciju studentskih rješenja, prilagodbu procesa učenja i poučavanja, te razvoj pedagoških pristupa putem tehnologije metaverzuma. Također su uključeni radovi koji se bave klasifikacijskim modelima za predikciju studentskog uspjeha i primjenom znanja o grafovima za poticanje kritičkog razmišljanja. Zbornik sadrži i istraživanja koja pokrivaju tehničke aspekte umjetne inteligencije, poput evaluacije modela za detekciju i klasifikaciju malih objekata na moru, modeliranja prostornih i vremenskih značajki u prognozi poza i pokreta, te analizu u domeni kompleksnih mreža i kvantne komunikacijske infrastrukture. Pored tehnoloških aplikacija, prisutni su i radovi koji ispituju utjecaj umjetne inteligencije na održivost s naglaskom na predviđanje razine mora i pripremu podataka u kontekstu klimatskih promjena.

Pored izlaganja radova, cilj znanstvenog skupa je umrežavanje i razmjena iskustava među doktorandicama i doktorandima te održavanje predavanja i izlaganja koja se bave temama koje su od interesa za doktorske studente. Istaknuta tema ovogodišnjeg skupa INFCON24 bila je primjena generativne AI u znanstvenim istraživanjima, stoga smo na skupu ugostili dvoje pozvanih predavača.

Zahvaljujemo pozvanim predavačima, izv. prof. dr. sc. Dijani Oreški s Fakulteta organizacije i informatike Sveučilišta u Zagrebu i doc. dr. sc. Marku Horvatu s Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu što su se odazvali našem pozivu i održali pozvana predavanja na temu primjene umjetne inteligencije u znanstveno-istraživačkom radu. U okviru njihovih predavanja dan je pregled suvremenih alata iz područja generativne umjetne inteligencije, razgovornih asistenata (*chatbotova*) koji mogu pomoći u učinkovitijem provođenju istraživanja na doktorskom studiju. Prvi dan skupa, izv. prof. dr. sc. Dijana Oreški s Fakulteta organizacije i

informatike Sveučilišta u Zagrebu održala je pozvano predavanje pod nazivom „*Doktorand pita, AI odgovara: Kako integrirati generativnu umjetnu inteligenciju u istraživački rad?*“. Drugi dan konferencije doc. dr. sc. Marko Horvat s Fakulteta elektrotehnike i računarstva Sveučilišta u Zagrebu održao je pozvano predavanje pod nazivom „*Primjena suvremenih alata umjetne inteligencije u doktorskom istraživanju*“. Također, jedan od važnih aspekata vezan uz umjetnu inteligenciju o kojem se raspravljalo u okviru pozvanih predavanja jesu etička pitanja vezana uz odgovornu primjenu alata umjetne inteligencije u istraživanjima i pisanju znanstvenih radova.

Pored pozvanih predavanja, u okviru skupa INFCON24 održano je i nekoliko izlaganja vezanih uz različite mogućnosti koje Sveučilište u Rijeci nudi doktorskim studentima. Zahvaljujemo svim izlagačima koji su doktorandima prezentirali vrlo korisne informacije. Tako je prvi dan održavanja skupa prof. dr. sc. Igor Prpić, predstojnik Doktorske škole Sveučilišta u Rijeci predstavio aktivnosti Doktorske škole i mogućnosti koje nudi za doktorske studente. Drugi dan održavanja skupa Ivana Dorotić Malić, voditeljica Centra za otvorenu znanost i upravljanje znanstvenim informacijama Sveučilišne knjižnice Rijeka prezentirala je usluge Sveučilišne knjižnice za doktorande. Nakon toga, zanimljiva rasprava bivših i trenutnih doktorskih studenata koji su doktorirali ili će doktorirati u 2024. i 2025. godini, vodila se u okviru panela „*Od ideje do doktorskog rada: priče doktorskih studenata o iskustvima istraživanja i izrade doktorskog rada*“.

Iskreno zahvaljujemo i svim članovima organizacijskog i programskog odbora na pomoći oko organizacije i provedbe skupa INFCON24.

Naposljetku zahvaljujemo prorektoru za znanost i umjetnost Sveučilišta u Rijeci, prof. dr. sc. Gordani Jeleniću i dekanici FIDIT-a, prof. dr. sc. Patriziji Poščić na podršci u organizaciji znanstvenog skupa INFCON24 koju su iskazali tijekom uvodnih govora.

Urednici zbornika:

prof. dr. sc. Ana Meštrović, voditeljica doktorskog studija Informatika

prof. dr. sc. Božidar Kovačić, prodekan za znanost, međunarodnu suradnju i projekte FIDIT-a

doc. dr. sc. Slobodan Beliga

Rijeka, 7. studenog 2024.

Sadržaj

IMPRESUM	I
UVODNO SLOVO	IV

POZVANA PREDAVNJA:

DIJANA OREŠKI:

DOKTORAND PITA, AI ODGOVARA: KAKO INTEGRIRATI GENERATIVNU UMJETNU INTELIGENCIJU U ISTRAŽIVAČKI RAD? 1

MARKO HORVAT:

PRIMJENA SUVREMENIH ALATA UMJETNE INTELIGENCIJE U DOKTORSKOM ISTRAŽIVANJU 2

IZLAGANJA:

KARLO BABIĆ:

PIRAMIDALNO REKURZIVNO REPREZENTIRANJE TEKSTA: EVALUACIJA NA GRAMATICI HRVATSKOG JEZIKA 4

BARTOL BORAS:

PRIMJENA VELIKIH JEZIČNIH MODELA U OBRAZOVANJU 6

KARLO CIMERA:

MODEL UNAPRIJEĐENJA OBALNO LINIJSKOG POMORSKOG PUTNIČKOG PROMETA SUSTAVOM ELEKTRIFIKACIJE S ASPEKTA

RAZVOJA LUČKIH SUSTAVA I OBALNOGA PODRUČJA 8

VANJA ČOTIĆ POTURIĆ:

DIZAJNIRANJE KLASIFIKACIJSKOG PREDIKTIVNOG MODELA ZA RANU PREDIKCIJU STUDENTSKEGA (NE)USPJEHA 10

VLATKA DAVIDOVIĆ:

REPORT ON COLLECTING DATASETS FOR CROATIAN ABSTRACTIVE SUMMARIZATION ON TRANSFORMER ARCHITECTURE 12

MINKI KANG:

INTRODUCING THE MAX PLANCK COMPUTING AND DATA FACILITY'S HPC SYSTEM AND MINIMIZING MPS INTERFERENCE IN GPU INFERENCE SERVERS THROUGH ADAPTIVE SCHEDULING 15

MARIJA KUŠTELEGA:

PREGLED DOSADAŠNJIH ISTRAŽIVANJA O UPOTREBLIVOJ PRIVATNOSTI I SIGURNOSTI U DIZJNU INFORMATIČKIH USLUGA 18

DEJAN LJUBOBROTOVIĆ:

EVALUACIJA MODELA ZA DUBINSKO UČENJE NA TABLIČnim PODACIMA ZA PREDVIĐANJE ZRELOSTI BRESKVI KORIŠTENJEM

MODEL TABNET, SAINT I NODE: KOMPARATIVNA ANALIZA 21

ANNA MARIA MIHEL:

EVALUACIJA TOČNOSTI PREDVIĐANJA UZVODNOG VODOSTAJA PRIOBALNE RIJEKE DO 24 SATA UNAPRIJED KORIŠTENJEM

KOMBINIRANOG PRISTUPA INŽENJERINGA ZNAČAJKI I HIBRIDNOG MODELA 23

IVONA MILINoviĆ:

PREDVIĐANJE PODIZanja RAZINE MORA U SVRHU ODRŽIVOG UPRAVLJANJA OBALnim PODRUČJEM PRIMJENOM UMJETNE INTELIGENCIJE 26

ANA PASARIĆ:

EMPOWERING STUDENTS WITH KNOWLEDGE GRAPHS: A NEW APPROACH TO FACT-CHECKING AND RESEARCH 28

Goran PAULIN:

SUSTAV ZA GENERIRANJE I PODEŠAVANJE ADAPTIVNIH MARITIVNIH SINTSETOVA ZA KLASIFIKACIJU STANJA MORA I DETEKCIJU

MALIH OBJEKATA NA MORU 31

MILAN PETROVIĆ:

UPOTREBA KOMPLEKSNIH MREŽA ZA MJERENJE UTJECAJA IZOLACIJE NA PROMJENE U MREŽAMA SOCIJALNE INTERAKCIJE

DROSOPHILE MELANOGASTER 33

ANDRIJA POLEKSIĆ:

PRIPREMA SKUPA PODATAKA ZA EKSTRAKCIJU RELACIJA U DOMENI KLIMATSkih PROMJENA 35

MARINA RAUKER KOCH:

RELACIJSKA BAZA PODATAKA KAO ELEMENT KONCEPTUALNOG OKVIRA NODE OF KNOWLEDGE (NOK) 38

EMA SMOLIĆ:	
GENERATIVNA UI TEMELJENA NA VELIKIM JEZIČNIM MODELIMA I EVALUACIJA STUDENTSKOG KODA: KVALITATIVNA I KVANTITATIVNA ANALIZA.....	40
ROMEO ŠAJINA:	
MODELING SPATIAL AND TEMPORAL FEATURES IN MULTI-PERSON POSE FORECASTING.....	43
ŽAKLINA ŠUPICA:	
KVANTNA KOMUNIKACIJSKA INFRASTRUKTURA	46
IVAN TUDOR:	
PERSONALIZACIJA PROCESA UČENJA I POUČAVANJA U SREDNJOŠKOLSKOM I VISOKOM OBRAZOVANJU POTPOMOZNUTO TEHNOLOGIJOM: SUSTAVNI PREGLED LITERATURE	48
MATEA TURALIJA REŠČIĆ:	
ANALIZA MOGUĆNOSTI PROŠIRENJA BRZE VIŠEPOLNE METODE ZA NEKOCKASTE SIMULACIJSKE KUTIJE	50
TEDO VRBANEC:	
ODREĐIVANJE OPTIMALNE DIMENZIJE VEKTORSKE REPREZENTACIJE TEKSTA U ZADATKU DETEKCIJE PARAFAZIRANJA	52
ANA VRCELIJ BOŽIĆ:	
ANALIZA ELEMENATA IGRIFIKACIJE U DIGITALnim OBRAZOVnim ALATIMA PRIMJENOM KLASIFIKACIJE ZA IGRIFIKACIJU	54
MARINA ŽUNIĆ:	
PEDAGOŠKI PRISTUPI ZA NEPREKINUTO UČENJE PUTEM TEHNOLOGIJE METAVERZUMA	56
LUCIJA ŽUŽIĆ:	
PREDVIĐANJE PUTANJE OSOBNIH PLOVILA KORIŠTENjem MODELA TEMELJENIH NA NEURONSKIM MREŽAMA S POV RATNOM VEZOM	58



POZVANA PREDAVANJA

Izv. prof. dr. sc. Dijana Oreški
Sveučilište u Zagrebu, Fakultet organizacije i informatike
Laboratorij za rudarenje podataka i inteligentne sustave
Pavlinska 2, 42000 Varaždin, Hrvatska
dijana.oreski@foi.hr



Doktorand pita, AI odgovara: Kako integrirati generativnu umjetnu inteligenciju u istraživački rad?

Znanstveno istraživanje sastoji se od nekoliko koraka, a generativna umjetna inteligencija (AI) može pružiti podršku u svakom od njih. U fazi postavljanja istraživačkog pitanja i formuliranja hipoteze, AI pomaže u analizi postojeće literature i generiranju novih ideja. Tijekom pregleda literature, umjetna inteligencija ubrzava pronalaženje relevantnih izvora i sintezu informacija. U dizajnu istraživanja, AI može predložiti metodološke pristupe. Prilikom prikupljanja podataka, AI doprinosi automatizaciji i organizaciji informacija, dok u fazi analize omogućava bržu obradu i interpretaciju rezultata. Tijekom pisanja i prezentacije rezultata, umjetna inteligencija pomaže pri strukturiranju lekturi teksta. Na kraju, AI omogućuje usklađivanje sa zahtjevima publikacija, čime se povećava učinkovitost cijelog procesa istraživanja.

Stoga su ciljevi ovog izlaganja: (i) upoznati studente s alatima generativne umjetne inteligencije koji se mogu primijeniti u znanstvenom istraživanju, (ii) naučiti inženjerstvo upita.

Inženjerstvo upita predstavlja ključnu vještina u radu s generativnom umjetnom inteligencijom, osobito u kontekstu znanstvenog istraživanja. Radi se o procesu oblikovanja preciznih i ciljano postavljenih upita kako bi se dobili što relevantniji odgovori od AI alata. Kvalitetan upit značajno povećava korisnost i kvalitetu rezultata.

Doc. dr. sc. Marko Horvat
Sveučilište u Zagrebu, Fakultet elektrotehnike i Računarstva
Zavod za primijenjeno računarstvo
Unska 3, 10000 Zagreb, Hrvatska
marko.horvat3@fer.hr



Primjena suvremenih alata umjetne inteligencije u doktorskom istraživanju

Svjedoci smo brzog razvoja tehnologija umjetne inteligencije (engl. *Artificial Intelligence*) koje koriste velike skupove podataka općeg znanja i omogućuju širok spektar primjena uz jednostavnost korištenja i otvorenost pristupa. Štoviše, gotovo svakodnevno razvijaju se novi alati koji pružaju brojne mogućnosti za napredno oblikovanje teksta na više prirodnih jezika, automatizirano generiranje multimedije, obradu djelomično strukturiranih ili nestrukturiranih podataka, vizualizaciju, statističku analizu rezultata istraživanja i druge zadatke čije je uspješno rješavanje prethodno od korisnika zahtijevalo bitno višu razinu stručnosti i ovladavanja područjem problema. Cilj predavanja je pružiti doktorskim studentima uvid u primjenu suvremenih alata umjetne inteligencije, posebice razgovornih agenata (engl. *Chatbots*) temeljenih na velikim jezičnim modelima (engl. *Large Language Models*, LLM), u akademskom okruženju te ih potaknuti na učinkovitiju provedbu aktivnosti tijekom doktorskih istraživanja. U praktičnom dijelu predavanja prikazati će se neki alati te primjeri njihovog korištenja u zadacima s kojima se doktorandi najčešće tijekom susreću tijekom izrade doktorske disertacije. Posebna pažnja posvetit će se pravnim aspektima autorstva i izrade izvornih doprinosa te etičkoj odgovornosti za rezultate dobivene korištenjem tehnologija umjetne inteligencije.



IZLAGANJA

Karlo Babić

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
karlo.babic@inf.uniri.hr

Piramidalno rekurzivno reprezentiranje teksta: evaluacija na gramatici hrvatskog jezika

Piramidalno rekurzivno učenje (PyRv) je metoda specifično osmišljena za treniranje neuronskih mreža kako bi predstavljale tekst, pri čemu se konstruira piramidalna hijerarhija reprezentacija. U ovoj hijerarhiji svaka razina obuhvaća sve apstraktnije reprezentacije ulaznog teksta, počevši od znakova ili podriječi, a zatim se prelazi na riječi, fraze, rečenice, te potencijalno i na odlomke. Ovaj strukturirani proces rezultira detaljnom višerazinskom reprezentacijom teksta.

Na svakoj razini piramide, PyRv kodira uzastopne parove reprezentacija u apstraktnije, višerazinske reprezentacije. Te nove reprezentacije služe dvostrukoj svrsi: prvo, koriste se za rekonstrukciju izvornog para reprezentacija iz kojih su nastale (autoenkoderska glava), i drugo, koriste se za predikciju reprezentacija koje se nalaze lijevo i desno od kodiranog para (autoregresijska glava). Ovaj proces osigurava da model, osim što uči kompaktne reprezentacije, ujedno i hvata kontekstualne odnose između kodiranih parova.

Rekurzivni proces kodiranja može započeti sa znakovima ili podriječima, koje se zatim rekurzivno kombiniraju u pojedinačne, ujedinjene reprezentacije. Kontinuiranim kodiranjem uzastopnih parova reprezentacija, model konstruira piramidu reprezentacija podriječi za svaku pojedinačnu riječ. Kada se dosegne razina riječi, model počinje sparivati i kodirati te reprezentacije riječi u jedinstvenu hijerarhijsku piramidu frazalnih reprezentacija, nastavljajući ovaj proces sve dok se ne dosegne vrh piramide ili unaprijed definirana maksimalna dubina.

Predloženi pristup temeljen na piramidalnom rekurzivnom učenju integrira nekoliko ključnih svojstava koja se smatraju vrlo poželjnima u zadatu reprezentacije teksta. Ova ključna svojstva uključuju hijerarhijsku reprezentaciju, kompozicionalnost reprezentacija, dekodabilnost reprezentacija i sposobnost učenja bez nadzora.

Prvo od tih svojstava, hijerarhijska reprezentacija, omogućuje modelu da tekst predstavlja na više razina granularnosti, od pojedinačnih znakova ili podriječi do čitavih fraza ili rečenica. Ova je karakteristika osobito korisna za jezike koji pokazuju složene morfološke strukture, fraze promjenjive duljine ili složenice. Omogućujući hijerarhijske reprezentacije, model olakšava finiju i detaljniju analizu teksta. Rekurzivni modeli obično dijele ovo svojstvo, dok ga nerekurzivni jezični modeli najčešće nemaju.

Druge svojstva, kompozicionalnost reprezentacija, podrazumijeva da se više pojedinačnih reprezentacija može kombinirati u kohezivnu, ujedinjenu reprezentaciju. Model s ovom sposobnošću može obuhvatiti značenje složenijeg teksta kombiniranjem značenja njegovih sastavnih dijelova na strukturiran i semantički koherentan način. To omogućuje modelu da učinkovitije i brže uči, osobito kada radi s ograničenim ili rijetkim podacima.

Treće svojstvo, dekodabilnost reprezentacija, odnosi se na sposobnost dekodiranja ili rekonstrukcije reprezentacije natrag u tekst iz kojeg je izvorno izvedena. Ova sposobnost služi kao važna mjera kvalitete tekstualnih reprezentacija, omogućujući istraživačima da bolje razumiju i interpretiraju informacije koje je model naučio. Dekodabilnost je uobičajeno svojstvo autoenkodera, kao što je vidljivo u modelima poput [1].

Četvrto svojstvo, učenje bez nadzora, omogućuje modelu da se trenira bez potrebe za velikim, označenim skupovima podataka. Umjesto toga, model uči predviđanjem susjednih reprezentacija i dekodiranjem prethodno kodiranih reprezentacija i nema potrebu za stabla parsiranja poput većine rekurzivnih modela. Nasuprot tome, mnogi drugi rekurzivni modeli, poput RNTN [2] i Tree-LSTM [3], oslanjaju se na stabla parsiranja tijekom treniranja.

U ovom radu naglašavamo važnost kompozicionalnosti reprezentacija, s posebnim fokusom na kombiniranje više reprezentacija riječi u jednu, ujedinjenu reprezentaciju.

Reprezentacije riječi, poput onih koje generira fastText [4], često se koriste za predstavljanje pojedinačnih riječi. Za predstavljanje sekvenci više riječi, često se koriste osnovne tehnike poput izračunavanja prosječnih vrijednosti (centroid). Međutim, takvi pristupi imaju značajna ograničenja. Kada se računa prosjek reprezentacija riječi (na primjer, uzimanjem srednje vrijednosti vektora više riječi), ključne informacije, poput redoslijeda riječi, često se gube.

Kako bi se prevladala ta ograničenja, istražena je primjena PyRv-a za kombiniranje više reprezentacija riječi u jednu, ujedinjenu reprezentaciju. Za razliku od našeg prethodnog rada na PyRv-u [5], gdje proces rekurzije započinje na razini podriječi ili tokena, u ovom radu se započinje s reprezentacijama riječi koje proizvodi fastText, pružajući drugačiju polaznu točku za rekurzivni proces.

Predloženi pristup je evaluiran na dva zadatka: označavanju univerzalnih vrsta riječi (UPOS) i označavanju univerzalnih zavisnih odnosa (DEPREL). UPOS označke predstavljaju osnovne gramatičke kategorije kao što su imenice, glagoli i pridjevi, pružajući osnovne sintaktičke informacije o riječima. DEPREL bilježi sintaktičke odnose između riječi unutar rečenice, ističući zavisnosti kao što su subjekti, objekti i atributi.

Ključne riječi – reprezentiranje teksta, rekurzivna neuronska mreža, hrvatski jezik, kompozicija

Literatura

- [1] J. Li, M.-T. Luong, and D. Jurafsky, “A hierarchical neural autoencoder for paragraphs and documents,” arXiv:1506.01057, 2015.
- [2] R. Socher et al., “Recursive deep models for semantic compositionality over a sentiment treebank,” in Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, Seattle, Washington, USA, 2013, pp. 1631–1642.
- [3] K. S. Tai, R. Socher, and C. D. Manning, “Improved semantic representations from tree-structured long short-term memory networks,” arXiv:1503.00075, 2015.
- [4] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov, “Enriching word vectors with subword information,” Transactions Assoc. Comput. Linguist., vol. 5, pp. 135–146, 2017.
- [5] K. Babić and A. Meštrović, “Recursively Autoregressive Autoencoder for Pyramidal Text Representation,” IEEE Access, vol. 12, pp. 71361–71370, 2024.

Bartol Boras

Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska
bartol.boras@fer.unizg.hr

Primjena velikih jezičnih modela u obrazovanju

U ovom proširenom sažetku opisat će se istraživanje provedeno u svrhu mojeg polaganja kvalifikacijskog doktorskog ispita na Fakultetu elektrotehnike i računarstva u akademskoj godini 2023/2024 [1]. Navedeni rad napisan je s idejom istraživanja korištenja velikih jezičnih modela u obrazovanju kako bi se dao uvid u trenutno stanje kao i dale smjernice za budući razvoj tehnologije u tom području.

Budući da su sposobni riješiti širok raspon kompleksnih problema, veliki jezični modeli postaju sve više integrirani u svakodnevne životne aktivnosti. Analiziramo li njihovu primjenu u obrazovnom kontekstu, možemo primijetiti dvije perspektive: učeničku i nastavničku. Učenicima mogu služiti kao podrška učenju, pomoći pri rješavanju zadataka i sl., dok nastavnicima mogu olakšati provedbu nastave generirajući i ocjenjujući ispite i vježbe, pa čak i rješavati administrativne poslove. Budući da su veliki jezični modeli složena tehnologija koju pomno treba proučiti prije integriranja u obrazovane procese, nalaže se potreba za istraživanjem njihove primjene u istima. Farrelly i Baker [2] proveli su slično istraživanje u kojem se naglasak stavlja na pregled literature vezane za korištenje generativne umjetne inteligencije u visokom obrazovanju, dok se istraživanje koje su proveli Yan i ostali [3] osvrće na primjenu velikih jezičnih modela u obrazovanju, kao i na praktičke i etičke izazove koji se u tom procesu pojavljuju.

Prvo pitanje na koje ovo istraživanje nastoji odgovoriti je „U kojim su obrazovnim domenama veliki jezični modeli najviše korišteni te gdje su pokazali najbolje rezultate?“ S pomoću te analize uviđamo koja područja zaostaju ili daju lošije rezultate u odnosu na druga čime dobivamo temelj razvoja strategije za buduća istraživanja. Drugo pitanje je: „Koji su veliki jezični modeli većinom korišteni?“ Različiti modeli imaju različite sposobnosti, kao i ograničenja. Analizirajući ih možemo dobiti uvid koji modeli su najpopularniji te ocijeniti njihove performanse. Treće pitanje dotiče se integriranosti: „U kojoj mjeri su ti jezični modeli bili potpuno integrirani u obrazovne sustave u odnosu na one koji su testirani u izoliranim okruženjima poput web stranica?“ Integrirana rješenja mogu dati potreban kontekst pri korištenju te su vjerojatno jednostavnija za korištenje s obzirom na to da predstavljaju napredak postojećih sustava ili aplikacija.

Kako bi se dao odgovor na ova pitanja, pretražena je Scopus baza podataka. Korišten je sljedeći upit: TITLE-ABS-KEY(("generative artificial intelligence" OR "generative AI" OR "GAI" OR "LLM" OR "LLMs" OR "Large Language Model" OR "Large Language Models") AND education). Pretraživanje je provedeno u travnju 2024. godine te je ograničeno na znanstvene članke napisane na engleskom jeziku te objavljene između 2022. i 2024. godine u temama „Computer Science“ ili „Engineering“. Rezultat pretraživanja bilo je 210 dokumenata koji su nakon dvije iteracije pregledavanja rezultirali s 37 dokumenata odabranih za detaljan pregled u ovom radu.

Odabrani radovi podijeljeni su i opisani u 5 kategorija: Ocjenjivanje, Rješavanje ispita, Pomoć pri učenju, Pomoć pri učenju s dvije grupe, Pomoć pri podučavanju. Ukupno 17 članaka fokusiralo se na pomoć nastavnicima pri podučavanju, dok se 13 članaka fokusiralo na pomoć učenicima pri učenju. Ovo nalaže da se obje ranije spomenute perspektive korištenja velikih jezičnih modela u obrazovanju razvijaju relativno jednakom te da niti jedna ne kaska za drugom. Iako uspješnost rezultata ovisi o naprednosti modela, javno dostupni modeli imaju mogućnost rješavanja studentskih ispita za prolaznu ocjenu

što predstavlja rizik za akademski integritet. Što se tiče ocjenjivanja studentskih rješenja, jezični modeli bi se trenutno trebali koristiti kao potpora ljudskim ocjenjivačima umjesto u potpunosti preuzeti proces ocjenjivanja. Radovi koji su opisivali pomoć pri učenju i podučavanju u velikoj mjeri su rezultirali pozitivnim ishodima. Kroz sva istraživanja korišteno je ukupno 9 različitih velikih jezičnih modela, uz napomenu da su neka istraživanja koristila više modela. Samo jednom se razvio „prilagođeni“ model, dok su se u svim ostalim slučajevima koristili „komercijalni“ jezični modeli. Najpopularniji model bio je OpenAI-jev GPT (u različitim verzijama) koji je u sumi korišten u 84% slučajeva. Jasno se prikazalo i ograničeno korištenje modela koji generiraju multimediju poput slika, videa i zvuka budući da su se takvi modeli (*Stable Diffusion* i *Midjourney*) koristili u samo dva slučaja. Pristup integracije modela u postojeće sustave implementiran je u samo 6 od 37 članaka (16 %) – jako malen udio, ali taj postotak nije iznenađujući s obzirom na novitet područja. Od navedenih 6 članaka, u 4 se integracija modela koristi za pomoć pri podučavanju.

Veliki jezični modeli imaju značajan potencijal za korištenje kao virtualna podrška učenicima u učenju i rješavanju zadataka. Slične tehnike također mogu olakšati proces podučavanja, možda čak i u većoj mjeri nego pomoć studentima, budući da se kroz članke prikazuju različite primjene velikih jezičnih modela u ovom području - od generiranja kurikuluma i nastavnih materijala do pomaganja u administrativnim zadacima. Međutim, potreban je oprez pri korištenju velikih jezičnih modela za ocjenjivanje studentskih radova budući da trenutne preporuke sugeriraju da ovaj proces još ne bi trebao biti u potpunosti povjeren tehnologiji.

Ključne riječi – pregled literature, veliki jezični modeli, generativna umjetna inteligencija, obrazovanje, tehnologijom podržano učenje

Literatura

- [1] B. Boras, “Exploring the application of large language models in educational settings” 2024.
- [2] T. Farrelly and N. Baker, “Generative Artificial Intelligence: Implications and Considerations for Higher Education Practice,” Educ. Sci., vol. 13, no. 11, Art. no. 11, Nov. 2023, doi: 10.3390/educsci13111109.
- [3] L. Yan et al., “Practical and ethical challenges of large language models in education: A systematic scoping review,” Br. J. Educ. Technol., vol. 55, no. 1, pp. 90–112, 2024, doi: 10.1111/bjet.13370.

Karlo Cimera

Sveučilište u Rijeci, Pomorski fakultet, Rijeka, Hrvatska

karlo.cimera@yahoo.com

Model unaprjeđenja obalno linijskog pomorskog putničkog prometa sustavom elektrifikacije s aspekta razvoja lučkih sustava i obalnoga područja

Predloženo istraživanje orijentirano je na područje unaprjeđenja sustava organizacije prometa i učinkovitosti linijskog brodarstva u Republici Hrvatskoj kroz sustav elektrifikacije, a istovremeno znanstveno obrađujući i vrednujući obje relevantne perspektive – kako brodsku, tako i lučku perspektivu ukupnog razvoja pomorsko-putničkog linijskog prometa i integralnog upravljanja obalnim područjem. Rezultat istraživanja je u prvom redu usmjeren na organizacijske, tehnološke, ekonomске, ekološke i prometne efekte uvođenja električnog pogona u redovne brodske linije, uzimajući u obzir postojeći promet i lučku infrastrukturu luka ticanja istih brodova. Navedeno područje istraživanja je odabранo radi utvrđivanja mogućnosti elektrifikacije linija, tj. utjecaj elektrifikacije na sigurnost, ekonomičnost, učinkovitost i raspoloživost linija. Glavni cilj je predložiti model koji bi doprinio smanjenju operativnih troškova kao i troškova infrastrukture, ali bez narušavanja učinkovitosti i sigurnosti prometa.

Razvoj i tehnologija pogona u prometu raste strahovitom brzinom zadnjih pet godina. U obalno linijskom pomorsko putničkom prometu rezultat ovog istraživanja je dokazati opći boljšak u obavljanju tranzita, kako kvalitetom, tako i brzinom, te utjecajem na okoliš. Istraživanje sam započeo jer sam od vremena srednjoškolskog obrazovanja, živeći na otoku, svakodnevno putovao brodskom linijom i uviđao mogućnosti napretka. Završetkom diplomskog studija, upisom u doktorski studij imao sam viziju istraživanja ove tematike koja prati suvremenu tehnologiju transporta. Evidentan je manjak uključenosti digitalne tehnologije u postojeće sisteme. Primjerice kod „park & ride“ i „taxi“ aplikacija (cestovni promet) imamo na aplikaciji mnogo korisnih podataka, dok kod pomorsko putničkog prometa u Republici Hrvatskoj su takva ista pitanja, ako su uopće dijelom riješena, riješena bez adekvatne primjene informacijskih tehnologija [3].

Metode koje su korištene pri istraživanju su sljedeće:

- metoda deskripcije pri opisivanju činjenica, procesa te empirijskih potvrđivanja njihova odnosa i veza u skladu s teorijskim spoznajama literature,
- metoda indukcije u svrhu zaključivanja, gdje će se na temelju pojedinačnih činjenica utvrditi opći sud,
- deduktivna metoda kod izvođenja zaključaka, kada se iz općih stavova izvode pojedinačni zaključci,
- metoda analize koristi će se kod složenoga predmeta istraživanja ovoga rada, raščlanjivanjem na sastavne dijelove i elemente, pri interpretaciji rezultata istraživanja,
- metoda sinteze kod kvalitetnoga zaključivanja dijelova složenijih pojava, osobito u elaboraciji teorijskih aspekata poduzetničke orientacije, tržišne orientacije, orientacije na zamjenu sustava postojećim pogonom, inovativnosti te uspješnosti poslovanja te
- metode generalizacije i komparacije tijekom pretraživanja elektronički dostupnih baza podataka, kako bi se osigurao pristup mogućim novijim svjetskim studijama povezanim s predmetom istraživanja.

Analizom dosadašnje literature očita je potreba za stvaranjem preduvjeta za dugoročnu održivost sustava obalnog linijskog pomorskoga putničkog prometa kao krajnjeg cilja ovog istraživanja, slijedom čega se može istaknuti sljedeće [1-2]:

- Autori ističu važnost prometne povezanosti otoka s kopnom i otoka međusobno napominjući da postojeći sustav nije funkcionalan.
- Autori upućuju na važnost pomorskoga putničkog prometa u Europi kako bi se odredila njegova glavna obilježja.
- Autori analiziraju stanje i ulogu morskog putničkog brodarstva u gospodarstvu Hrvatske zaključujući da postoji snažna povezanost turizma i pomorskoga putničkog prometa koji je moguće ostvariti modernizacijom.

Osim ulaganja u nove brodove i razvoj luka i lučke infrastrukture, što su dugoročni planovi, nužna je racionalizacija sustava koja bi se postigla moderniziranjem pogona plovila. Navedeno se odnosi na nadogradnju (osuvremenjivanje) postojeće i gradnju nove lučke infrastrukture za pružanje lučkih usluga povezanih s modernizacijom obalnoga linijskoga pomorskoga prijevoza.

Model unaprjeđenja ne smije sniziti kvalitetu usluge niti dovesti u pitanje sigurnost plovidbe ili pak dovesti do upitnosti brodske povezanosti. Osnovna funkcija unaprjeđenja jest dugoročna održivost sustava s ekološkog, društvenog i ekonomskog aspekta, s naglaskom na ekološki prihvativim rješenjima [4]. Stoga je krajnji cilj istraživanja analizirati sustav obalnoga linijskoga pomorskoga putničkog prometa i odrediti model unaprjeđenja u pogledu ekonomike i ekologije brodarstva.

Ključne riječi – linija, promet, brod, luka, elektrifikacija

Literatura

- [1] Stupalo, V., Jolić, N., Žgaljić, D., 2021., „Maritime cabotage of passenger liner transport in Croatia after EU accession“, Book of Preceedings, 4th International Maritime Science Conference (IMSC 2004), 16-17 June 2012, Faculty of Maritime Studies, Split, p.8-19
- [2] Deluka-Tibljaš, A., Karleuša, B., Dragičević, N., 2013, „Pregled primjene metode višekriterijske analize pri donošenju odluka o prometnoj infrastrukturi“, Građevinar, Z.
- [3] Strategija prometnog razvijanja Republike Hrvatske (2017.-2030.), Ministarstvo mora, prometa i infrastrukture
- [4] Strategija pomorskog razvijanja i integralne pomorske politike Republike Hrvatske za razdoblje od 2014. do 2020. godine, Ministarstvo mora, prometa i infrastrukture

Vanja Čotić Poturić

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
vcotic@uniri.hr

Dizajniranje klasifikacijskog prediktivnog modela za ranu predikciju studentskog (ne)uspjeha

U okviru istraživanja za potrebe izrade doktorske disertacije namjerava se razviti informacijski sustav namijenjen podršci obrazovnog sustava, posebice predmeta u STEM području. Osnovna funkcionalnost informacijskog sustava bila bi informiranje studenta o riziku neuspjeha baziranog na dostupnim obrazovnim podacima, kao i slanje povratnih informacija o individualiziranoj optimalnoj strategiji za umanjenje tog rizika.

Cilj prvog dijela istraživanja dizajniranje je prediktivnog klasifikacijskog modela u formi bodovnog sustava na temelju kojeg će se vršiti predikcija (ne)uspjeha studenata u svakom od 15 tjedana nastave. Definirana su tri istraživačka pitanja. Da bi se odgovorilo na postavljena istraživačka pitanja provedeni su slijedeći postupci:

- definiranje zavisne varijable,
- prikupljanje i uređivanje podataka iz e-kolegija te definiranje nezavisnih varijabli,
- određivanje relevantnih prediktora,
- dizajniranje bodovnog sustava,
- evaluacija bodovnog sustava.

U nastavku se navode metode i rezultati svakog od navedenih postupaka.

Na kraju akademske godine 2023./2024. analizirani su rezultati koje su studenti Sveučilišnog prijediplomskog studija računarstva Tehničkog fakulteta Sveučilišta u Rijeci postigli na kolegiju Matematika 1. Kolegij je pohađalo 76 studenata, a njih 26 nije položilo kolegij. Varijabla Uspjeh čije se vrijednosti žele previdjeti dihotomna je jer ima samo dva moguća ishoda, prolaz ili pad kolegija. Studentima koji su položili kolegij (50 studenata) pridružena je vrijednost zavisne varijable 1, dok je studentima koji nisu položili kolegij pridružena vrijednost zavisne varijable 0 (26 studenata).

Nakon definiranja zavisne varijable Uspjeh bilo je potrebno odrediti nezavisne varijable, aktivnosti studenata tijekom semestra koje će služiti kao prediktori (ne)uspjeha. Prikupljeni su podaci iz sustava za e-učenje o preuzimanju prezentacija, rješavanju testova s vježbi, rješavanju testova za vježbu, pregledavanju video lekcija te postotku bodova ostvarenih na kolokvijima i bonus testovima. Analizirani su i odgovori na pitanja iz dvaju upitnika koji su ponuđeni studentima u prvom tjednu nastave, upitnika o prijašnjoj razini učenja te upitnika o motivaciji za upis studija [1]. Na ovaj je način definirano 20 nezavisnih varijabli kao mogućih prediktora (ne)uspjeha. Prikupljeni podaci uredeni su i analizirani u programskom jeziku R. Svi numerički podaci pretvoreni su u dihotomne varijable temeljem graničnih vrijednosti za koje je vrijednost Youdenovog indeksa najveća.

Zatim je pomoću Pearsonovog hi-kvadrat testa određeno koja od dihotomnih varijabli je relevantan prediktor (ne)uspjeha studenata u svakom od 15 nastavnih tjedana. Od ukupno 20 analiziranih varijabli 16 je relevantnih te su se one koristile u nastavku istraživanja za formiranje bodovnog sustava.

Za procjenu jačine asocijacije između relevantnih varijabli i (ne)uspjeha studenata korištena je mjera Cramer's V. Pomoću vrijednosti Cramer's V koeficijenata formiran je bodovni sustav koeficijenata za relevantne aktivnosti za svaki od 15 nastavnih tjedana. Za

svaki tjedan određena je optimalna granična vrijednost broja bodova za koju je vrijednost Youdenovog indeksa najveća. Na temelju tih optimalnih graničnih vrijednosti sume bodova za svaki tjedan, numerička varijabla pretvara se u dihotomnu, prolaz ili pad kolegija.

Nakon dizajniranja bodovnog sustava potrebno ga je testirati na poznatim podacima te odrediti njegovu prediktivnu uspješnost. Evaluacija performansi klasifikacijskog prediktivnog modela koji se temelji na bodovnom sustavu iskazana je različitim metričkim mjerama. U radu [2] željelo se predvidjeti rizične studente na kolegiju Vjerodost i statistika tijekom 17 tjedana trajanja kolegija. Najbolju klasifikacijsku moć pokazao je klasifikator konstruiran na Bayesovoj mreži s vrijednostima mjere F1 unutar intervala [0.69, 0.89]. Ovaj model ima veće vrijednosti F1 unutar intervala [0.79, 0.92]. Visoka specifičnost [0.80, 1.00] u svih 15 tjedana ukazuje na činjenicu da model vrlo rijetko klasificira negativne slučajeve kao pozitivne. To omogućuje ranu detekciju studenata koji su u opasnosti da neće položiti kolegij.

Provođenje navedenih koraka rezultiralo je odgovorima na postavljena istraživačka pitanja te je cilj prvog dijela istraživanja ostvaren, dizajniran je prediktivni klasifikacijski model u formi bodovnog sustava na temelju kojeg će se vršiti predikcija (ne)uspjeha studenata u svakom od 15 tjedana nastave.

Ključne riječi – prediktorske varijable, Youdenov indeks, mjera Cramer's V, bodovni sustav

Literatura

- [5] G. Ribić, »Motivacija za studij kod učenika srednjih škola: uloga osnovnih psiholoških potreba i identiteta,« Diplomski rad, Sveučilište u Rijeci, Filozofski fakultet, Rijeka, 2016. [Mrežno]. Available: <https://urn.nsk.hr/urn:nbn:hr:186:716500>.
- [6] T. A. Kustitskaya, A. A. Kytmanov and M. V. Noskov, "Early Student-at-Risk Detection by Current Learning Performance and Learning Behavior Indicators," Cybernetics and Information Technologies, vol. 22, no. 1, pp. 117-133, 2022.

Vlatka Davidović

University of Rijeka, Faculty of Informatics and Digital Technologies, Rijeka, Croatia
Polytechnic of Rijeka, Rijeka, Croatia
v david@veleri.hr

Report on Collecting Datasets for Croatian Abstractive Summarization on Transformer Architecture

Large Language Models (LLMs) based on transformer architecture currently demonstrate high capabilities in text comprehension and generation in the NLP field. To achieve good results, LLMs must be trained on a vast amount of text to learn how to generate new text that looks like it was created by humans [1]. Collecting and preparing large amounts of high-quality texts are key components in training large language models for NLP tasks or domains.

Although current models generate text well in different languages, the result is still skewed towards English, as English texts predominate in corpora [2]. Collecting datasets in different languages can result in better linguistic representation during training and give better results in those languages in terms of specific domains or tasks.

The main goal of the research is to train the model for abstractive summarization in Croatian. Abstractive summarization creates a shorter version of the original text that includes the essential information without copying the sentences from the original text [3]. So, to train the model, an appropriate dataset is required. The summarization dataset consists of long texts and related summaries.

The Croatian language is represented in some available datasets, but the dataset for the summarization task is missing. The monolingual dataset collected from the web crawl, CC-100 [4], contains 20 GB of text in Croatian. The COPA-HR dataset (Choice of plausible alternatives in Croatian) [5] is a translation of the English COPA dataset, which consists of 1000 premises with questions and answers. Twitter-HBS [6] is a Twitter dataset that discriminates between Bosnian, Croatian, Montenegrin, and Serbian. It contains tweets from 614 users, of whom 89 are labeled as tweeting in Croatian. SETimes.HBS [7] is a news dataset in Bosnian, Croatian, and Serbian that contains 3196 texts in Croatian. Domain-specific datasets are MultiEURLEX [8], EUR-Lex-Sum [9], and EUROPA [10]. They focus on legal EU documents officially translated into 24 languages, including Croatian. A multilingual corpus for training and evaluating a diacritics restoration system [11] is a collection of Wikipedia articles that contain diacritics. Croatian is one of the 12 languages. The mOSCAR [12] is a multilingual and multimodal document corpus crawled from the web that includes 1,719,617 Croatian text documents among 315M. Other large datasets, such as HALvest (Open Scientific Papers Harvested from HAL) [13], contain 660,663 documents in 56 languages. 8 papers are written in Croatian. MegaCOV [14] is a Twitter dataset that includes billions of tweets in 65 languages about COVID-19. There are 685K tweets in Croatian.

Next are presented new datasets collected between 2022 and 2024 for the task of training the summarization model for Croatian language.

Croatian Digital Theses Repository (NSK) [15]: This repository contains an open-access collection of student theses written in Croatian from 2007-2024. The theses were collected through the official web portal as PDF documents. All documents are converted into plain text during preprocessing. After this process, empty or corrupt documents are removed. The prepared dataset contains approximately 8 GB of text. Besides the folder

with documents, one CSV file contains all URLs of the original documents, their titles, and years.

Croatian Journal Repository (Hrčak) [16]: This repository offers open access to the collection of scientific and professional journals written in Croatian. Papers are available for download, mainly in PDF format. Older papers were not in a document-readable format for reuse, as they were scanned as images. After downloading documents from the official web portal and converting them into text format, empty documents are removed. The dataset contains 5.5 GB of text.

Croatian forums: Data are collected from three popular forums: Forum.hr [17], Bug.hr [18], and Roda.hr [19]. Forum.hr contains general and broad topics. Bug.hr forum has ICT and, in general, technology-oriented topics. Roda.hr is a pregnancy and parenthood-oriented forum. All forums are divided into topics that contain different themes. One open theme for discussion is saved as one document. It contains the id, title, question, and answers. The document can contain more than 10,000 answers. Data are collected using web scraping tools Selenium [20] and BeautifulSoup [21]. Forum.hr dataset contains over 272,000 files, Bug.hr contains over 232,000, and Roda.hr contains over 46,000 files.

News portals: The dataset collected from the Croatian news portals has the following fields: id, title, link, published, summary, and text. Pre-processing this dataset includes deduplication and removing documents with empty summaries or summaries with only links or images. It is saved in JSON format and comprises over 300,000 texts and related summaries prepared for the summarization task.

Keywords – Croatian datasets, summarization, LLMs

References

- [1] I. Turc, M.-W. Chang, K. Lee and K. Toutanova, "Well-read students learn better: On the importance of pre-training compact models," ArXiv, 2019.
- [2] Y. Liu, J. Cao, C. Liu, K. Ding, K., and L. Jin, "Datasets for Large Language Models: A Comprehensive Survey". ArXiv, abs/2402.18041, 2024.
- [3] S. Chopra, M. Auli and A. M. Rush, "Abstractive Sentence Summarization with Attentive Recurrent Neural Networks," Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, p. 93–98, 2016.
- [4] G. Wenzek, M.A. Lachaux, A. Conneau, V. Chaudhary, F. Guzmán, A. Joulin, and E. Grave, CCNet: Extracting High Quality Monolingual Datasets from Web Crawl Data, Proceedings of the 12th Language Resources and Evaluation Conference (LREC), p. 4003-4012, May 2020, <https://data.statmt.org/cc-100/>
- [5] N. Ljubešić, Choice of plausible alternatives dataset in Croatian COPA-HR, Slovenian language resource repository CLARIN.SI, ISSN 2820-4042, 2021, <http://hdl.handle.net/11356/1404>.
- [6] N. Ljubešić, and P. Rupnik, "The Twitter user dataset for discriminating between Bosnian, Croatian, Montenegrin and Serbian Twitter-HBS 1.0." Slovenian language resource repository CLARIN.SI. 2020.
- [7] N. Ljubešić, and P. Rupnik, "The news dataset for discriminating between Bosnian, Croatian and Serbian SETimes.HBS 1.0", Slovenian language resource repository CLARIN.SI, ISSN 2820-4042, 2022. <http://hdl.handle.net/11356/1461>
- [8] I. Chalkidis, M. Fergadiotis, I. Androutsopoulos, "MultiEURLEX - A multi-lingual and multi-label legal document classification dataset for zero-shot cross-lingual transfer". Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing, Punta Cana, Dominican Republic, 2021.

- [9] D. Aumiller, A. Chouhan, M. Gertz, “EUR-Lex-Sum: A Multi- and Cross-lingual Dataset for Long-form Summarization in the Legal Domain”, CoRR, 2022, <https://arxiv.org/abs/2210.13448>
- [10] O. Salaün, F. Piedboeuf, G. Le Berre, D. Alfonso-Hermelo, and P. Langlais, “EUROPA: A Legal Multilingual Keyphrase Generation Dataset”. In Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), pages 12718–12736, Bangkok, Thailand. Association for Computational Linguistics, 2024.
- [11] J. Náplava, M. Straka, J. Hajič, P. Straňák, “Corpus for training and evaluating diacritics restoration systems”, LINDAT/CLARIAH-CZ digital library at the Institute of Formal and Applied Linguistics (ÚFAL), Faculty of Mathematics and Physics, Charles University, 2018, <http://hdl.handle.net/11234/1-2607>
- [12] M. Futerál, “mOSCAR: A Large-scale Multilingual and Multimodal Document-level Corpus”, 2024, <https://arxiv.org/abs/2406.08707>
- [13] F. Kulumba, W. Antoun, G. Vimont and L. Romary, “Harvesting Textual and Structured Data from the HAL Publication Repository”, 2024, <https://arxiv.org/abs/2407.20595>
- [14] M. Abdul-Mageed, A. Elmadany, E.M.B. Nagoudi, D. Pabbi, K. Verma, and R. Lin. “Mega-COV: A Billion-Scale Dataset of 100+ Languages for COVID-19”, 2021, <https://doi.org/10.48550/arXiv.2005.06012>
- [15] Nacionalni repozitorij završnih i diplomske radova ZIR, <https://zir.nsk.hr/>, accessed 20.4.2024.
- [16] Portal hrvatskih znanstvenih i stručnih časopisa, <https://hrcak.srce.hr/>, accessed 29.5.2024.
- [17] Forum.hr, <https://www.forum.hr/>, accessed 17.5.2024.
- [18] BUG Forum, <https://forum.bug.hr/forum/>, accessed 10.5.2024.
- [19] Forum RODA, <https://forum.roda.hr/>, accessed 29.5.2024.
- [20] Selenium WebDriver, <https://www.selenium.dev/documentation/webdriver/>, accessed 2.4.2024.
- [21] L. Richardson, Beautiful Soup, <https://pypi.org/project/beautifulsoup4/>, accessed 2.4.2024.

Minki Kang

Chung-Ang University, Seoul, Republic of Korea

bbx8216@cau.ac.kr

Introducing the Max Planck Computing and Data Facility's HPC System and Minimizing MPS Interference in GPU Inference Servers through Adaptive Scheduling

During my internship, I had the opportunity to work at the Max Planck Computing and Data Facility (MPCDF), which provides high-performance computing (HPC) and data science support to various Max Planck institutes. One of MPCDF's key systems, Raven, features Intel Xeon Ice Lake-SP processors and Nvidia A100 GPUs, boasting over 1,500 compute nodes with a theoretical peak performance of 8.8 PFlop/s for CPUs and 16 PFlop/s for GPUs.

Users submit their jobs to the HPC system using an open-source workload manager called SLURM [1]. SLURM automatically prioritizes jobs and allocates the appropriate nodes for execution, allowing users to manage resources efficiently without manually selecting nodes.

Monitoring resource usage in HPC systems is essential for assessing utilization and ensuring optimal execution. To achieve this, MPCDF has implemented a performance monitoring system called HPCM [2], which collects CPU and GPU performance metrics with minimal overhead. The data is processed through databases such as Splunk, providing users with detailed reports on their resource usage. CPU performance is monitored using Linux's perf module, while GPU metrics are collected using Nvidia's nvidia-smi and Data Center GPU Manager (DCGM) tools.

However, assessing resource efficiency and code optimization during execution is challenging for Python programs, because Python is an interpreted language, unlike compiled languages like C. To address this issue, I implemented a feature that adds data on libraries used by Python programs to the HPCM system, enabling more precise monitoring of Python applications' performance.

Using the collected data, we introduced a Roofline model-based resource evaluation method to assess how effectively users utilized resources for their jobs. This system sends notifications to users after their jobs finish, informing them of their resource usage efficiency through an epilog script. I am currently developing a neural network model to provide guidelines for users on writing SLURM scripts for better resource efficiency.

With the increasing diversity and usage of DNN applications, there has been a surge in inference requests for GPUs in cloud environments. These inference tasks must meet specific Service Level Objectives (SLO) [3], such as latency limits, and the Inference Server must provide resource environments that satisfy the SLOs of various workloads. However, the requests are diverse and highly variable. When the SLO is lenient or the batch size is small, a single GPU may not be fully utilized, leading to resource wastage, especially as GPU hardware performance continues to improve, exacerbating the issue of low GPU utilization.

To enhance GPU utilization, there is a need for GPU sharing, which allows multiple workloads to share a single GPU. GPU sharing can be categorized into two main types: Temporal Sharing and Spatial Sharing. Temporal Sharing involves multiple application kernels executing within a single time slice, while Spatial Sharing refers to the spatial sharing of GPU resources through methods like Multi Process Service (MPS) [4] or Multi

Instance GPU (MIG) [5]. MIG allows a single GPU to be divided into seven independent instances; however, the time required for instance reconfiguration makes it difficult to respond quickly to frequently changing workloads. In contrast, MPS separates compute resources but does not isolate memory resources per process, potentially leading to overall performance degradation.

To address these issues, the previous study, gputlet [6], implemented an inference server that shares a GPU among a maximum of two workloads using MPS; however, it still experienced low GPU utilization and interference prediction errors. iGniter [7] enables the simultaneous execution of multiple applications and conducts lightweight profiling, but it fails to minimize interference between workloads and has errors in its interference prediction model. Orion [8] is a scheduler that offers spatial sharing at the kernel level for ML applications, utilizing low-priority jobs to increase GPU utilization, but it inadequately considers the completion times of these low-priority jobs.

To solve these problems, the first goal of this research is to enable the resource allocation system to respond appropriately to changing workload requirements by using MPS to rapidly adjust resource partitioning for each process. The second goal is to utilize MPS for spatial sharing of the GPU while efficiently allocating resources, accurately modeling the inter-workload interference, and ensuring predictable latency. The final goal is to implement scheduling that minimizes interference, allowing each workload to feel like it is running in an independent environment, even when sharing the GPU.

This research is expected to effectively utilize GPUs while meeting user requirements for evolving DNN requests in cloud environments, allowing users to use resources more economically and contributing to the efficiency of resource utilization in cloud environments.

Keywords – spatial GPU sharing, DNN inference, cloud computing

References

- [1] Yoo, A. B., Jette, M. A., & Grondona, M. (2003, June). Slurm: Simple linux utility for resource management. In Workshop on job scheduling strategies for parallel processing (pp. 44-60). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [2] Stanisic, L., & Reuter, K. (2020). Mpcdf hpc performance monitoring system: Enabling insight via job-specific analysis. In Euro-Par 2019: Parallel Processing Workshops: Euro-Par 2019 International Workshops, Göttingen, Germany, August 26–30, 2019, Revised Selected Papers 25 (pp. 613-625). Springer International Publishing.
- [3] C. Jones, J. Wilkes, N. Murphy, and C. Smith, Site Reliability Engineering: How Google Runs Production Systems. O'Reilly Media, 2016. [Online]. Available: <https://landing.google.com/sre/sre-book/chapters/service-level-objectives/>
- [4] NVIDIA. (2024) Multi-process service. [Online]. Available: <https://docs.nvidia.com/deploy/mps/index.html>
- [5] NVIDIA. (2023) Nvidia multi-instance gpu user guide. [Online]. Available: <https://docs.nvidia.com/datacenter/tesla/mig-user-guide/index.html>
- [6] Choi, S., Lee, S., Kim, Y., Park, J., Kwon, Y., & Huh, J. (2022). Serving heterogeneous machine learning models on Multi-GPU servers with Spatio-Temporal sharing. In 2022 USENIX Annual Technical Conference (USENIX ATC 22) (pp. 199-216).
- [7] Xu, Fei, et al. "igniter: Interference-aware gpu resource provisioning for predictable dnn inference in the cloud." IEEE Transactions on Parallel and Distributed Systems 34.3 (2022): 812-827.

- [8] Strati, F., Ma, X., & Klimovic, A. (2024, April). Orion: Interference-aware, Fine-grained GPU Sharing for ML Applications. In Proceedings of the Nineteenth European Conference on Computer Systems (pp. 1075-1092).

Marija Kuštelega

Sveučilište u Zagrebu, Fakultet organizacije i informatike, Varaždin, Hrvatska
marija.kustelega@foi.unizg.hr

Pregled dosadašnjih istraživanja o upotrebljivoj privatnosti i sigurnosti u dizajnu informatičkih usluga

Postoji jaz između koncepata upotrebljivosti (engl. *usability*) i privatnosti/sigurnosti prilikom dizajniranja informatičkih usluga [1]. Organizacije su tradicionalno pridavale važnost sigurnosti u smislu zaštite fizičke imovine, ali s razvojem digitalnog svijeta, uočeno je da organizacije sve veću pozornost obraćaju na koncept privatnosti vezan uz zaštitu osobnih podataka potrošača. Iako je 79% Amerikanaca izjavilo da je zabrinuto za to kako organizacije koriste njihove podatke, većina njih (56%) preskače čitanje politika privatnosti zbog neintuitivnog tehničkog opisa sadržaja [2]. Gartner predviđa da će do 2024. godine povećana očekivanja potrošača o transparentnosti podataka dovesti do trenda razvoja centraliziranih portala namijenjenih za upravljanje pristankom i preferencama privatnosti kao što su to obavijesti, kolačići i slično [3]. Postojeći okviri i procesi koji razmatraju privatnost i sigurnost prilikom dizajna sustava, koristeći „*privacy by design*“ pristup, usredotočuju se samo na ukomponiranje potrebnih postavaka privatnosti i sigurnosti kako bi one zadovoljavale zakonske regulative, a ne toliko na „*user-friendly*“ dizajn usluge [4]. U Ciscovoj studiji o privatnosti podataka provedenoj u 2023. godini navedeno je kako je 97% organizacija svjesno da je zaštita privatnosti ključna za stjecanje povjerenja potrošača i da imaju odgovornost etički koristiti njihove podatke [5]. Iz tog razloga je potrebno pronaći rješenje kojem će se omogućiti da pojmovi vezani uz privatnost budu lako razumljivi i intuitivni korisnicima.

Glavni cilj ovog rada je identificirati elemente kojima se postiže upotrebljiva privatnost i sigurnost (engl. *usable privacy and security*) prilikom dizajniranja korisničkog iskustva. Koristeći sustavni pregled literature istražit će se trenutna primjena principa upotrebljive privatnosti i sigurnosti prilikom dizajniranja informatičkih usluga kao i postojeći mjerni instrumenti za ispitivanje upotrebljive privatnosti i sigurnosti usluga.

Međunarodna organizacija za standardizaciju (engl. *International Organization for Standardization - ISO*) je definirala upotrebljivost kao mjeru do koje korisnici mogu koristiti proizvod, osiguravajući pritom učinkovitost, djelotvornost i zadovoljstvo korisnika u određenom kontekstu uporabe [6]. Dosadašnja istraživanja opisuju upotrebljivost kao čimbenik koji je u sukobu s konceptom privatnosti i sigurnosti, ističući pritom da se ulažu naporci da se premoste te razlike [7] [8]. Obavijesti o privatnosti, koje prikazuju prakse ophođenja privatnim podacima, koje primjenjuje nuditelj usluge ključne su za korisnike kako bi donosili informirane odluke, ali trenutni mehanizmi često su neučinkoviti zbog nedostatka smjernica za dizajnere i programere kako razviti upotrebljivo i korisno sučelje za pružanje pravovremenih informacija o privatnosti [9]. Korisničko iskustvo (engl. user experience - UX) kao pojam može se opisati kao iskustvo interakcije između čovjeka i proizvoda koji nadilazi sam vizualni aspekt korisničkog sučelja i upotrebljivosti [10]. Postoje specifične grupe stručnjaka koje se bave upotrebljivom sigurnošću i privatnošću (engl. *Usable Security and Privacy Group*) istražujući ljudske čimbenike koji utječu na donošenje odluka vezanih uz sigurnost i privatnost prilikom korištenja informatičkih usluga [11]. Jedan od primjera projekta za rješavanje tog problema je „*Usable privacy police project*“ koji je pokušao pojednostaviti politike privatnosti pomoću alata za strojno učenje kako bi one bile lako razumljive korisnicima i potaknule korisnike da ih čitaju [12].

Neka od ponuđenih rješenja za bolji dizajn korisničkog iskustva koji uvažava koncepte privatnosti i sigurnosti uključuju: (1) podizanje svijesti o postupcima prikupljanja i pohrane podataka, (2) redizajn složenih ili zbumujućih značajki te (3) dizajniranje proizvoda s mogućnošću kontrole privatnosti [13]. Sve više se inicijative usmjeravaju na standardizaciju, kao što su to kreiranje standardiziranih ikona za privatnost da bi se osiguralo da korisnici razumiju značenje tih ikona i lakše percipiraju ključne informacije vezane uz privatnost [4]. Otkrivena su ograničenja pri dizajniranju takvih sustava, budući da dizajn sučelja s najboljim rezultatima upotrebljivosti možda neće biti u potpunosti u skladu s primjenjivim zakonskim regulativama [14].

Nadalje, istraživači su pokušali osmislitи sveobuhvatni upitnik koji bi ispitivao upotrebljivu privatnost promatrajući dimenzije kao što su to znanje, stav, percipirana korisnost, percipirana lakoća upotrebe i ponašanja ispitanika [15]. Lako je mjereno upotrebljive privatnosti korisno i za usklađenost tvrtki s Općom uredbom o zaštiti podataka (GDPR-om), teško je osmisiliti kako bi taj mjerni instrument trebao izgledati [16]. Najbliže tom cilju postignuto je s novim modelom za procjenu privatnosti gdje su kriteriji upotrebljive privatnosti kategorizirani na temelju njihovog područja primjene u GDPR-u, kao što su to (1) privole, (2) načela transparentnosti, (3) prava ispitanika, (4) svrha obrade i (5) zakonska osnova za obradu podataka [17].

U okviru budućih istraživanja želi se razviti mjerni instrument kojima će se evaluirati informatičke usluge s aspekta upotrebljivosti, privatnosti i sigurnosti. Ideja je razviti holistički upitnik koji će istovremeno ispitivati percepciju korisničkog iskustva s uslugom (uključujući upotrebljivost) i usvajanje koncepata privatnosti i sigurnosti. Navedena saznanja će se koristiti za izgradnju okvira za razvoj korisničkog iskustva s uključenim principima privatnosti i sigurnosti. Sami okvir poslužiti će za razvoj smjernica kojima se mogu poslužiti UX dizajneri kako bi razvili informatičke usluge koje će biti u skladu sa zaštitom osobnih podataka korisnika.

Ključne riječi - upotrebljivost, privatnost, sigurnost, dizajn informatičkih usluga

Literatura

- [1] M. Alshamari, M., "A review of gaps between usability and security/privacy", International Journal of Communications, Network and System Sciences, 9(10), 2016, pp. 413-429.
- [2] Pew Research Center (2023). "How Americans View Data Privacy". [Na internetu]. Dostupno na: <https://www.pewresearch.org/internet/2023/10/18/how-americans-view-data-privacy/> [pristupano 14.10.2024].
- [3] Gartner (2022). "Gartner Identifies Top Five Trends in Privacy Through 2024". [Na internetu]. Dostupno na: <https://www.gartner.com/en/newsroom/press-releases/2022-05-31-gartner-identifies-top-five-trends-in-privacy-through-2024> [pristupano 14.10.2024].
- [4] M. von Grafenstein, I. Kiefaber, J. Heumüller, V. Rupp, P. Graßl, O. Kolless, & Z. Puzst, „Privacy icons as a component of effective transparency and controls under the GDPR: effective data protection by design based on art. 25 GDPR“, Computer Law & Security Review, 52, 2024, 105924.
- [5] Cisco (2024). „Cisco 2024 Data Privacy Benchmark Study“. [Na internetu]. Dostupno na: https://www.cisco.com/c/dam/en_us/about/doing_business/trust-center/docs/cisco-privacy-benchmark-study-2024.pdf?CCID=cc000160&DTID=odicdc000016&OID=rpts-c032067 [pristupano 14.10.2024].
- [6] ISO 9241-11:1998, „Ergonomic Requirements for Office Work with Visual Display Terminals (VDTs)“, The International Organization for Standardization, Geneva, 1998.

- [7] B. Naqvi and A. Seffah, "Interdependencies, conflicts and trade-offs between security and usability: why and how should we engineer them?" in HCI for Cybersecurity, Privacy and Trust: First International Conference, HCI-CPT 2019, Held as Part of the 21st HCI International Conference, July 26–31, 2019, pp. 314-324.
- [8] K. Krol, J. M. Spring, S. Parkin, S., & M.A. Sasse, "Towards robust experimental design for user studies in security and privacy" in The LASER workshop: learning from authoritative security experiment results, 2016, pp. 21-31.
- [9] F. Schaub, R. Balebako, A. L. Durity, & L.F. Cranor, "A design space for effective privacy notices" in Eleventh symposium on usable privacy and security, 2015, pp. 1-17.
- [10] A. Berni and Y. Borgianni, "From the definition of user experience to a framework to classify its applications in design", Proceedings of the Design Society, 1, 2021, pp. 1627-1636.
- [11] International computer science institute (bez dat.). „Usable Security and Privacy“. [Na internetu]. Dostupno na: <https://www.icsi.berkeley.edu/icsi/groups/privacy> [pristupano 10.10.2024].
- [12] N. Sadeh, A. Acquisti, T. D. Breaux, L. F. Cranor, A. M. McDonald, J. R. Reidenberg, ... & S. Wilson, "The usable privacy policy project" in Technical report, Technical Report, CMU-ISR-13-119. Carnegie Mellon University, 2013.
- [13] G. Chalhoub, "The UX of things: Exploring UX principles to inform security and privacy design in the smart home" in Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems, April, 2020, pp. 1-6.
- [14] H. Habib and L. F. Cranor, "Evaluating the usability of privacy choice mechanisms" in Eighteenth Symposium on Usable Privacy and Security, 2022, pp. 273-289.
- [15] F. Herbert, F. M. Farke, M. Kowalewski, and M. Dürmuth, „Vision: Developing a Broad Usable Security & Privacy Questionnaire“ in Proceedings of the 2021 European Symposium on Usable Security, October, 2021, pp. 76-82.
- [16] E. C. Groen, D. Feth, S. Polst, J. Tolsdorf, S. Wiefling, L. L. Iacono, & H. Schmitt, „Achieving usable security and privacy through Human-Centered Design“ in Human Factors in Privacy Research, Cham: Springer International Publishing, 2023, pp. 83-113.
- [17] J. Johansen and S. Fischer-Hübner, „Making GDPR usable: A model to support usability evaluations of privacy“ in Privacy and Identity Management. Data for Better Living: AI and Privacy: 14th IFIP WG 9.2, 9.6/11.7, 11.6/SIG 9.2. 2 International Summer School, Windisch, Switzerland, August 19–23, 2019, pp. 275-291.

Dejan Ljubobratović

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
dejan.ljubobratovic@uniri.hr

Evaluacija modela za dubinsko učenje na tabličnim podacima za predviđanje zrelosti breskvi korištenjem modela TabNet, SAINT i NODE: komparativna analiza

Zrelost pri berbi ima presudan utjecaj na kvalitetu ploda breskve, vijek trajanja, a posljedično i prihvatanje kod potrošača. Stoga bi točno predviđanje zrelosti plodova omogućilo odabir optimalnog vremena za berbu. Parametar kojim se obično predstavlja zrelost ploda je tvrdoća breskve [1]. Cilj ovoga rada je kreirati model koji će na osnovi mjerjenih morfoloških i fizičko-kemijskih karakteristika breskvi čim točnije predviđati njihovu tvrdoću, tj. zrelost [2].

Redhaven je sorta breskve srednje veličine s glatkom, crvenkastom kožom i žuto-narančastim mesom, koja je poznata po slatkom, bogatom okusu. Ova sorta je vrlo popularna zbog svoje otpornosti na bolesti i stabilnog prinosa, a zrije sredinom ljeta. Za potrebe ovog istraživanja, breskve sorte Redhaven su brane u voćnjaku Agro Car d.o.o. u Bistranskim Novakima u periodu od 14 dana. Nakon svake berbe u laboratoriju su mjereni sljedeći parametri: masa, dimenzije, DA indeks, boja na kolorimetru, fotografiranje, multi spektralno snimanje, tvrdoća, destruktivna impedancija, udiotopljive suhe tvari i ukupne kiseline u plodu. Tijekom tih 14 dana analizirana su ukupno 702 ploda u raznim fazama zrelosti.

U prijašnjem radu rađena je usporedba modela strojnog učenja na osam modela strojnog učenja i ANN model se pokazao najtočnijim u predviđanju zrelosti [3]. Kao nastavak tog rada odabrana su tri modela neuronskih mreža za daljnju analizu i usporedbu rezultata predviđanja. Kako su modeli neuronskih mreža uglavnom rađeni za obradu velikih skupova podataka, skup od svega 702 mjerjenja zahtijevao je posebne vrste modela. Stoga su odabrana tri modela neuronskih mreža koja se dobro nose s malim skupovima podataka, ali koji su istovremeno prigodni za obradu tabličnih podataka, kakvi su i naši. Odabrani modeli su TabNet, SAINT (*Self-Attention and Intersample Attention Transformer*) i NODE (*Neural Oblivious Decision Ensembles*). To su modeli koji se koriste u obradi tabličnih podataka, a svi se temelje na principima neuronskih mreža, iako pristupi svakog modela imaju svoje specifičnosti.

TabNet je model dubokog učenja koji koristi mehanizam pažnje (engl. *attention mechanism*) prilagođen tabličnim podacima. TabNet kombinira klasične neuronske mreže s postupkom *sparse attention*, što mu omogućuje da automatski odabire koje značajke koristiti na različitim razinama dubokog modela, umjesto da prepostavlja da su sve značajke jednako važne za svaki primjer [4].

SAINT (*Self-Attention and Intersample Attention Transformer*) je model koji koristi transformersku arhitekturu, poznatu iz područja obrade prirodnog jezika, i prilagođava je za rad s tabličnim podacima. SAINT koristi mehanizam samopozornosti (engl. *self-attention*) kako bi modelirao odnose između značajki, ali također koristi *intersample attention* kako bi modelirao odnose između uzoraka podataka. Ova karakteristika ga čini posebnim unutar tabličnih podataka [5].

NODE (*Neural Oblivious Decision Ensembles*) je neuronska mreža koja pokušava imitirati ponašanje stabla odluka. NODE model koristi neuronske mreže kako bi stvorio

skup *decision ensembles*, što omogućuje učinkovitu obradu složenih tabličnih podataka uz prednosti neuronskih mreža [6].

Kako se u ovom istraživanju koristio novi skup mjerena, ponovljena su predviđanja ANN modelom, a zatim i korištenjem spomenuta tri modela. Napravljena je detaljna usporedba dobivenih rezultata i izdvojene su varijable koje su najviše doprinijele uspješnoj predikciji korištenjem interpretabilnog strojnog učenja ugrađenog u TabNet model.

Ključne riječi - strojno učenje, predviđanje zrelosti breskvi, neuronske mreže, tablični podaci

Literatura

- [1] D. Ljubobratović, M. Vuković, M. Brkić Bakarić, T. Jemrić, i M. Matetić, „Utilization of Explainable Machine Learning Algorithms for Determination of Important Features in ‘Suncrest’ Peach Maturity Prediction“, Electronics, sv. 10, izd. 24, str. 3115, pros. 2021, doi: 10.3390/electronics10243115.
- [2] D. Ljubobratovic, Z. Guoxiang, M. Brkic Bakaric, T. Jemric, i M. Matetic, „Predicting Peach Fruit Ripeness Using Explainable Machine Learning“, u DAAAM Proceedings, 1. izd., sv. 1, B. Katalinic, Ur., DAAAM International Vienna, 2020, str. 0717–0723. doi: 10.2507/31st.daaam.proceedings.099.
- [3] D. Ljubobratović, M. Vuković, M. Brkić Bakarić, T. Jemrić, i M. Matetić, „Assessment of Various Machine Learning Models for Peach Maturity Prediction Using Non-Destructive Sensor Data“, Sensors, sv. 22, izd. 15, str. 5791, kol. 2022, doi: 10.3390/s22155791.
- [4] S. O. Arik i T. Pfister, „TabNet: Attentive Interpretable Tabular Learning“, 9.12.2020., arXiv: arXiv:1908.07442. Pristupljeno: 14.10.2024. [Na internetu]. Dostupno na: <http://arxiv.org/abs/1908.07442>
- [5] G. Somepalli, M. Goldblum, A. Schwarzschild, C. B. Bruss, i T. Goldstein, „SAINT: Improved Neural Networks for Tabular Data via Row Attention and Contrastive Pre-Training“, 2.6.2021., arXiv: arXiv:2106.01342. Pristupljeno: 14. listopad 2024. [Na internetu]. Dostupno na: <http://arxiv.org/abs/2106.01342>
- [6] S. Popov, S. Morozov, i A. Babenko, „Neural Oblivious Decision Ensembles for Deep Learning on Tabular Data“, 19. rujan 2019., arXiv: arXiv:1909.06312. Pristupljeno: 14.10.2024. [Na internetu]. Dostupno na: <http://arxiv.org/abs/1909.06312>

Anna Maria Mihel

Sveučilište u Rijeci, Tehnički fakultet, Rijeka, Hrvatska
annamaria.mihel@riteh.uniri.hr

Evaluacija točnosti predviđanja uzvodnog vodostaja priobalne rijeke do 24 sata unaprijed korištenjem kombiniranog pristupa inženjeringu značajki i hibridnog modela

U posljednjih nekoliko godina, klimatske promjene uzrokuju značajne probleme u priobalnim rječnim područjima. Istraživanje u okviru ovoga rada je usmjeren na donji tok rijeke Neretve, koji ima izražen sezonski karakter s periodima malih voda od svibnja do rujna, te velikih voda od listopada do travnja [1]. Tijekom visokih voda može doći do plavljenja okolnih područja, dok tijekom niskih voda dolazi do povećanog prodora slane vode i smanjenja kakvoće vode što ugrožava ispravno funkcioniranje sustava navodnjavanja. Ovi problemi negativno utječu na lokalno stanovništvo, poljoprivrednu i bioraznolikost. Stoga je potrebno razviti točne modele za predviđanje razine vodostaja.

Numerički modeli za određivanje razine vodostaja suočavaju se s ograničenjima poput potrebe za velikim skupovima podataka, visokim stupnjem znanja o hidrauličkim procesima i dugim vremenom računalne obrade [2]. Alternativno, pristupi temeljeni na podacima, posebno strojno učenje, učinkovito prevladavaju ova ograničenja. Nedavne studije pokazuju uspješnu primjenu rekurentnih neuronskih mreža, s posebnim naglaskom na hibridne arhitekture. Smjer ovog rada se upravo i temelji na prethodnome [3]. Pregled istraživanja o primjeni strojnog učenja u predviđanju vodostaja u priobalnim područjima predstavljen je u preglednom radu [4].

Za potrebe studije korišteni su simulirani podaci, generirani pomoću HEC-RAS model površinskog toka vode. Simulacija predstavlja nestacionarno jednodimenzionalno strujanje rijeke s barotropnim karakteristikama (homogena gustoća fluida) [5]. Razdoblje simulacije obuhvaća četiri godine, od 2016. do 2019., a podaci su prikupljeni s vremenskom rezolucijom od jednog sata. Kao ulazni podaci korišteni su vodostaji na četiri mjerne postaje (Ušće, Opuzen, Kula Norinska, Metković) od ušća rijeke do ciljane postaje, uz dodatak protoka na stanicu Metković.

U prethodnoj studiji [6] zabilježena je učinkovitost primjene spektrograma u predviđanju protoka. Slijedom toga, u ovoj studiji se ispituje primjena spektrograma, s ciljem predviđanja razine vodostaja. Primijenjen je inženjerинг značajki s ciljem proširenja trenutnog skupa podataka [7]. Dodatne značajke uključuju brojne vremenske intervale, kao što su sat, dijelove dana, dan, mjesec, godišnje doba, godina. Uz vremenske intervale korištene su i uprosječene dnevne vrijednosti vodostaja sa svih postaja, kao i pomični prosjek za razdoblje od 24 sata. Prethodno treniranju modela, primijenjen je pomični prozor od 24 sata jer obuhvaća varijacije u razinama vodostaja, dnevne i poludnevne. Idući korak čini normalizacija podataka u rasponu od 0 do 1. Korišten je hibridni model koji kombinira konvolucijsku neuronsku mrežu (CNN) i mrežu s dugom kratkoročnom memorijom (LSTM), jer omogućuje prepoznavanje lokalnih i prostorno-vremenskih obrazaca, kao i sekvencialnih struktura, uz detekciju dugoročnih veza u podacima.

Analizira performansi modela provedena je koristeći Nash-Sutcliffe koeficijent efikasnosti, korijena srednje kvadratne pogreške i srednje apsolutna postotne pogreške, koje predstavljaju odabrane indikatore uspješnosti. Uz to, primijenjena je i korelacija koja prikazuje usporedbu predviđenih i stvarnih vrijednosti, točnije njihovo odstupanje od linije najboljeg pristajanja („best-fit line“). Testirana su četiri scenarija: prvi s izvornom

vremenskom serijom, drugi sa spektrogramima, te treći i četvrti koji kombiniraju inženjerинг značajki s vremenskim serijama i spektrogramima.

Temeljem indikatora uspješnosti za predviđanja unutar vremenskog intervala od 1 do 24 sata unaprijed, zaključeno je da najtočnije predviđene vrijednosti razina vodostaja ostvarene su za interval od jednog sata unaprijed. Sukladno tome, uočen je postupan pad performansi, odnosno točnosti predviđanja, s najlošijim rezultatima za predviđanja do 24 sata. Opoženi trend je očekivan s obzirom na promatrano područje kompleksnog priobalnog okruženja, kao posljedica akumulacije pogrešaka te prisutnosti nelinearnih procesa. Za predviđanje od jedan sat unaprijed najbolje rezultate je pružio scenarij gdje se koristi izvorna vremenska serija, dok za scenarije predviđanja više od jednog sata unaprijed, maksimalno do 24, inženjerинг značajki ukomponiran s izvornom vremenskom serijom. Time je potvrđeno da dodatne značajke pružaju bolje razumijevanje periodičkog ponašanja rijeke, prepoznavanje dugoročnih trendova, sezonalnosti i vremenski ovisnih uzoraka, čiji se utjecaj povećava s produljenjem razdoblja predviđanja zbog složenih odnosa između varijabli. Osim toga, prepoznavanje cjelokupnog trenda ostvareno je pomoću dnevnih i pomičnih prosjeka.

Prethodni zaključci su dalje potvrđeni korištenjem korelacije, odnosno usporedbe predviđenih i stvarnih vrijednosti. Za scenarij predviđanja do jedan sat unaprijed, distribucija točaka ne odstupa značajno od linije najboljeg pristajanja, međutim, najveća odstupanja za ekstremne vrijednosti razine vodostaja, iznad 1,5 m, uočena su kada je primijenjen inženjerинг značajki. U tim slučajevima, predviđene vrijednosti nalaze se ispod linije najboljeg pristajanja. Također, za predviđanja do 24 sata unaprijed, sličan trend uočen je u gotovo svim scenarijima, pri čemu su najlošiji rezultati uočeni kada se spektrogram kombinira s inženjerингom značajki.

Zaključno, uvođenje inženjerингa značajki dovelo je do sporijeg pada performansi modela za dulje scenarije predviđanja, do 24 sata, što je rezultat manje akumulacije pogrešaka. Stoga, primjena ovog pristupa u stvarnim scenarijama može biti korisna, ovisno o specifičnim zahtjevima. Za poboljšanje rezultata trenutne studije, predlaže se uvođenje dodatnih varijabli, poput temperature i saliniteta, korištenje naprednih metoda obrade signala (engl. *Variational Mode Decomposition* – VMD), kao i osiguravanje transparentnosti rada modela te važnost značajki u konačnim predviđanjima (engl. *SHapley Additive exPlanations* – SHAP).

Ključne riječi – priobalna rijeka, strojno učenje, razina vodostaja, inženjerинг značajki

Literatura

- [1] N. Kravica, H. Gotovac, G. Lončar, "Salt-wedge dynamics in microtidal Neretva River estuary", *Regional Studies in Marine Science*, vol. 43, pp. 101713, March 2021. <https://doi.org/10.1016/j.rsma.2021.101713>
- [2] M. Zounemat-Kermani, E. Matta, A. Cominola, X. Xia, Q. Zhang, Q. Liang, i R. Hinkelmann, "Neurocomputing in surface water hydrology and hydraulics: A review of two decades retrospective, current status and future prospects", *Journal of Hydrology*, vol. 588, pp. 125085, September 2020. <https://doi.org/10.1016/j.jhydrol.2020.125085>
- [3] A. M. Mihel, G. Vrbančić, Š. Pečnik, J. Lerga, N. Kravica, "Employing Feature Engineering for River Stage Forecasting to Improve Hybrid Model Performance", *32nd International Conference on Software, Telecommunications and Computer Networks (SoftCOM 2024)*, IEEE, 2024.

- [4] A. M. Mihel, J. Lerga, N. Krvavica, "Estimating water levels and discharges in tidal rivers and estuaries: Review of machine learning approaches", Environmental modelling & software, vol. 176, pp. 106033, May 2024. <https://doi.org/10.1016/j.envsoft.2024.106033>
- [5] S. Ghosh, "Flood dynamics and its spatial prediction using open-channel hydraulics and hydrodynamic model in the dam-controlled river of India", Journal of Ecohydraulics, vol. 8.2, p. 171-191, June 2023. <https://doi.org/10.1080/24705357.2023.2225521>
- [6] A. M. Mihel, K. Lenac, N. Krvavica, J. Lerga, "Discharge Forecasting in Coastal Rivers Using CNN-LSTM Hybrid Approach", 2023 International Symposium ELMAR, IEEE, 2023. <https://doi.org/10.1109/ELMAR59410.2023.10253933>
- [7] S. Ozdemir, S.Divya, "Feature Engineering Made Easy: Identify unique features from your dataset in order to build powerful machine learning systems", Packt Publishing Ltd, 2018.

Ivona Milinović

Sveučilište u Rijeci, Pomorski fakultet, Rijeka, Hrvatska
ivonastellam@gmail.com

Predviđanje podizanja razine mora u svrhu održivog upravljanja obalnim područjem primjenom umjetne inteligencije

Klimatske promjene jasan su indikator ljudskog nemara za vlastiti okoliš. Otapanje permafrosta koje dovodi do podizanja razine mora, sve učestalije suše i poplavna razdoblja, globalno zagrijavanje i povećanje emisije stakleničkih plinova popraćeno sa netipičnim temperaturnim fenomenima, pokazatelj su negativnog učinka klimatskih promjena. Navedeni atipični nusprodukti otežavaju održivo upravljanje obalnim područjem uvezši u obzir da se obalno područje konstantno mijenja kontinuiranim podizanjem razine mora.

Svjetska meteorološka organizacija (engl. *World Meteorological Organization - WMO*) upozorava kako je u 2023. godini globalna srednja razina mora dosegnula rekord te navode kako je u periodu od 2014. do 2023. godine stopa globalnog porasta srednje razine mora dvostruko veća usporedno sa periodom od 1993. do 2002. godine [1]. Navedeni podatci osim što su poražavajući, uveliko otežavaju upravljanje obalnim područjem. Gotovo je nemoguće predvidjeti kolika će globalna srednja razina mora biti za 50 godina stoga umjetna inteligencija može poslužiti kao alternativa. Iako je predviđanje samo predviđanje i ne može se uzeti u obzir kao kompletna činjenica, bez predviđanja nema niti planiranja, a u konačnici niti jasnog produkta. Obalnim područjem ne može se upravljati bez adekvatnih predviđanja utjecaja klimatskih promjena kao što je podizanje razine mora.

Važnost umjetne inteligencije leži u činjenici da se u iznimno kratkom vremenu mogu proučiti različiti podatci i njihova međusobna povezanost te kauzalnost. Umjetna inteligencija predstavlja način razumijevanja utjecaja klimatskih promjena. Kako bi se problem riješio ili barem onemogućilo nastajanje kompleksnijeg problema, taj problem mora biti jasno definiran te se mora razumjeti njegova uzročnost i utjecaj na ostale subjekte. Koristeći se različitim oblicima umjetne inteligencije mogu se jasnije uočiti uzroci pojavljivanja klimatskih anomalija, njihov utjecaj na budući okoliš te se mogu vizualizirati potencijalna rješenja koja minimaliziraju ili u potpunosti otklanjaju nekakav klimatski problem. Podizanje razine mora predstavlja iznimnu prijetnju našem okolišu [2] dok nama otežava planiranje obalnim prostorom. Konstantna promjenjivost obalnog prostora predstavlja nemogućnost održivog upravljanja istim u svrhu zaštite okoliša i kreiranje novih klimatskih strategija.

1988. godine WMO i UNEP (engl. *United Nations Environment Programme*) stvaraju IPCC (engl. *The Intergovernmental Panel on Climate Change*) [3] čiji je cilj pružanje znanstvenih informacija vladama u svrhu razvoja klimatskih politika. Danas IPCC koristi razne alate umjetne inteligencije kako bi što bliže prikazao znanstvene procjene klimatskih promjena te njihove implikacije i potencijalne buduće rizike. *NASA-in Sea Level Projection Tool* [4] koristi IPCC-eva istraživanja kako bi vizualizirao predikcije podizanja razine mora u svrhu boljeg razumijevanja, minimiziranja negativnih utjecaja, kreiranja boljih klimatskih strategija te kreiranja efikasnijih održivih načina upravljanja obalnim područjem.

3D simulacije i vizualizacije obalnog područja mogu se stvarati i korištenjem alata Omniverse [5]. Ovaj oblik prikazivanja iznimno je koristan u planiranju izgradnje fizičkih sustava kao što su luke jer može uzeti u obzir predikciju podizanja razine mora i drugih

negativnih utjecaja klimatskih promjena. Omniverse također može koristiti u planiranju obnove postojećeg obalnog prostora koji se pokazuje, ili bi se u skorijoj budućnosti mogao pokazati neefikasan uvezši u obzir sve rapidnije podizanje razine mora.

Negativan utjecaj klimatskih promjena prouzročen ljudskom kratkovidnošću i sebičnošću danas je nemoguće ignorirati. Strateško razmišljanje očuvanja okoliša je imperativ. Stvaranjem kvalitetne zakonske pozadine i korištenjem predikcijskih alata umjetne inteligencije koji vizualiziraju potencijalne scenarije moguće je prikazati kakav utjecaj na okoliš mogu imati sadašnje radnje. Primjenjivanjem umjetne inteligencije u svrhu predviđanja podizanja razine mora može se pametnije planirati i upravljati obalnim područjem imajući njegovu sveopću zaštitu na prvom mjestu.

Ključne riječi – klimatske promjene, održivo upravljanje obalnim područjem, podizanje razine mora, umjetna inteligencija, predviđanja

Literatura

- [1] World Meteorological Organization (WMO), State of the Global Climate 2023, Geneva, 2024., WMO (<https://library.wmo.int/records/item/68835-state-of-the-global-climate-2023>)
- [2] O. M. Sorkhabi, B. Shadmanfar, M. M. Al-Amidi, Deep learning of sea-level variability and flood for coastal city resilience, 2023., City and Environment Interactions, Vol. 17.
- [3] WMO, UN, The Intergovernmental Panel on Climate Change, Geneva, 2024., (<https://www.ipcc.ch/about/>)
- [4] Climate-ADAPT, Sea Level Projection Tool, 2022., (<https://climateadapt.eea.europa.eu/en/metadata/tools/sea-level-projection-tool>)
- [5] C. Hall, Modeling & Predicting Sea Level Rise with AI & Data Visualization, 2023., Cutter Consortium (<https://www.cutter.com/article/modeling-predicting-sea-level-rise-ai-data-visualization-sus-advisor>)

Ana Pasarić

University of Rijeka, Faculty of Informatics and Digital Technologies, Rijeka, Croatia
ana.pasaric1@student.uniri.hr

Empowering Students with Knowledge Graphs: A New Approach to Fact-Checking and Research

The proliferation of disinformation and misinformation, both human-generated and AI-driven, poses a significant threat to our ability to learn and make informed decisions [7, 25]. This transformation has necessitated the integration of media and digital literacy into educational curricula. While educators grapple with these new requirements, the emergence of AI-generated content presents additional challenges related to accuracy and authenticity.

As the volume of false claims continues to rise, automated fact-checking systems have emerged as essential tools to address this challenge [7, 22]. Among these tools, knowledge graphs (KGs) have demonstrated their potential to enhance the accuracy, efficiency, and transparency of fact-checking processes [4, 8, 20].

This systematic literature review was conducted to examine the applications of knowledge graphs (KGs) in fact-checking. A systematic search strategy was employed to locate relevant research articles using key search terms in academic databases. The identified studies were then carefully evaluated to ensure they directly addressed the research question and met specific inclusion criteria.

Knowledge graphs, structured representations of information comprised of triples (subject, predicate, object), serve as foundational structures for a wide range of applications, including knowledge search, recommendation systems, and decision support [8, 10]. Their structured representation of information makes them invaluable resources for fact-checking. By ensuring data quality and verifying the existence of specific information within the graph, fact-checking contributes to maintaining accuracy, expanding the knowledge base, detecting errors, and enhancing search capabilities [21, 23].

While often used interchangeably, knowledge graphs and knowledge bases have subtle differences. A knowledge base is a repository for structured information, typically factual statements about the real world. Knowledge graphs, a specialized type of knowledge base, leverage a graph structure for representing this information [14]. This structure allows entities to be linked by relationships, enabling more intricate querying and reasoning capabilities. The Resource Description Framework (RDF) is commonly used to encode knowledge within KGs as factual triples [8, 10].

Knowledge-based approaches are particularly valuable in the context of fact-checking, facilitating the extraction, verification, and representation of factual knowledge. By extracting information from diverse sources, such as text documents, and using it in creating knowledge graphs, these approaches enable more intricate querying and reasoning over the data [2, 24]. Their structured representation of knowledge, with explicitly defined relationships between entities, facilitates efficient and accurate fact verification by allowing machines to reason over chains of topics [20]. KGs also enhance the transparency of fact-checking by allowing users to see the evidence trail behind a claim, ultimately improving trust in the verification process [2, 15, 31].

Knowledge graphs can effectively handle incomplete information by using techniques like link prediction which can infer missing facts by leveraging the underlying graph

structure [8, 21]. Moreover, KGs can be seamlessly integrated with machine learning models to enhance fact-checking capabilities [12]. For instance, embedding-based methods can represent entities and relationships in a continuous vector space, facilitating more sophisticated reasoning and the prediction of missing facts [16, 17, 19].

The scalability of KGs allows them to efficiently handle large volumes of data, an essential feature for fact-checking applications that require real-time processing and verification of extensive information [1, 3]. Fact-checking frameworks utilizing KGs often employ graph-based classifiers to distinguish true and false facts. These classifiers leverage graph patterns to effectively predict fact veracity [2, 14].

Fact-checking models utilizing KGs assess claims and provide explanations through rich semantics, logical rule discovery, and web text mining, resulting in efficient labeling and higher quality outcomes. However, challenges such as data sparsity, noise, inconsistencies, and outdated information can impact the reliability of fact-checking outcomes [3, 6, 11, 14, 15, 17].

Addressing these issues and leveraging advancements in natural language processing, machine learning, and database technologies is crucial for developing more accurate, reliable, and transparent fact-checking systems. Knowledge graphs offer a promising solution by providing a structured representation of information that can help students understand complex topics and evaluate the credibility of information sources.

By providing students with a robust tool for exploring research topics and verifying information, Knowledge graph-based fact-checking frameworks can substantially enhance the learning experience. Future research should focus on addressing the challenges and opportunities presented by knowledge graphs, with the aim of creating more innovative and equitable learning environments that foster lifelong learning and active citizenship.

Keywords – misinformation, disinformation, fact checking, knowledge graphs

References

- [1] N. Ahmadi, J. Lee, P. Papotti, and M.Saeed, “Explainable fact checking with probabilistic answer set programming,” arXiv preprint arXiv:1906.09198, 2019.
- [2] A. Amayuelas, S. Zhang, X.S. Rao, and C. Zhang, “Neural methods for logical reasoning over knowledge graphs,” In International Conference on Learning Representations, 2022.
- [3] I. Augenstein, C. Lioma, D. Wang, L.C. Lima, C. Hansen, C. Hansen, and J.G. Simonsen, “MultiFC: A real-world multi-domain dataset for evidence-based fact checking of claims,” arXiv preprint arXiv:1909.03242, 2019.
- [4] S. Feng, V. Balachandran, Y. Bai, and Y. Tsvetkov, “Factkb: Generalizable factuality evaluation using language models enhanced with factual knowledge,” arXiv preprint arXiv:2305.08281, 2023.
- [5] M.H. Gad-Elrab, D. Stepanova, J. Urbani, and G. Weikum, “Exfakt: A framework for explaining facts over knowledge graphs and text,” In Proceedings of the twelfth ACM international conference on web search and data mining, January 2019, pp. 87-95.
- [6] M.H. Gad-Elrab, D. Stepanova, J. Urbani, and G. Weikum, “Tracy: Tracing facts over knowledge graphs and text,” In The world wide web conference, May 2019, pp. 3516-3520.
- [7] Z. Guo, M. Schlichtkrull, and A. Vlachos, “A survey on automated fact-checking,” Transactions of the Association for Computational Linguistics, 10, 2022, pp. 178-206.
- [8] H. Hammouchi, and M. Ghogho, “Evidence-aware multilingual fake news detection,” IEEE Access, 10, 2022, pp.116808-116818.

- [9] A. Hogan, E. Blomqvist, M. Cochez, C. d'Amato, G.D. Melo, C. Gutierrez, S. Kirrane, J.E.L. Gayo, R. Navigli, S. Neumaier, and A.C.N. Ngomo, "Knowledge graphs," ACM Computing Surveys [Csur], 54[4], 2021, pp. 1-37.
- [10] V.P. Huynh, and P. Papotti, "A benchmark for fact checking algorithms built on knowledge bases," In Proceedings of the 28th ACM International Conference on Information and Knowledge Management, November 2019, pp. 689-698.
- [11] S. Ji, S. Pan, E. Cambria, P. Marttinen, and S.Y. Philip, "A survey on knowledge graphs: Representation, acquisition, and applications," IEEE transactions on neural networks and learning systems, 33[2], 2021, pp. 494-514.
- [12] Y.J. Kim, B.W. Kwak, Y. Kim, R.K. Amplayo, S.W. Hwang, and J. Yeo, "Modularized transfer learning with multiple knowledge graphs for zero-shot commonsense reasoning," arXiv preprint arXiv:2206.03715, 2022.
- [13] J. Kim, S. Park, Y. Kwon, Y. Jo, J. Thorne, and E. Choi, "FactKG: Fact verification via reasoning on knowledge graphs," arXiv preprint arXiv:2305.06590, 2023.
- [14] J. He, W. Kryściński, B. McCann, N. Rajani, and Xiong, C. "Ctrlsum: Towards generic controllable text summarization," arXiv preprint arXiv:2012.04281, 2020.
- [15] P. Lin, Q. Song, Y. Wu, and J. Pi, "Discovering patterns for fact checking in knowledge graphs," Journal of Data and Information Quality [JDIQ], 11[3], 2019, pp. 1-27.
- [16] Y. Ling, F. Wu, S. Dong, Y. Feng, G. Karypis, and C.K. Reddy, "International Workshop on Multimodal Learning-2023 Theme: Multimodal Learning with Foundation Models," In Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, August 2023, pp. 5868-5869.
- [17] E. Maliaroudakis, K. Boland, S. Dietze, K. Todorov, Y. Tzitzikas, and P. Fafalios, "ClaimLinker: Linking text to a knowledge graph of fact-checked claims," In Companion Proceedings of the Web Conference 2021, April 2021, pp. 669-672.
- [18] M. Mountantonakis, and Y. Tzitzikas, "Using multiple RDF knowledge graphs for enriching ChatGPT responses," In Joint European Conference on Machine Learning and Knowledge Discovery in Databases, Cham: Springer Nature Switzerland, September 2023, pp. 324-329.
- [19] P. Nakov, D. Corney, M. Hasanain, F. Alam, T. Elsayed, A. Barrón-Cedeño, P. Papotti, S. Shaar, and G.D.S. Martino, "Automated fact-checking for assisting human fact-checkers," arXiv preprint arXiv:2103.07769, 2021.
- [20] R. Omar, O. Mangukiya, P. Kalnis, and E. Mansour, "Chatgpt versus traditional question answering for knowledge graphs: Current status and future directions towards knowledge graph chatbots," arXiv preprint arXiv:2302.06466, 2023.
- [21] L. Rakotoson, C. Letaillieur, S. Massip, and F. A. A. Laleye, "Extractive-boolean question answering for scientific fact checking," in Proceedings of the 1st International Workshop on Multimedia AI against Disinformation, ser. MAD '22. New York, NY, USA: Association for Computing Machinery, 2022, p. 27-34.
- [22] N. Seddari, A. Derhab, M. Belaoued, W. Halboob, J. Al-Muhtadi, and A. Bouras, "A hybrid linguistic and knowledge-based analysis approach for fake news detection on social media," IEEE Access, 10, 2022, pp. 62097-62109.
- [23] P. Shao, D. Zhang, G. Yang, J. Tao, F. Che, and T. Liu, "Tucker decomposition-based temporal knowledge graph completion.,," Knowledge-Based Systems, 238, 2022, pp. 107841.
- [24] A. Tchechmedjiev, P. Fafalios, K. Boland, M. Gasquet, M. Zloch, B. Zapilko, S. Dietze, and K. Todorov, "ClaimsKG: A knowledge graph of fact-checked claims," In The Semantic Web–ISWC 2019: 18th International Semantic Web Conference, Auckland, New Zealand, October 26–30, 2019, Proceedings, Part II 18, Springer International Publishing, 2019, pp. 309-324.
- [25] P. Yao, and D. Barbosa, "Typing errors in factual knowledge graphs: Severity and possible ways out," In Proceedings of the Web Conference 2021, April 2021, pp. 3305-3313.

Goran Paulin

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
Kreativni odjel d.o.o., Rijeka, Hrvatska
gp@kreativni.hr

Sustav za generiranje i podešavanje adaptivnih maritivnih sintsetova za klasifikaciju stanja mora i detekciju malih objekata na moru

Potrošnja brodskog goriva, a s njom i ekološki otisak, povećavaju se proporcionalno rastu brzine kretanja broda i stanja mora [1]. Brzinom broda upravlja posada, a stanje mora ovisi prvenstveno o vjetru. Stanje mora ocjenjuje se kombinacijom mjerena jačine lokalnog vjetra brodskim anemometrom i subjektivnom iskustvenom procjenom visine i oblika valova. Izražava se boforima, na ljestvici od 0 (tišina) do 12 (orkan) [2].

Razvoj računalnog vida i dubokih neuronskih mreža stvorio je preduvjete za optimizaciju potrošnje brodskog goriva objektivizacijom ocjene stanja mora u daljini, kontinuiranim automatiziranim promatranjem (kamerom) i korištenjem u tu svrhu istreniranog klasifikatora, čime je moguće mapirati nazučinkovitiji plovni put. Prilikom mapiranja potrebno je uzeti u obzir i potencijalne prepreke na putu (plovila, plutače, ljudi, otpad...), što je dijelom moguće učiniti koristeći aktualne detektore (npr. YOLOv9 [3]). Detektori načelno imaju problem s malim objektima (10-32 px), ali moguće ga je riješiti dodatnim treniranjem, koristeći odgovarajuće skupove podataka.

Klasična izrada skupova podataka za obje namjene, prikupljanjem foto i video zapisa s broda, je zahtjevna jer je potrebno naići na sva stanja mora i snimati more s odgovarajuće, unaprijed poznate visine, na različitim udaljenostima od obale, kako bi se riješio problem ambivalencije (slika mora manjeg bofora, snimljena s male visine može vizualno odgovarati slici mora višeg bofora, snimljenoj s veće visine). Zbog ambivalencije manualno anotiranje postaje izrazito subjektivno i utoliko podložno greškama. Potencijalno rješenje ovog problema je korištenje sintetičkih podataka i DCC metode korištenja alata za generiranje digitalnog sadržaja [4] koja omogućava upravljivost rezultatom (sintsetom, u smislu generiranja parova slika i anotacija), uz visok stupanj realizma nužan za premoščivanje jaza domene. U tu svrhu izgradili smo sustav za generiranje i podešavanje adaptivnih maritivnih sintsetova za klasifikaciju stanja mora i detekciju malih objekata na moru.

Modul za generiranje stanja mora sadrži alat za optičku kalibraciju koji omogućava korištenje različitih kamera i objektiva nepoznatnih specifikacija, a zadatak mu je odrediti točnu udaljenost svakog piksela na snimljenoj referentnoj slici. Ova informacija je nužna kako bi centralni dio istog modula mogao generirati 3D valove odgovarajućeg bofora (od 1 do 8) promatrane na potrebnoj udaljenosti, što je preduvjet adaptacije sintseta za treniranje klasifikatora namijenjenog kameri postavljenoj na ciljanoj visini. Osim valova simulira se i pjena. Valovi i pjena bazirani su na EncinoWaves [5] implementaciji unutar SideFX Houdini okruženja [6], razvijenoj koristeći TMA (Texel-Marsen-Arlöse) vrstu spektra [7]. Modul još sadrži i simulator gibanja objekata na morskoj površini u skladu s kretanjem valova (kao vizualnu referencu veličine valova pri podešavanju sustava), integrirani klasifikator treniran na realnim podacima (koji verificira upotrebljivost pojedine sintetizirane slike), prethodno kalibrirani podsustav fizikalno simuliranog neba (u funkciji rasvjete) i podsustav za distribuirano XPU renderiranje. Koristeći ovaj modul moguće je simulirati valove s pripadnom pjenom (pri željenom boforu) za 1,8 s (koristeći AMD 5950X CPU) i renderirati anotiranu sliku dimenzija 331 px za 2 s (koristeći 2x RTX 3090 GPU +

AMD 5950X CPU). Anotacija, osim klase (bofora), može sadržavati i visinu vala u svakom pikselu. Eksperimenti su pokazali da 90-minutno korištenje ovog modula (uz potrošnju 1,3 kW struje) može povećati točnost klasifikatora za 18%, a pritom i uštediti 15 tona goriva koliko bi tipični tanker potrošio prikupljajući realne slike za treniranje u istom vremenu.

Modul za generiranje malih objekata koristi modul za generiranje stanja mora (za generiranje mora), a sastoji se još od voxelizera (koji pretvara generiranu 3D geometriju u voksele, za referentu ocjenu dostatnosti detalja promatranih u rezolucijama 10-32 px), podsustava za prenamjenu mo-cap animacije (za generiranje 3D plivača), "brodogradilišta" (za proceduralno generiranje različitih vrsta 3D plovila koristeći 92 različita parametra, čime je sintset moguće adaptirati svim potrebnim tipovima plovila), centralnog podsustava za efikasno pozicioniranje malih objekata (koji omogućava proizvoljnu nepreklopajuću distribuciju N 3D objekata različitih klasa vidljivih u zadanom limitu broja piksela), generator Cryptomatte [8] maski (potrebnih za anotaciju) i anotator (koji uključuje i generiranje dubinskih mapa). Eksperimentalno testiranje učinkovitosti sintsetova proizvedenih ovim modulom je predstojeći zadatak.

Ključne riječi – sintetički podaci, maritimni sintset, valovi, stanje mora, detekcija malih objekata na moru

Literatura

- [1] N. Bialystocki i D. Konovessis, „On the estimation of ship's fuel consumption and speed curve: A statistical approach“, Journal of Ocean Engineering and Science, sv. 1, izd. 2, str. 157–166, tra. 2016, doi: 10.1016/j.joes.2016.02.001.
- [2] D. Wheeler i C. Wilkinson, „From Calm to Storm, the Origins of the Beaufort Wind Force Scale“, Mar Mirror, sv. 90, izd. 2, str. 187–201, sij. 2004, doi: 10.1080/00253359.2004.10656896.
- [3] C.-Y. Wang, I.-H. Yeh, i H.-Y. M. Liao, „YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information“, 2024. [Na internetu]. Dostupno na: <https://arxiv.org/abs/2402.13616>
- [4] G. Paulin i M. Ivasic-Kos, „Review and analysis of synthetic dataset generation methods and techniques for application in computer vision“, Artif Intell Rev, sv. 56, izd. 9, str. 9221–9265, 2023, doi: 10.1007/s10462-022-10358-3.
- [5] C. J. Horvath, „Empirical directional wave spectra for computer graphics“, u Proceedings of the 2015 Symposium on Digital Production, u DigiPro '15. New York, NY, USA: ACM, kol. 2015, str. 29–39. doi: 10.1145/2791261.2791267.
- [6] „Houdini Help“. Pristupljeno: 17.3.2024. [Na internetu]. Dostupno na: <https://www.sidefx.com/docs/houdini/ocean/oceanspectra.html>
- [7] S. A. Hughes, „The TMA shallow-water spectrum description and applications“, 1984. Pristupljeno: 17.3. 2024. [Na internetu]. Dostupno na: <https://hdl.handle.net/11681/12522>
- [8] J. Friedman i A. Jones, „Cryptomatte“. Pristupljeno: 22.4.2024. [Na internetu]. Dostupno na: <https://github.com/Psyop/Cryptomatte>

Milan Petrović

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
milan.petrovic@inf.uniri.hr

Upotreba kompleksnih mreža za mjerjenje utjecaja izolacije na promjene u mrežama socijalne interakcije *Drosophila melanogaster*

Razumijevanje načina na koji okolišni i društveni uvjeti utječu na strukturu mreža društvenih interakcija ključno je u bihevioralnoj biologiji. Životinje često mijenjaju svoje društvene obrasce interakcije kada su izložene različitim društvenim iskustvima [1, 2]. *Drosophila melanogaster* je dobro uspostavljen modalni organizam za proučavanje društvenog ponašanja zbog svoje jednostavnosti, lakoće eksperimentiranja i bogatog repertoara ponašanja [3-5]. U ovom istraživanju koristimo teoriju kompleksnih mreža kako bismo kvantificirali i usporedili mreže društvenih interakcija *Drosophila melanogaster* pod dva različita uvjeta: život u grupi i socijalna izolacija. Konstruiranjem i analizom društvenih mreža za svaki uvjet, cilj nam je razumjeti kako socijalna deprivacija utječe na strukturu društvenih interakcija [6].

Eksperiment je konstruiran tako da mušice dijelimo u dvije tretirane skupine:

1. Osnovna skupina (socijalna kohezija): Mušice žive zajedno u grupi pet dana. Petog dana mjere se njihove društvene interakcije u zajedničkoj areni, a na temelju njihovih interakcija konstruira se društvena mreža.
2. Izolirana skupina (socijalna deprivacija): Mušice žive u izolaciji pet dana. Petog dana se zajedno grupiraju u areni, a njihove interakcije se snimaju kako bi se konstruira društvena mreža.

Za svaki tretman izvodimo 20 neovisnih ponavljanja, a svaka skupina sadrži 12 mušica. Društvene interakcije kvantificiramo kroz broj interakcija između jedinki i ukupno vrijeme provedeno u interakciji između jedinki, koji su predstavljeni kao težine veza u našim mrežama. Izgradnja i analiza mreža provedena je tako da podatke o interakcijama koristimo za izgradnju društvenih mreža za obje eksperimentalne skupine. Čvorovi u mreži predstavljaju pojedinačne mušice, a težinske veze predstavljaju snagu društvenih veza na temelju broja ili trajanja interakcija. Za usporedbu mreža izračunavamo nekoliko ključnih mjera u mrežama:

- Centralnost međupoloženosti: Mjeri utjecaj čvora na protok informacija unutar mreže.
- Centralnost blizine: Odražava koliko učinkovito čvor može pristupiti drugim čvorovima u mreži.
- Koeficijent grupiranja: Kvantificira tendenciju čvorova da formiraju čvrsto povezane klastere.
- Asortativnost: opisuje tendenciju sličnih čvorova (u smislu stupnja) da se međusobno povezuju.
- Heterogenost stupnja: Prikazuje varijabilnost u distribuciji stupnja mreže.

Kako bismo procijenili jesu li uočene razlike između dviju skupina statistički značajne, generiramo dvije vrste nasumičnih mreža za usporedbu. **Pseudo-društvene mreže putem nasumičnog grupiranja mušica:** iz grupe mušica u svim grupama, nasumično odabiremo 12 mušica (jednu iz svake grupe) i normaliziramo ih u prostoru. Mjerimo njihove društvene interakcije i iz podataka gradimo pseudo društvene mreže. Ovaj nam pristup omogućuje kontrolu učinka uzorka slučajne interakcije, i stvaranje mreža na koje ne utječe socijalna okolina. **Tehnika nasumičnog povezivanja čvorova:** U ovom pristupu zadržavamo izvore

težine veza, ali ih nasumično ponovno dodjeljujemo među čvorovima. Ovaj pristup čuva ukupnu učestalost i trajanje interakcije, ali uklanja izvornu društvenu strukturu, što nam omogućuje testiranje robusnosti mrežnih metrika.

Pretpostavljamo da će se društvene mreže izoliranih mušica značajno razlikovati od onih mušica koje žive u skupini. Konkretno, očekujemo da će izolirane mušice pokazati niže koeficijente grupiranja i asortativnost, što ukazuje na smanjenu društvenu povezanost i sklonost homogenim interakcijama. Također predviđamo povećani stupanj heterogenosti, sugerirajući da društvena izolacija može dovesti do nejednakog sudjelovanja u društvenim interakcijama.

Ova studija pruža nove uvide u društveno ponašanje *Drosophila melanogaster* u različitim uvjetima okoliša. Koristeći teoriju kompleksnih mreža, demonstriramo kvantitativni okvir za razumijevanje promjena u ponašanju koje proizlaze iz društvene izolacije. Ova otkrića imaju šire implikacije za razumijevanje kako socijalna deprivacija utječe na ponašanje pojedinca i grupnu dinamiku životinjskih vrsta.

Ključne riječi – kompleksne mreže, mreže socijalnih interakcija, nasumične mreže

Literatura

- [1] J. A. Jezovit, N. Alwash, and J. D. Levine, “Using Flies to Understand Social Networks,” *Front. Neural Circuits*, vol. 15, p. 755093, Dec. 2021, doi: 10.3389/fncir.2021.755093.
- [2] M. Stojkovic et al., “Using a Combination of Novel Research Tools to Understand Social Interaction in the *Drosophila melanogaster* Model for Fragile X Syndrome,” *Biology*, vol. 13, no. 6, p. 432, Jun. 2024, doi: 10.3390/biology13060432.
- [3] M. Petrović, A. Meštrović, R. Andretić Waldowski, and A. Filošević Vujnović, “A network-based analysis detects cocaine-induced changes in social interactions in *Drosophila melanogaster*,” *PLOS ONE*, vol. 18, no. 3, p. e0275795, Mar. 2023, doi: 10.1371/journal.pone.0275795.
- [4] F. Rigo, A. Filošević, M. Petrović, K. Jović, and R. Andretić Waldowski, “Locomotor sensitization modulates voluntary self-administration of methamphetamine in *Drosophila melanogaster*,” *Addict. Biol.*, vol. 26, no. 3, p. e12963, 2021.
- [5] B. Samardžija et al., “Transgenic *Drosophila melanogaster* Carrying a Human Full-Length DISC1 Construct (UAS-hfIDISC1) Showing Effects on Social Interaction Networks,” *Curr. Issues Mol. Biol.*, vol. 46, no. 8, pp. 8526–8549, Aug. 2024, doi: 10.3390/cimb46080502.
- [6] G. Liu et al., “A simple computer vision pipeline reveals the effects of isolation on social interaction dynamics in *Drosophila*,” *PLOS Comput. Biol.*, vol. 14, no. 8, p. e1006410, Aug. 2018, doi: 10.1371/journal.pcbi.1006410.

Andrija Poleksić

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
andrija.poleksic@uniri.hr

Priprema skupa podataka za ekstrakciju relacija u domeni klimatskih promjena

Globalno zatopljenje i klimatske promjene imaju dubok i dugotrajan učinak na globalne ekosustave, vremenske prilike, razinu mora i ljudsko društvo, što predstavlja prijetnju bioraznolikosti te izgledima za održivu budućnost [1]. Unatoč općeprihvaćenosti i znanstvenoj potkrepi, udio populacije još uvijek poriče ljudski utjecaj na klimatske promjene (engl. *climate denial*). Poricanje ljudskog utjecaja na klimatske promjene, između ostalog, potiče iz pogrešnih uvjerenja ili korporativnih utjecaja motiviranih profitom. Istraživanje koje provodi Areni [2] proučava dinamiku dviju grupa u kontekstu prihvaćanja i poricanja klimatskih promjena na Reddit-u. Uočeno je da se poricatelji u argumentaciji većinski oslanjaju na alternativne izvore informacija (npr. blogove i društvene medije), dok se druga grupa oslanja na znanstvena istraživanja. S druge strane, ubrzan rast objavljenih podataka i informacija, uključujući i znanstvena istraživanja (radove), iziskuje automatizaciju procesiranja u svrhu pridobivanja činjenica te donošenja informiranih (istraživačkih) odluka, odnosno sprječavanje informacijskih poremećaja (npr. dezinformacija) u domeni klimatskih promjena.

Motivirani navedenim izazovima, problemom klimatskih promjena i „poplavom“ informacija, u istraživačkom radu [3] detaljno opisujemo postupke prikupljanja i obrade podataka – objavljenih znanstvenih radova iz dome klimatskih promjena. U znanstvenim radovima su podaci zapisani u tekstualnom (nestrukturiranom) obliku te je za njihovo strukturirano procesiranje potrebno primijeniti metode izlučivanja informacija (engl. *Information Extraction* - IE). Točnije, razmatraju se postupci pripremu podataka za izlučivanje relacija (engl. *Relation Extraction* - RE) iz teksta te se analiziraju svojstva dobivenog skupa podataka. Prikazat će se rezultati na uzorku od ~5% pripremljenog skupa podataka. Nastavno na istraživanja [4, 5], u kojima je pokazana važnost skupa podataka za predtreniranje velikih jezičnih modela (engl. *Large Language Models* - LLMs) tipa enkoder, u ovom radu su uspoređene količine podataka s relevantnim velikim jezičnim modelima – BERT [6], SciBERT [7] i ClimateBERT [8]. Usporedbom u Tablici 1 je razvidno da je prikupljena količina podataka dostašna za postupke predtreniranja za adaptaciju na domenu (engl. *Domain Adaptive Pretraining*) – odnosno postupak dodatnog učenja postojećeg jezičnog modela nad vlastitim domenskim podacima u svrhu poboljšanja performansi modela za novu domenu [9].

Model	Skup podataka	# token	avg. r
BERT	BooksCorpus (800 mil. riječi) i engleska Wikipedija (2,500 mil. riječi)	3,30 mlrd.	/
SciBERT	1.14 mil. znanstvenih radova iz baze Semantic Scholar	3,17 mlrd.	154
ClimateBERT	Novinski članci, sažeci znanstvenih radova i korporativna izvješća o klimatskim promjenama i održivosti	0,22 mlrd.	/
Naš skup	~200,000 znanstvenih radova vezanih uz klimatske promjene	1,25 mlrd.	242

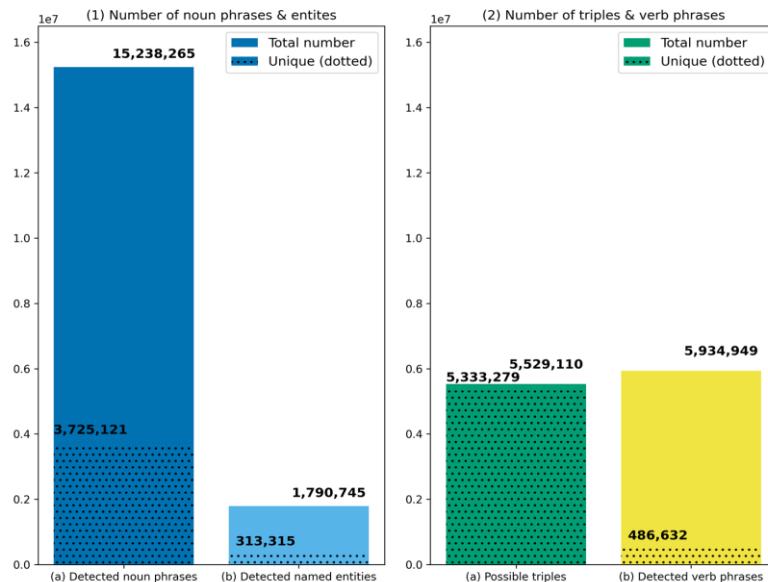
Tablica 1. Usporedba podataka za učenje: Skup podataka korišten za predtreniranje modela s ukupnim brojem tokena (# token) i prosječnim brojem rečenica po dokumentu (avg. r) ako je primjenjivo.

Nadalje, kako bismo analizirali primjerenoš skupa podataka za daljnje postupke izlučivanja relacija, na uzorku od 5% (10.000 znanstvenih radova), provodi se automatsko označavanje vrsta riječi (engl. *Part-of-Speech tagging* - POS) te prepoznavanje imenovanih entiteta (engl. *Named Entity Recognition* - NER) pomoću gotovih neuralnih modela iz

biblioteke *flair* [10]. Na temelju označenih vrsta riječi heuristički definiramo imenske skupine (engl. *Noun phrase*) te glagolske fraze (engl. *Verb phrase*) kao prototipne entitete, odnosno relacije među entitetima prema navedenom:

1. **Imenske skupine:** Cardinal number (CD), Adjective (JJ), Determiner (DT), Noun (NN), Foreign word (FW), Possessive ending (POS), Hyphen (HYPH), Symbol (SYM);
2. **Glagolske fraze:** Verb (VB), "to" (TO), Adverb (RB), Modal (MD).

Ova heuristika dopušta nam analizu potencijalnih trojki relacija (entitet–relacija–entitet). Slika 1 prikazuje ukupan broj glagolskih fraza (~6 mil.), imenskih skupina (~15 mil.) te imenovanih entiteta (~1.8 mil.) na uzorku od ~2.4 mil. rečenica. Slika 1 prikazuje i broj jedinstvenih vrijednosti za svaku od četiri navedene skupine.



Slika 1. Broj imenskih skupina, entiteta, glagolskih fraza i trojki: Broj imenskih skupina (1a), imenovanih entiteta (1b), potencijalnih trojki (2a) i glagolskih fraza (2b) s brojem jedinstvenih vrijednosti (točkasto) na uzorku od 10,000 radova.

Nesrazmjer količine imenskih skupina i imenovanih entiteta (~8:1) ukazuje na potrebu za domenskim NER modelom, nastavno, broj jedinstvenih glagolskih fraza (486.632), iako obećavajući, mora biti smanjen na broj realistične primjene za klasifikator. Uočena je visoka sličnost kod pojedinih primjera glagolskih fraza: „is shown”, „shows”, „are shown” i „has been shown”; ukazuje na sljedeći korak poboljšanja kvalitete podataka – deduplikaciju.

U radu su postavljeni temelji za izlučivanje relacijskih trojki, gdje se očekuje da relacije postoje kod glagolskih fraza, koje se nalaze između imenovanih entiteta (heurističkih imenskih skupina ili entiteta koje detektira NER model). Nadalje, pretpostavljamo da će dobiveni rezultati omogućiti informiranju automatsku anotaciju relacija pomoću velikih jezičnih modela slično primjerima potencijalnih relacija/entiteta u rečenicama:

1. „For example, Atlantic cyclones have been well documented as causing high surge levels and heavy precipitation.” - (*Atlantic cyclones*, *cause*, *high surge levels*)
2. „El Niño–Southern Oscillation (ENSO) is another important factor for winter temperature in China.“ - (*ENSO*, *affects*, *winter temperature in China*)

Ključne riječi – izlučivanje relacija, NER, POS, predtreniranje jezičnih modela

Literatura

- [1] H.-G. et al, Impacts of 1.5°C Global Warming on Natural and Human Systems, in: Global Warming of 1.5 °C. An IPCC Special Report on the impacts of global warming of 1.5 °C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty, Cambridge University Press, Cambridge, UK and New York, NY, USA, 2018, pp. 175–312. doi:10.1017/9781009157940.005.
- [2] C. S. Areni, Motivated Reasoning and Climate Change: Comparing news sources, politicization, intensification, and qualification in denier versus believer subreddit comments, *Applied Cognitive Psychology* 38 (2024). doi:10.1002/acp.4167.
- [3] A. Poleksić, S. Martinčić-Ipšić, Towards Dataset for Extracting Relations in the Climate-Change Domain. Heraklion: CEUR:Joint proceedings of the 3rd International workshop one knowledge graph generation from text (TEXT2KG) and DQMLKG co-located with the Extended Semantic Web Conference (ESWC 2024); 2024
- [4] A. Poleksić. 2023. Ekstrakcija relacija za automatsku konstrukciju grafa znanja. In Zbornik sažetaka - Znanstveni skup doktorskih studenata informatike: INFCON23, Sanda Martinčić-Ipšić, Marina Ivašić-Kos, and Slobodan Beliga (Eds.). Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Croatia, 23.
- [5] A. Poleksić, S. Martinčić-Ipšić, Effects of Pretraining Corpora on Scientific Relation Extraction Using BERT and SciBERT // SEMANTICS 2023 EU: 19th International Conference on Semantic Systems Leipzig, Njemačka, 20.09.2023-22.09.2023
- [6] J. Devlin, M. Chang, K. Lee, and K. Toutanova, BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding, arXiv preprint arXiv:1810.04805, 2019. <https://arxiv.org/abs/1810.04805>.
- [7] I. Beltagy, K. Lo, and A. Cohan, SciBERT: A Pretrained Language Model for Scientific Text, in Proc. Conf. Empirical Methods in Natural Language Processing (EMNLP), 2019.
- [8] N. Webersinke et al., ClimateBert: A Pretrained Language Model for Climate-Related Text, 17. prosinac 2022., arXiv: arXiv:2110.12010. doi: 10.48550/arXiv.2110.12010.
- [9] S. Gururangan, et al. Don't Stop Pretraining: Adapt Language Models to Domains and Tasks, in Proc. 58th Annual Meeting of the Association for Computational Linguistics, Online, Jul. 2020, pp. 8342–8360. doi: 10.18653/v1/2020.acl-main.740..
- [10] A. Akbik et al., FLAIR: An Easy-to-use Framework for State-of-the-art NLP, in Proc. NAACL 2019, 2019 North American Chapter Assoc. for Computational Linguistics, 2019, pp. 54–59.

Relacijska baza podataka kao element konceptualnog okvira Node of Knowledge (NOK)

Question Answering (QA) sustavi imaju za cilj odgovarati na pitanja postavljena prirodnim jezikom, odnosno nude automatizirani pristup traženja odgovora na ta pitanja [1]. Zajedničko svim QA sustavima su tri osnovne faze kroz koje se prolazi u pronalaženju odgovora [2], [3], [4], [5]: analiza pitanja, traženje kandidata za odgovor i odabir odgovora.

Konceptualni okvir *Node of Knowledge* (NOK), kao i drugi QA sustavi, ima za cilj analizirati i interpretirati tekstualne podatke, te na temelju njih generirati odgovore koji što preciznije i točnije odgovaraju na postavljena pitanja. Različiti QA sustavi za to koriste različite metode i algoritme. Metoda NOK, koja je sastavni dio konceptualnog okvira NOK, za zapisivanje tekstualnog znanja koristi relacijsku bazu podataka. Relacijska baza podataka sastoji se od međusobno povezanih relacija (tablica) koje inicialno nisu namijenjene za upisivanje tekstualnog znanja. Analizom rečenica prirodnog jezika, riječi i njihova značenja te načina i redoslijeda na koji se riječi povezuju u rečenicu, metoda NOK definira pravila transformacije kojima se rečenice prilagođavaju na način da se riječi u njima hijerarhijski organiziraju što ih priprema za unos u relacijsku bazu podataka. Prilagođavanje rečenica provodi se njihovim pretvaranjem u formalizirani NOK zapis (FNOK) i prema pravilima koja su definirana za pojedine vrste riječi: za glagole [6], imenice [7], pridjeve [8], priloge i prijedloge [9], brojeve i većinu zamjenica [10].

Sustav transformacije teksta u relacijsku bazu podataka temeljen na NOK-u sastoji se od tri osnovna procesa kojima se omogućuje učitavanje tekstualnog znanja u relacijsku bazu podataka i generiranje odgovora na pitanja. Prvi proces priprema tekst za transformaciju. U drugom procesu se tekst transformira uz pomoć NOK metode, obogaćuje i povezuje s rječnikom te upisuje u relacijsku bazu podataka da bi se u trećem procesu postavljanjem upita iz relacijske baze generirali odgovori na postavljena pitanja. U prvoj inačici [10] sustav je izrađen i testiran na rečenicama koje sadrže jednu radnju/glagol dok je u drugoj inačici sustav proširen, odnosno provedeno je proširivanje područja njegove primjene na odabrane tipove složenih što je zahtijevalo izmjene i nadogradnju prethodno izrađenih modela [11]. Za izradu modela podataka korištena je metodologija za razvoj informacijskih sustava – MIRIS [12] i koncepti NOK metode [13]. Za implementaciju relacijske baze podataka u obje inačice korištena je Oracle relacijska baza.

Ključne riječi – konceptualni okvir Node of Knowledge (NOK), relacijska baza podataka, predstavljanje znanja

Literatura

- [1] M. Caballero, »A brief survey of question answering systems,« International Journal of Artificial Intelligence & Applications (IJAI), 12(5), 2021.
- [2] J. Prager, E. Brown, A. Coden i D. Radev, "Question-answering by predictive annotation," Proceedings of the 23rd annual international ACM SIGIR conference on Research and development in information retrieval, pp. 184-191, 2000.
- [3] E. H. Hovy, L. Gerber, U. Hermjakob, M. Junk i C. Y. Lin, "Question Answering in Webclopedia," TREC, Vol. 52, pp. 53-56, 2000.

- [4] A. Iftene, Textual Entailment. Ph.D Thesis, Cuza University, Faculty of Computer Science, 2009.
- [5] B. Ojokoh i E. Adebisi, "A review of question answering systems," Journal of Web Engineering 17.8, pp. 717-758, 2018.
- [6] M. Ašenbrener Katić, S. Čandrić i M. Pavlić, "Modeling of verbs using the node of knowledge conceptual framework," u 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2018.
- [7] M. Ašenbrener Katić, S. Čandrić i M. Pavlić, "Nouns in the Conceptual Framework "Node of Knowledge"," Tehnički vjesnik / Technical Gazette, Vol. 28/No. 6, p. in the process of publication, 2021.
- [8] M. Pavlić, Z. D. Han, A. Jakupovic, M. Asenbrener Katic i S. Candrllic, "Adjective representation with the method Nodes of Knowledge.", u In 2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), 2017.
- [9] M. Ašenbrener Katić, S. Čandrić i M. Rauker Koch, "Adverb and Preposition Representation in Croatian and English using the Node of Knowledge Method," u Central European Conference on Information and Intelligent Systems, Dubrovnik, 2022.
- [10] M. Ašenbrener Katić, Sustav za integraciju relacijske baze podataka i jednostavnih rečenica prirodnog jezika, doktorska disertacija, Rijeka: Odjel za informatiku, Sveučilište u Rijeci, 2017.
- [11] M. Rauker Koch, Proširivanje konceptualnog razvojnog okvira NOK-a za transformaciju, doktorska disertacija, Rijeka: neobjavljeno, 2024.
- [12] M. Pavlić, Oblikovanje baze podataka, Rijeka: Odjel za informatiku, Sveučilište u Rijeci, 2011.
- [13] A. Jakupović, M. Pavlić i Z. Dovedan Han, "Formalisation method for the text expressed knowledge," Expert Systems with Applications, 41(11), pp. 5308-5322, 2014.

Ema Smolić

Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska
ema.smolic@fer.unizg.hr

Generativna UI temeljena na velikim jezičnim modelima i evaluacija studentskog koda: kvalitativna i kvantitativna analiza

Nedavni napreci na polju generativne umjetne inteligencije (UI) sa sobom donose i potencijalne nove primjene na mnogim poljima. U području obrazovanja posebno su zanimljive mogućnosti korištenja alata generativne UI u svrhu ekstrakcije i/ili ekstrapolacije informacija radi automatizacije povratne informacije na učeničke ili studentske uratke [1, 2].

U ovom radu ispituje se sposobnost široko korištenih komercijalnih velikih jezičnih modela (engl. *Large language models - LLM*) za generiranje komentara o kvaliteti izvornog kôda te njegovo numeričko ocjenjivanje.

Iako postoje brojni radovi na temu automatske evaluacije kôda, čak i u sličnom – pedagoškom – kontekstu [1-7], ovo je istraživanje prvo koje se bavi ispitivanjem javno dostupnih komercijalnih LLM-ova kao pomoćnih alata u generiranju komentara i numeričke ocjene na stvaran studentski programski kôd. Kôd pritom može bit potpuno logički i stilski ispravan, no i neprevodiv, ili s manjim greškama, što alat mora prepoznati i na odgovarajući način vrednovati u izlazu.

Istraživanje [8] se sastoji od dva eksperimenta, a u oba su uključena dva komercijalna LLM-a: GPT-3.5 te Gemini. Prvi se odnosi na zero-shot generiranje komentara i ocjene na studentski kôd. Jezičnom se modelu na početku eksperimenta zadaje zadatak (ocjena isječaka studentskog programskog kôda u jeziku C, koji se proslijeđuju jedan po jedan), osnovna očekivanja od izlaza (ocjena u postotku i komentar) te kriteriji ocjenjivanja (funkcionalni zahtjevi koda). Nije zadan oblik komentara niti su proslijeđene dodatne informacije o kontekstu. Nakon što se dvama LLM-ovima prezentiralo svih 50 programskih isječaka, komentari i ocjene usporedili su se s onima prethodno dodijeljenima od strane asistenata na predmetu. Tri su istraživača za svaki od dva modela nezavisno ocijenila a) točnost generiranog komentara (s asistentskim komentarom kao orijentirom) cjelobrojnom ocjenom 1 - 5, te b) stupanj korespondencije između generiranog komentara i dodijeljene ocjene cjelobrojnom ocjenom 1 - 3. U oba slučaja viša ocjena istraživača znači veću točnost odnosno razinu korespondencije. Slaganje ocjenjivača (engl. *inter-rater reliability, IRR*) osigurano je zahtjevom da Krippendorfov α -koeficijent u svim slučajevima iznosi barem 0,8. Također, sposobnost generiranja komentara i sljedivost ocjene evaluirani su kvalitativno.

Drugi je eksperiment slobodnijeg oblika i bavi se provjerom metode *few-shot promptinga*, tj. zadavanja nekoliko primjera izlaza modelu kako bi mogao prilagoditi svoj izlaz. Odabранo je 11 od 50 testnih primjera na kojima je gori od dva modela testirana u prvom eksperimentu imao najveće odstupanje generirane ocjene od one asistentske. Naizmjenično su korišteni za testiranje *few-shot* metode kao jedan testni uz preostalih deset s asistentskim komentarima i ocjenama kao primjerima željenog izlaza. Uspjeh metode evaluiran je kvalitativno.

Rezultati eksperimenata pokazuju da testirani veliki jezični modeli mogu biti korisni kao podrška ocjenjivanju, no još uvijek zahtijevaju ljudski nadzor. Točnije, podaci prikupljeni u prvom eksperimentu upućuju na to da od dvaju modela na zadatku generiranja relevantnih komentara na programski kôd, GPT-3.5 postiže bolje rezultate od

Geminija – kako s gledišta prosječne ocjene (dodijeljene od strane istraživača – ocjenjivača), tako i prema učestalosti nisko ocijenjenih komentara – iako su oba modela općenito gledajući u tom zadatku vrlo dobra (prosječna ocjena zaokružena na 4). Također, oba modela pokazuju razuman, odnosno dobar stupanj usklađenosti generirane ocjene i generiranog komentara (zaokružena ocjena 3). Ipak, opisan uspjeh modela ne može se smatrati dovoljno dobrim za samostalno ocjenjivanje, već kao indikacija potencijala za korištenje u svrhu potpore evaluaciji studentskog programskog kôda od strane ljudskog eksperta. Nadalje, kvalitativna analiza komentara i generiranih ocjena upućuje na način generiranja ocjena koji nije sukladan stvarnom znanju iz područja ni pedagoškim principima. Konkretno, iako je općenito poželjna činjenica da model uspješno prepoznae stilističke nesavršenosti, koje i ističe u komentaru, njihov utjecaj u ocjeni ravnopravan većim pogreškama poput onih logičkih nema uporište u pedagogiji niti se u konkretnom području razvoja softvera može smatrati opravdanim. Taj je fenomen potrebno kontrolirati metodama u koje spada i *few-shot prompting*, tj. pružanje konkretnih primjera željenog ponašanja modelu pored osnovnih *zero-shot* uputa, što je osnova drugog eksperimenta. Naposlijetu, statistička analiza samih dodijeljenih ocjena od strane ljudskog eksperta (asistenta na predmetu) te onih dodijeljenih od strane oba LLM-a pokazuje da ispitani modeli imaju značajno nižu sklonost generiranja vrlo niskih te vrlo visokih ocjena, čak i kada je asistent označio rješenje potpuno točnim. Sukladno tome, učestalost ocjena u srednjem rasponu (~65% - ~75%) kod LLM-ova je značajno veća nego kod ljudskog asistenta. Ove se razlike potencijalno mogu objasniti prethodno istaknutim odstupanjima u pristupu izračuna postotne ocjene, no razna su druga objašnjenja, poput težnje modela prema srednjim ocjenama u svrhu minimizacije pogreške, također moguća. U svakom slučaju, iako je pokazano da su generirani komentari kod testiranih modela smisleni i mogu pružiti dodatni uvid ili potporu ocjenjivanju te da ocjene izražene u postocima slijede iz njih na razumnoj razini, odstupanja u tim ocjenama između čovjeka i LLM-a, kao moguća posljedica različitih kriterija, prevelika su da bi se modeli mogli smatrati prikladnima za automatsku dodjelu numeričkih ocjena.

Kvalitativna analiza rezultata drugog eksperimenta, pak, upućuje na to da u našoj eksperimentalnoj okolini upotrijebljeni modeli nisu dovoljno fleksibilni da nauče heuristiku bodovanja iz deset konkretnih primjera koji sadrže programski kod, komentar asistenta i ocjenu asistenta. Ipak, u nekim su slučajevima prilagodili jezik, stil i formu komentara onima iz primjera. Svejedno, često je bilo potrebno opetovano ispravljanje modela ili ponavljanje konteksta, zbog čega se testirani modeli ne mogu smatrati prikladnima za prilagodbu na opisanoj razini.

Zaključujemo da komercijalni LLM-ovi mogu poslužiti kao potpora evaluaciji realnog studentskog koda, pogotovo u kvalitativnom aspektu, no uz obavezan ljudski nadzor i/ili prilagodbu kriterija evaluacije.

Ključne riječi – LLM, evaluacija koda, UI u obrazovanju

Literatura

- [1] R. Balse, B. Valabolu, S. Singhal, J. M. Warriem and P. Prasad, Investigating the potential of gpt-3 in providing feedback for programming assessments, vol. 1, 2023.
- [2] Anishka, A. Mehta, N. Gupta, A. Balachandran, D. Kumar and P. Jalote, "Can chatgpt play the role of a teaching assistant in an introductory programming course?", ArXiv, vol. abs/2312.07343, 2023.

- [3] J. Leinonen, P. Denny, S. MacNeil, S. Sarsa, S. Bernstein, J. Kim, et al., Comparing code explanations created by students and large language models, 2023.
- [4] M. Carey, Code review gpt, 02 2023, [online] Available: <https://github.com/mattzcarey/code-review-gpt/>.
- [5] R. Balse, V. Kumar, P. Prasad and J. M. Warriem, "Evaluating the quality of llm-generated explanations for logical errors in cs1 student programs", Proceedings of the 16th Annual ACM India Compute Conference, 2023.
- [6] N. Kiesler, D. Lohr and H. Keuning, "Exploring the potential of large language models to generate formative programming feedback", 2023 IEEE Frontiers in Education Conference (FIE), pp. 1-5, 2023.
- [7] I. Azaiz, O. Deckarm and S. Strickroth, "Ai-enhanced auto-correction of programming exercises: How effective is gpt-3.5?", ArXiv, vol. abs/2311.10737, 2023.
- [8] E. Smolić, M. Pavelić, B. Boras, I. Mekterović and T. Jagušt, "LLM Generative AI and Students' Exam Code Evaluation: Qualitative and Quantitative Analysis," 2024 47th MIPRO ICT and Electronics Convention (MIPRO), Opatija, Croatia, 2024, pp. 1261-1266, doi: 10.1109/MIPRO60963.2024.10569820.

Romeo Šajina

Juraj Dobrla University of Pula, Faculty of Informatics, Pula, Croatia

romeo.sajina@gmail.com

Modeling Spatial and Temporal Features in Multi-Person Pose Forecasting

In the context of multi-person pose forecasting, accurate modeling of spatial and temporal features is essential for predicting human motion dynamics. The spatial component refers to the relationships between joints or individuals in a scene, while the temporal component focuses on the progression of poses over time. Various models leverage different architectures to effectively capture these aspects, including Graph Convolutional Networks (GCNs), Recurrent Neural Networks (RNNs), Temporal Convolutional Networks (TCNs), and Transformer-based architectures.

Graph Convolutional Networks (GCNs) have become a prevalent method for capturing spatial dependencies between joints or body parts in pose forecasting. In such models, the human skeleton is represented as a graph, where the nodes correspond to joints, and edges represent the physical or logical connections between them. The LTD model [1], for example, employs 12 GCN blocks with residual connections to capture spatial relationships within a single person's pose over time. Similarly, the SocialITGCN model [2] extends this concept to multi-person scenarios by constructing a spatial adjacency matrix based on the Euclidean distance between individuals, thus capturing inter-person interactions alongside intra-person spatial dynamics. Additionally, GCNs have been applied in future motion forecasting, where the spatial connections between joints can be leveraged for predicting more realistic motion. The approach in [3] emphasizes using GCNs to predict future poses by encoding human joint dependencies effectively, highlighting the suitability of GCNs for long-term spatial forecasting. Incorporating dynamic graph structures allows models to better adapt to varying human poses and interactions.

Recurrent Neural Networks (RNNs) and their variants, such as Long-Short-Term Memory (LSTM) and Gated Recurrent Units (GRUs), have been widely used to capture temporal dependencies in human pose forecasting. These models process sequences of data step by step, maintaining a memory of previous time steps, which makes them suitable for learning temporal dynamics in pose data. For example, DVITA [4] applies RNNs to model human motion sequences by encoding past pose information and forecasting future motion trajectories. The ability of RNNs to retain long-term dependencies makes them useful for tasks that require understanding how poses evolve over time, particularly in scenarios where the temporal aspect of the motion is complex and highly variable. While effective, RNNs often suffer from vanishing gradient problems and computational inefficiencies when dealing with long sequences, which has led to the adoption of more advanced techniques like Temporal Convolutional Networks (TCNs) and attention-based models.

Temporal dependencies, crucial for understanding the flow of motion, have been addressed using various methods. Temporal Convolutional Networks (TCNs) have been popular for modeling temporal sequences by applying convolution operations over time. For instance, SocialITGCN [2] combines GCNs with TCNs to capture both spatial and temporal dependencies in a unified framework, providing an effective mechanism for forecasting motion in multi-person settings. In addition to TCNs, Transformer-based models have demonstrated significant improvements in modeling long-range temporal

dependencies. These models rely on self-attention mechanisms, enabling efficient modeling of relationships between poses across time. SoMoFormer [5], for example, applies attention to sequences of joints rather than entire poses, enabling the simultaneous prediction of future trajectories for all joints in a multi-person scene. TBiFormer [6] takes a different approach by breaking down the human body into multiple parts, modeling their temporal interactions separately through a Temporal Body Partition Module, which improves the precision of temporal feature extraction at a fine-grained level. Attention mechanisms also facilitate the integration of social dynamics in multi-person forecasting. The Multi-Range Transformer (MRT) [7] incorporates both local and global attention mechanisms, allowing the model to attend to individual movements while simultaneously capturing social interactions across the entire scene. This dual attention structure improves the model's ability to predict coordinated actions between individuals. JRTformer [8], another Transformer-based model, enhances the attention mechanism by introducing explicit joint relations alongside temporal differentiation, which helps refine the modeling of joint dependencies over time.

The GCN-Transformer model [9] exemplifies a more complex approach, combining GCNs with attention mechanisms. In the GCN-Transformer, the input sequences are passed through the Scene Module, consisting of a Spatio-Temporal Fully-Connected module and a Spatial-GCN network. The Spatial-GCN focuses on extracting social dependencies among individuals within a scene by using learnable adjacency matrices, enabling the model to capture intricate patterns of interaction dynamics. The processed scene context is then fed into the Spatio-Temporal Attention Forecasting Module, which leverages self-attention to capture long-term dependencies, with the Temporal-GCN module, which extracts temporal relationships via graph convolution. This dual-modality approach enhances the architecture's spatial and temporal modeling capabilities.

Recent advancements have also explored simpler architectures, such as multilayer perceptrons (MLPs), for capturing spatial and temporal dependencies. The MPFSIR model [10] employs alternating of spatial and temporal blocks to capture dependencies across joints and time steps, respectively. This model achieves state-of-the-art performance by focusing on simplicity and computational efficiency without needing more complex architectures like GCNs or Transformers.

Experimental results on the SoMoF Benchmark and ExPI dataset reveal that models like SoMoFormer, Future Motion, SocialTGCN, MRT, TBIFormer, and DVITA, which primarily focus on either spatial or temporal dimensions, exhibit inconsistent improvements over the baseline, with noticeable differences in their predictive accuracy between datasets. In contrast, models that effectively integrate both spatial and temporal features demonstrate consistent performance gains, maintaining a steady improvement over the Zero Velocity model across both SoMoF and ExPI datasets. This underscores the importance of joint spatial-temporal modeling in achieving robust and reliable pose forecasting.

Keywords – spatial feature, temporal features, multi-person pose forecasting

References

- [1] Wei Mao et al. "Learning trajectory dependencies for human motion prediction". In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019, pp. 9489–9497.
- [2] Xiaogang Peng et al. "The MI-Motion Dataset and Benchmark for 3D Multi-Person Motion Prediction". In: arXiv preprint arXiv:2306.13566 (2023).

- [3] Chenxi Wang et al. "Simple baseline for single human motion forecasting". In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021, pp. 2260–2265.
- [4] Behnam Parsaeifard et al. "Learning decoupled representations for human pose forecasting". In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021, pp. 2294–2303.
- [5] Edward Vendrow et al. "SoMoFormer: Multi-Person Pose Forecasting with Transformers". In: arXiv preprint arXiv:2208.14023 (2022).
- [6] Xiaogang Peng, Siyuan Mao, and Zizhao Wu. "Trajectory-aware body interaction transformer for multi-person pose forecasting". In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023, pp. 17121–17130.
- [7] Jiashun Wang et al. "Multi-person 3D motion prediction with multi-range transformers". In: Advances in Neural Information Processing Systems 34 (2021), pp. 6036–6049.
- [8] Qingyao Xu et al. "Joint-Relation Transformer for Multi-Person Motion Prediction". In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 2023, pp. 9816–9826.
- [9] Romeo Šajina, Goran Oreški, and Marina Ivašić-Kos "GCN-Transformer: Multi-task Graph Convolutional Network and Transformer for Multi-person Pose Forecasting", unpublished
- [10] Romeo Šajina and Marina Ivasic-Kos. "MPFSIR: An Effective Multi-Person Pose Forecasting Model With Social Interaction Recognition". In: IEEE Access 11 (2023), pp. 84822–84833.
- [11] Vida Adeli et al. "Tripod: Human trajectory and pose dynamics forecasting in the wild". In: Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021, pp. 13390–13400.
- [12] Wen Guo et al. "Multi-person extreme motion prediction". In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022, pp. 13053–13064.

Žaklina Šupica

Hrvatska istraživačka i akademska mreža - CARNET, Zagreb, Hrvatska
zaklina.supica@cernet.hr

Kvantna komunikacijska infrastruktura

Vrijednost informacije raste iz dana u dan. Kako raste vrijednost informacije, raste i potreba da se kontinuirano povećava i njega sigurnost. Prijetnje i napadi, sigurnosni izazovi i ugroze te financijske štete od napada postaju naša svakodnevница.

Jedan od načina zaštite informacije je kriptiranje istih. Od davnina poznato je da je kriptografija imala za cilj ostvariti sigurnu komunikaciju na način da su samo pošiljatelj i primatelj poruke mogli poruku pročitati, da su pošiljatelj i primatelj poruke mogli biti sigurni da poruku nitko nije presreo putem komunikacijskog kanala i izmijenio je te da pošiljatelj može biti siguran da je primatelj zaista posao poruku. Simetrični i asimetrični kriptografski algoritmi oduvijek su osiguravali informacije na adekvatan način. Međutim, sigurnost kriptografskih algoritama danas je ozbiljno narušena i to pojavom kvantnih računala.

Nekoliko je povijesnih znanstvenih otkrića dovelo do razvoja kvantnih računala, kvantnih mreža, kvantne distribucije ključeva te post-kvantne kriptografije. 1981. godine je fizičar Richard Feynman razvio kvantni koncept [1]. Slijedio je razvoj protokola zvanog BB84 po autorima Charles Bennettu i Gilles Brassardu, a razvijen je 1984. godine. BB84 je protokol kvantne distribucije ključa (engl. *Quantum Key Distribution*) koji osigurava sigurnost procesa generiranja ključa od prisluškivanja [2]. Nadalje, 1994. godine matematičar Peter Shor predstavlja algoritam koji upotrebljava svojstva i način rada kvantnih računala poput superpozicije, isprepletenosti i kvantne Fourierove transformacije za pronalazak prostih faktora nekog cijelog broja N [3]. Time je matematički postupak faktorizacije doveden do stanja da treba pričekati razvoj dovoljno jakog računala koje će riješiti matematički postupak i dekriptirati informacije. 2001. godine faktoriziran je broj 15. Iako danas zvuči jednostavno, prije više od 20 godina to je bio izuzetno težak zadatak za koji se koristila prva verzija IBM kvantnog računala [4]. Od 2019. godine Google je imao najbolje i najjače kvantno računalo na svijetu no tu poziciju je navodno preuzele računalo H2-1 no rad koji je objavljen, objavljen je samo kao informativni članak [5]. U svakom slučaju, činjenica je da kvantna računala napreduju i samo je pitanje koliko godina će proći dok jedno kvantno računalo ne bude dovoljno jako da riješi kriptografske algoritme.

Razvoj kvantnih računala i njihova prijetnja kriptografiji je potrebno adresirati na ozbiljan način jer je već nekoliko godina poznata strategija „priklupljaj sada, dekriptiraj kasnije“ (engl. *harvest now, decrypt later*). Postoje dva pristupa ovom problemu. Jedan je razvoj infrastrukture za kvantu distribuciju ključeva, a drugi pristup čini razvoj post-kvantnih algoritama [6]. U ovom sažetku zadržat ćemo se na razvoju infrastrukture za kvantu distribuciju ključeva odnosno razvoju kvantne komunikacijske infrastrukture.

2019. godine Republika Hrvatska potpisala je Deklaraciju o europskoj kvantnoj komunikacijskoj infrastrukturi čime se obvezala na provedbu aktivnosti na izgradnji sigurne kvantne komunikacijske infrastrukture. Na temelju toga pokrenut je nacionalni projekt Hrvatska kvantna komunikacijska infrastruktura – CroQCI, a cilj projekta je implementacija eksperimentalnih kvantnih komunikacijskih sustava i mreže, nadopunjениh i integriranih s rasponom klasičnih sigurnih komunikacijskih tehnologija.

U osnovnom postavu, kvantna se mreža može opisati pomoću tri osnovna sloja od kojih svaki ima specifičnu funkciju: kvantni sloj, sloj za upravljanje ključevima i aplikacijski sloj [7]. Kvantni sloj zadužen je za povezivanje dva komunikacijska čvora te je njegov rezultat

istovremeno generiranje jednakog materijala ključa na dvije udaljene lokacije. Osnovne funkcije sloja za upravljanje ključevima su dohvat ključeva iz kvantnog sloja i predaja kriptografskih ključeva aplikacijskom sloju. Dodatna funkcionalnost ovog sloja je i uspostavljanje konekcije između dva čvora koja nisu međusobno povezana izravnim linkom, a radi ostvarenja kvantno sigurne komunikacije. Aplikacijski sloj sadrži aplikacije koje koriste kriptografske ključeve koje na zahtjev dobiju od sloja za upravljanje ključevima te koriste ključeve za zaštićenu komunikaciju.

Radeći na sloju za upravljanje ključevima plan je implementirati dva sustava: sustav za upravljanje ključevima (engl. *Key Management System*, KMS) i hardverski sigurnosni modul (engl. *Hardware Security Module*, HSM). KMS je sustav zadužen za upravljanje životnim ciklusom kriptografskih ključeva i nadzor nad pristupom istima. HSM je specijalizirani uređaj koji je namijenjen za sigurnu pohranu kriptografskih ključeva te ima mogućnost izvršavanja kriptografskih operacija. Uz softversku sigurnost, pružaju i hardversku sigurnost jer su otporni na neovlaštenu fizičku manipulaciju. U ovom fazi, konceptualno su predviđena tri scenarija za dohvaćanje i pohranu ključeva, a to su: 1. Direktno dohvaćanje ključeva na zahtjev; 2. Periodično dohvaćanje ključeva i lokalna pohrana; 3. Periodično dohvaćanje ključeva i pohrana na HSM. U cilju nam je demonstrirati sve opisane scenarije kako bismo na osnovu dobivenih rezultata lakše izveli zaključke o tome koji scenarij ima bolje performanse te ga primijenili na studiju slučaja.

Područje koje je predmet interesa autorice je vrlo specifično, inovativno i postavlja temelje za daljnju implementaciju kvantne komunikacijske infrastrukture. Otvoreno je više smjerova istraživanja i doprinosa znanosti.

Ključne riječi – kvantna komunikacijska infrastruktura, kriptografija, kvantna prijetnja, postkvantni algoritmi

Literatura

- [1] C. H. Ugwuishiwi, U. E. Orji, C. I. Ugwu, C. N. Asogwa, „An overview of Quantum Cryptography and Shor's Algorithm“, International Journal of Advanced Trends in Computer Science and Engineering, Volume 9, No.5, September - October 2020, pp. 7487-7495.
- [2] Kako BB84 protokol osigurava sigurnost procesa generiranja ključa od prisluškivanja? Mrežno: <https://hr.eitca.org/cybersecurity/eitc-is-qcf-quantum-cryptography-fundamentals/practical-quantum-key-distribution/qkd-teaching-kit/examination-review-qkd-teaching-kit/how-does-the-bb84-protocol-ensure-the-security-of-the-key-generation-process-against-eavesdropping/> (pristupljeno: 1.10.2024.)
- [3] Shor, P.W. „Algorithms for quantum computation: Discrete logarithms and factoring“ In Proceedings of the 35t, Annual Symposium on Foundations of Computer Science, Santa Fe, NM, USA, 20–22 November 1994; pp. 124–134.
- [4] Vandersypen, L., Steffen, M., Breyta, G. et al. Experimental realization of Shor's quantum factoring algorithm using nuclear magnetic resonance. Nature 414, 883–887 (2001)
- [5] Matthew DeCross i sur., “The computational power of random quantum circuits in arbitrary geometries”, arXiv:2406.02501v3 [quant-ph] 21 Jun 2024
- [6] “Quantum-Safe Secure Communications”, <https://uknqt.ukri.org/wp-content/uploads/2021/10/Quantum-Safe-Secure-Communications.pdf> (pristupljeno: 1.10.2024.)
- [7] D. Ivković, Ž. Šupica, “Koncept između testne okoline i testnog KMS/HSM sustava” neobjavljen

Ivan Tudor

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
ivan.tudor@uniri.hr

Personalizacija procesa učenja i poučavanja u srednjoškolskom i visokom obrazovanju potpomognuto tehnologijom: sustavni pregled literature

Prilikom planiranja aktivnosti učenja i poučavanja je važno voditi računa o ovim i specifičnim karakteristikama učenika kako bi obrazovni proces bio učinkovitiji, a personalizirani pristupi imaju pritom ključnu ulogu. Učenici se međusobno razlikuju s obzirom na predznanje, očekivanja, stil učenja, tempo ostvarivanja ishoda učenja, kognitivne sposobnosti, motivaciju i druge karakteristike [1]. Dodatno, nove generacije učenika karakteriziraju brza obrada informacija i sklonost gubljenja pažnje ako nastane nezainteresiranost za određeni sadržaj.

Cilj personalizacije u obrazovnom kontekstu je povećanje interesa i motivacije te bržeg i temeljitijeg savladavanja ishoda učenja. Kako bi se procesi učenja i poučavanja uspješno prilagodio specifičnostima novih generacija učenika, ključno je uvođenje inovativnih pristupa i naprednih tehnologija [2]. S obzirom na sve veću prisutnost digitalne tehnologije u svakodnevnom životu, nužno je iskoristiti njen potencijal u obrazovanju, pri čemu personalizacija predstavlja jednu od mogućnosti.

Personalizacija u računalom potpomognutom obrazovanju (engl. *technology-enhanced learning*, TEL) donosi brojne prednosti, koje su značajne za učenike, nastavnike i obrazovne institucije. Tehnologija omogućuje individualizaciju nastavnog sadržaja, prilagođavajući ga razini znanja, stilu učenja, tempu i interesima svakog učenika [3]. Na taj način, učenici mogu učiti brzinom koja im odgovara i koristiti materijale koji su relevantni za njihove interese. Razvoj tehnologije omogućio je i učenje u različitim socijalnim okruženjima koja pružaju različite razine poticaja.

U ovom radu prezentira se rezultat sustavnog pregleda literature (engl. *Systematic Literature Review*, SLR) prema metodologiji utvrđenoj od strane autora Okoli i Schabram [4]. Svrha ovog sustavnog pregleda literature je istražiti mogućnosti personalizacije učenja i poučavanja uz pomoć tehnologije kako bi se dale preporuke za buduća istraživanja, posebno za primjenu u srednjoškolskom i visokom obrazovanju. Svrha će se postići odgovorima na sljedeća istraživačka pitanja:

- P1. Koje se metode i tehnike koriste za personalizaciju u nastavnom procesu?
- P2. Na temelju kojih podataka o učenicima/studentima se implementiraju metode i tehnike za personalizaciju?
- P3. Za koje se uzraste učenika i studenata, nastavnih predmeta i aktivnosti personalizacija koristi?
- P4. Kojeg su tipa provedena istraživanja o efikasnosti personalizacije u nastavnom procesu?

P5. Ima li personalizacija u nastavnom procesu pozitivan utjecaj na motivaciju i/ili ostvarivanje ishoda učenja i na koji način?

Upit nad bazama podataka Scopus i Web of Science rezultirao je s ukupno 1599 radom, a nakon primjene kriterija uključivanja i isključivanja, osnovnog pregleda i procjene kvalitete, za detaljnju analizu u ovom istraživanju uključen je 21 rad.

Istraživanjem su utvrđene razine obrazovanja i predmeti gdje se primjenjuje personalizacija. Također, analizirani su tipovi istraživanja kao i utjecaj personalizacije na učenike. Rezultati su pokazali da se personalizacija najčešće koristila u visokoškolskoj

nastavi, i to u prirodnim znanostima, STEM području te učenju stranih jezika. Većina istraživanja bila je kvantitativne prirode, ponekad s dodatkom kvalitativnih metoda.

Za prilagođavanje sadržaja, zadataka i aktivnosti učenja ovisno o njihovim potrebama koriste se sustavi čiji se rad temelji na algoritmima klasteriranja podataka, povratnog prostiranja povratne pogreške, dubokog učenja te preporučivanja (engl. *recommender system*). Njihov se rad temelji na demografskim podacima, prethodnim postignućima, preferiranom stilu učenja, interesima i motivacijama učenika, a u nekim slučajevima se na temelju tih podataka učenike opisuje obrazovnim personama [5], [6] koje se koriste kao temelj za personalizaciju.

Analizom je također uočeno da se povećava broj istraživanja na temu personalizacije u obrazovanju uz pomoć digitalne tehnologije. Svi radovi zaključuju da personalizacija ima pozitivan utjecaj, uglavnom na uspješnije usvajanje ishoda učenja, ali i na veću motivaciju učenika. Niti jedna studija nije zabilježila negativne učinke personalizacije na učenike.

U budućem radu se planira detaljnije istražiti mogućnosti primjene obrazovnih persona u kombinaciji s obrazovnim sustavima preporučivanja, pristupom koji nije često korišten no pokazao se efikasnim. Kontekst istraživanja bit će personalizirano učenje matematike na studijima na kojima je to jedan od općih predmeta. U tu svrhu će se nadograditi obrazovni sustav preporučivanja ELARS [7] novim funkcionalnostima te osmisliti dizajn učenja s personalizirani putovima učenja i dodatnim aktivnostima kako bi se pružila podrška savladavanju ishoda učenja studentima s različitim razinama (pred)znanja i preferencijama.

Ključne riječi – personalizacija, srednjoškolsko i visoko obrazovanje, motivacija učenika, sustavni pregled literature, računalom potpomognuto obrazovanje

Literatura

- [1] Stančić, Z., Ivančan, A., Periša, D., Vučić-Pavković, M., Dobrić Fajl, E. (2006): Stilovi učenja - novi putevi učenja i poučavanja. Zbornik radova 6. međunarodnog seminara „Živjeti zajedno“. Savez defektologa Hrvatske. Varaždin, 20.-22. travnja 2006., str. 109-118.
- [2] Equity and quality in education: Supporting disadvantaged students and schools, vol. 9789264130852. Organisation for Economic Cooperation and Development (OECD), 2012. doi: 10.1787/9789264130852-en.
- [3] C. R. Brito, M. M. Ciampi, R. M. Vasconcelos, L. A. Amaral, H. D. Santos, and V. A. Barros, 'Rethinking engineering education', in 2017 IEEE Frontiers in Education Conference (FIE), IEEE, Oct. 2017, pp. 1–5. doi: 10.1109/FIE.2017.8190506.
- [4] Okoli. (2015). A Guide to Conducting a Standalone Systematic Literature Review, Communications of the Association for Information Systems: Vol. 37, Article 43.
- [5] R. Weinhandl, M. Mayerhofer, T. Houghton, Z. Lavicza, M. Eichmair, and M. Hohenwarter, 'Mathematics student personas for the design of technology-enhanced learning environments', 2023.
- [6] I. Tudor, M. H. Dlab and G. Đurović, "Learner Personas in Technology-Enhanced Learning," 2024 47th MIPRO ICT and Electronics Convention (MIPRO), Opatija, Croatia, 2024, pp. 311-316, doi: 10.1109/MIPRO60963.2024.10569495.
- [7] M. H. Dlab, "Experiences in using educational recommender system ELARS to support e-learning," 2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO), Opatija, Croatia, 2017, pp. 672-677, doi: 10.23919/MIPRO.2017.7973508.

Matea Turalija Reščić

Sveučilište u Rijeci, Medicinski fakultet u Rijeci, Rijeka, Hrvatska
matea.turalija@medri.uniri.hr

Analiza mogućnosti proširenja brze višepolne metode za nekockaste simulacijske kutije

Razvojem modernih tehnologija, znanstvena zajednica suočava se s izazovom rješavanja sve složenijih problema u računalnim simulacijama koje nadilaze mogućnosti tradicionalnih metoda. Umjesto promatranja fenomena u laboratoriju, znanstvenici sada mogu simulirati čitave sustave u virtualnim okruženjima, što ne samo da omogućuje testiranje teorija, nego i otkrivanje novih zakonitosti koje bi inače ostale skrivene.

Molekulska dinamika, kao pristup simulaciji ponašanja atoma i molekula, ima široku primjenu u biofizici, kemiji i znanosti o materijalima. Međutim, današnja potreba za ogromnim brojem čestica i složenost interakcija između njih stvaraju velike izazove za optimalno korištenje sve više raspodijeljenih i heterogenih računalnih resursa [1]. Brza višepolna metoda (engl. *Fast Multipole Method*, FMM) predstavlja jedno od potencijalnih rješenja za ovaj problem [2] jer omogućuje skalabilnije izračune dalekosežnih interakcija, zbog čega se oni izvode brže na većim molekulskim sustavima. Međutim, u svojoj osnovnoj primjeni, FMM je ograničena na kockaste simulacijske kutije [3], što predstavlja značajan izazov u slučajevima kada je potrebno koristiti druge geometrije simulacijskih kutija. Prednost takvih geometrija je smanjenje količine vode koju je potrebno simulirati kod molekulskih sustava koji nisu podjednake veličine u sve tri dimenzije, čime se poboljšavaju performanse simulacije [4].

U našem istraživanju, glavni je cilj proširiti FMM za podršku različitim geometrijama simulacijskih kutija u molekulskim simulacijama. Kako bismo riješili ovo ograničenje implementirali smo korekcijski faktor koji omogućuje prilagodbu FMM-a za nekockaste simulacijske kutije. Ovaj faktor uzima u obzir broj čestica i veličinu simulacijskih kutija te korigira energiju FMM-a kako bi bolje odgovarala referentnim vrijednostima. Tijekom istraživanja razmotreno je nekoliko mogućih načina izračuna korekcijskog faktora i odabrana ona koja daje korigiranu vrijednost energije najbližu referentnim vrijednostima. Rezultati naših simulacija pokazali su da primjena korekcijskog faktora značajno poboljšava točnost energije FMM-a, posebno u simulacijama s velikim brojem čestica i nekockastim simulacijskim kutijama.

Naš budući rad usmjeren je na daljnje unaprjeđenje skalabilnosti i točnosti FMM-a, uz proširenje korekcijskih faktora na još složenije geometrije simulacijskih kutija. Također, istražit ćemo optimizaciju podjele kutija na podkutije kako bismo omogućili što efikasnije izvođenje velikih simulacija na modernim superračunalima.

Ključne riječi – simulacija molekulske dinamike, brza višepolna metoda, simulacijske kutije

Literatura

- [1] S. Páll et al., “Heterogeneous parallelization and acceleration of molecular dynamics simulations in GROMACS,” *The Journal of Chemical Physics*, vol. 153, no. 13, p. 134110, Oct. 2020, doi: 10.1063/5.0018516.
- [2] B. Kohnke, C. Kutzner, and H. Grubmüller, “A GPU-Accelerated Fast Multipole Method for GROMACS: Performance and Accuracy,” *J. Chem. Theory Comput.*, vol. 16, no. 11, pp. 6938–6949, Nov. 2020, doi: 10.1021/acs.jctc.0c00744.

- [3] B. Kohnke et al., “A CUDA fast multipole method with highly efficient M2L far field evaluation,” *The International Journal of High Performance Computing Applications*, vol. 35, no. 1, pp. 97–117, Jan. 2021, doi: 10.1177/1094342020964857.
- [4] I. Kabadshow, Periodic boundary conditions and the error-controlled fast multipole method. in *Schriften des Forschungszentrums Jülich IAS Series*, no. 11. Jülich: Forschungszentrum Jülich, 2012, ISBN: 9783893367702.

Tedo Vrbanec

Sveučilište u Zagrebu, Učiteljski fakultet, Zagreb, Hrvatska

tedo.vrbanec@ufzg.hr

Određivanje optimalne dimenzije vektorske reprezentacije teksta u zadatku detekcije parafraziranja

Mjerenje sličnosti tekstova ključno je za otkrivanje plagiranja. Zadatak je posebno težak ukoliko je riječ o utvrđivanju prikrivenih oblika plagiranja poput parafraziranja. Pojavom jezičnih modela temeljenih na dubokom učenju poput Word2Vec [1], Doc2Vec [2], FastText [3] i GloVe [4], čiji algoritmi prilikom treniranja svojih neuronskih mreža stvaraju vektorske prostore u koje se preslikavaju riječi i/ili cijeloviti tekstovi te sadrže inherentnu semantiku teksta kojim su trenirani, omogućeno je preciznije pronalaženje sličnosti tekstova na semantičkoj razini. Kod tih prvih modela dubokog učenja iz prve faze istraživanja, vektorske ugradnje dobivaju se njihovim vlastitim treniranjem nad korpusima nad kojima se traži sličnost. Prilikom pripreme za treniranje nužno je algoritmu odrediti broj dimenzija vektora za reprezentaciju tekstova, broj koji najbolje uspijeva prenijeti semantiku za zadatak otkrivanja parafraziranja.

Jasno je kako iz logičkog razmišljanja, tako i iz trenda rasta broja dimenzija jezičnih modela od prvih modela do današnjih velikih jezičnih modela utječe na kvalitetu modela, odnosno na njegovu sposobnost izvlačenja semantike iz tekstova i potom na rezultate usporedbe tekstova preko tako nastalih višedimenzionalnih vektora. Stoga je u okviru ovog istraživanja bilo potrebno istražiti kako je broj dimenzija povezan s performansama modela. Prva naznaka da porast broja dimenzija ne vodi linearno do porasta kvalitete rezultata mjerena F1-mjerom evidentirana je tijekom provedbe velikog broja eksperimenata na relativno malom razvojnem korpusu 10docs (malom po broju dokumenata) [5, 6]. Njima je utvrđeno da nakon „prekomjernog“ povećanja broja dimenzija, performanse modela zapravo - padaju. Empirijskom metodom se stoga pokušalo utvrditi varijable i funkcije nad njima kojima bi se mogao izračunati broj dimenzija modela koji je optimalan kod treniranja kako bi model prenio semantiku teksta kojeg preslikava u vektorski prostor te su formule predstavljene u prethodna dva rada [6, 7]. U ovom nastavku istraživanja dobivena je još preciznija formula.

Optimalnost se odnosi na minimalan broj dimenzija kod koje model daje dobre rezultate. To nije broj dimenzija kod koje model ostvaruje apsolutno najbolji rezultat već kod tog broja model ostvaruje jedan od prvih lokalnih maksimuma na grafikonu funkcije F1-mjere s obzirom na varijablu broja dimenzija, a svi su lokalni maksimumi zapravo zadovoljavajućih vrijednosti F1-mjere. Kako bismo bili sigurni u prirodu funkcije i formulu po kojoj se računa optimalan broj dimenzija vektorskog prostora jezičnih modela, provedeni su dodatni eksperimenti sa modelima kojima je moguće regulirati broj dimenzija prije procesa treniranja, a rezultati su prikazani u izlaganju.

Ovo istraživanje implicira dva zaključka. Prvi je sama spoznaja da je očekivana vrijednost F1-mjere izračunate kod optimalnog broja dimenzija blizu moguće maksimalne vrijednosti, te je povećanje broja dimenzija nepotreban „trošak“ računalnih resursa kod treniranja, što pak se reflektira na vremenski i financijski trošak treniranja. Drugi je zaključak formula koja daje optimalan broj dimenzija vektorskog prostora ovisno od dva parametra: broj jedinstvenih riječi u korpusu te broj ne-praznih dokumenata u korpusu. Korištenje formule za određivanje optimalnog broja dimenzija prilikom treniranja velikih jezičnih modela, ima potencijal ostvariti značajne uštede u pogledu trajanja treniranja te potrebnih računalnih resursa za to.

Ključne riječi – jezični modeli, vektorske ugradnje, optimalne dimenzije, duboko učenje, parafraziranje

Literatura

- [1] T. Mikolov, K. Chen, G. Corrado, i J. Dean, „Distributed Representations of Words and Phrases and their Compositionality“, Nips, str. 1–9, 2013, doi: 10/c7rpzm.
- [2] Q. V. Le i T. Mikolov, „Distributed Representations of Sentences and Documents“, u International Conference on Machine Learning, 2014, str. 1188–1196.
- [3] P. Bojanowski, E. Grave, A. Joulin, i T. Mikolov, „Enriching Word Vectors with Subword Information“, Computing Research Repository, srp. 2016, doi: 1511.09249v1.
- [4] J. Pennington, R. Socher, i C. Manning, „Glove: Global Vectors for Word Representation“, u Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), Stroudsburg, PA, USA: Association for Computational Linguistics, 2014, str. 1532–1543. doi: 10/gfshwg.
- [5] T. Vrbanec i A. Meštrović, „Corpus-Based Paraphrase Detection Experiments and Review“, Information, sv. 11, izd. 5, str. 241, tra. 2020, doi: 10/ghjtff.
- [6] T. Vrbanec i A. Meštrović, „Relevance of Similarity Measures Usage for Paraphrase Detection“, u Proceedings of the 13th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management, Portugal: SCITEPRESS - Science and Technology Publications, 2021, str. 129–138. doi: 10/gndtr5.
- [7] T. Vrbanec i A. Meštrović, „Comparison study of unsupervised paraphrase detection: Deep learning—The key for semantic similarity detection“, Expert Systems, sv. 40, izd. 9, str. e13386, 2023, doi: 10.1111/exsy.13386.

Ana Vrcelj Božić

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
Građevinska tehnička škola Rijeka, Hrvatska
ana.vrcelj@student.uniri.hr

Analiza elemenata igrifikacije u digitalnim obrazovnim alatima primjenom klasifikacije za igrifikaciju

U današnje vrijeme igrifikacija (engl. *gamification*) se sve više koristi u obrazovanju kako bi se povećala motivacija učenika [1] jer ju je lakše osmisliti i provesti u učionici nego učenje temeljeno na igram. Umjesto razvoja posebnih obrazovnih igara, igrifikacija koristi neke elemente dizajna igre uključene u javno dostupne digitalne alate za igrifikaciju [2]. Međutim, odabir pravih alata za igrifikaciju i njihovih elemenata dizajna igara nije jednostavan zadatak za učitelje [3].

Ovaj rad opisuje vlastitu klasifikaciju za igrifikaciju i njezinu primjenu u evaluaciji popularnih digitalnih alata za igrifikaciju. Pregled karakteristika ovih alata može pomoći učiteljima ne samo u odabiru tih alata, već i u samostalnom vrednovanju drugih alata [4]. Opisana klasifikacija prvi je korak u razvoju budućeg tehnološko-pedagoškog okvira za dizajn i provedbu igrificiranih aktivnosti u školama. Opisano istraživanje provodi se u okviru projekta "Poticanje motivacije za učenje korištenjem igrifikacije" te predstavlja nastavak istraživanja usmjerjenog na razvoj kriterija za odabir digitalnih alata za igrifikaciju [5]. Cilj projekta je istražiti elemente igrifikacije za poticanje motivacije učenika, posebice u srednjim školama, te započeti razvoj tehnološko-pedagoškog okvira igrifikacije za osmišljavanje i provedbu igrificiranih aktivnosti.

U svrhu stvaranja vlastite klasifikacije za igrifikaciju, koja će se integrirati kao tehnološki aspekt u budući okvir igrifikacije, analizirani su postojeći okviri pri čemu je okvir MDA (engl. *MDA framework*) korišten kao temelj jer je pogodan za analizu igrificiranih modela u obrazovanju [6]. Predložena klasifikacija sastoji se od 23 elementa podijeljena u četiri kategorije: mehanika (engl. *mechanics*), dinamika (engl. *dynamics*), estetika (engl. *aesthetics*) i ostalo (engl. *other*).

U ovom istraživanju fokus je na dalnjem usavršavanju klasifikacije kroz evaluaciju odabranih alata za igrifikaciju te odgovore na ključna istraživačka pitanja:

Q1: „Može li se predložena klasifikacija igrifikacije koristiti za analizu i evaluaciju alata za igrifikaciju?“

Q2: „Koji od popularnih alata za igrifikaciju sadrži najviše elemenata igrifikacije?“

Q3: „Koji su elementi igrifikacije najčešće korišteni u popularnim alatima za igrifikaciju?“

Kako bi se istražilo može li se predložena klasifikacija koristiti za analizu i evaluaciju alata za igrifikaciju, odabранo je 9 popularnih alata za analizu koji su uspješno evaluirani na temelju predloženih elemenata. U procesu evaluacije, Kahoot!, Quizizz i Classcraft su se istaknuli kao alati s najvećim brojem uključenih elemenata igrifikacije. Najčešći elementi dizajna igara korišteni u popularnim alatima za igrifikaciju uključuju bodove (engl. *points*) iz kategorije mehanika, povratne informacije (engl. *feedback*) i asinkrono korištenje (engl. *asynchronous use*) iz kategorije dinamika, natjecanje (engl. *competition*) i suradnju (engl. *cooperation*) iz kategorije estetika, te izvješća (engl. *reports*) i razrede (engl. *classes*) iz kategorije ostalo [7].

Rezultati analize elemenata igrifikacije izravno doprinose cilju unaprjeđenja i revidiranja predložene klasifikacije. Identifikacija najčešće korištenih elemenata igrifikacije sugerira

da trenutna klasifikacija uspješno prepozna ključne komponente koje se najčešće pojavljuju u popularnim alatima za igrifikaciju. Stoga, rezultati pružaju dobru osnovu za daljnja istraživanja usmjereni na unapređenje primjene igrifikacije u školama, što uključuje i razvoj vlastitih alata za igrifikaciju koji će biti upotrijebljeni u sklopu istraživanja. Istražit će se i pedagoški aspekt igrifikacije kako bi se nastavilo s razvojem tehnološko-pedagoškog okvira igrifikacije koji će pomoći učiteljima u osmišljavanju i provedbi igrificiranih aktivnosti za učenike.

Ključne riječi – igrifikacija u obrazovanju, digitalni alati za igrifikaciju, okvir MDA, klasifikacija za igrifikaciju

Literatura

- [1] C. Dichev and D. Dicheva, “Gamifying education: what is known, what is believed and what remains uncertain: a critical review,” International Journal of Educational Technology in Higher Education, vol. 14, 2017.
- [2] A. Vrcelj, N. Hoić-Božić and M. Holenko Dlab, “Use of Gamification in Primary and Secondary Education: A Systematic Literature Review,” International journal of educational methodology, vol. 9, no. 1, pp. 13- 27, 2023.
- [3] A. Vrcelj, N. Hoić-Božić and M. Holenko Dlab, “Using Digital Tools for Gamification in Schools,” 44th International Convention Proceedings / Skala, Karolj (ur.). Rijeka: Croatian Society for Information, Communication and Electronic Technology- MIPRO, 906- 910, 2021.
- [4] A. M. Toda, A. C. T. Klock, W. Oliveira, P. T. Palomino, L. Rodrigues and L. Shi, “Analysing gamification elements in educational environments using an existing gamification taxonomy,” Smart Learn. Environ., vol. 6, no. 16, 2019.
- [5] A. Vrcelj Božić, N. Hoić-Božić and K. Strančin, “Technological Aspects of Gamification: Criteria for the Selection of Digital Tools and Platforms,” in ECEL 2024, unpublished.
- [6] G. P. Kusuma, E. K. Wigati, Y. Utomo and L. K. P. Suryapranata, “Analysis of Gamification Models in Education Using MDA Framework,” Procedia Computer Science, vol. 135, p. 385-392, 2018.
- [7] A. Vrcelj Božić, N. Hoić-Božić, M. Holenko Dlab, K. Strančin, and T. Jagušt, “Analysis of the Gamification Aspects of Digital Educational Tools Using Gamification Classification”, Proceedings of the SoftCOM 2024 conference, 2024.

Marina Žunić

Sveučilište u Rijeci, Fakultet informatike i digitalnih tehnologija, Rijeka, Hrvatska
marina.zunic@inf.uniri.hr

Pedagoški pristupi za neprekinuto učenje putem tehnologije metaverzuma

Metaverzum (engl. *metaverse*) izaziva veliki interes u različitim područjima pa tako i u obrazovanju gdje se može koristiti kao platforma koja pretvara proces učenja u zanimljivo iskustvo unutar imerzivnog okruženja. Metaverzumom se stvaraju vrlo realistični i interaktivni virtualni svjetovi pomoću kojih se može prikazati bilo koje okruženje unutar kojeg korisnici komuniciraju sa sadržajem za učenje kao i međusobno [1]. U obrazovanju metaverzum omogućuje korisnicima učenje koncepata koje nemaju priliku iskusiti u stvarnom svijetu, vježbanje u simuliranom okruženju koje u stvarnom svijetu može biti opasno i slično. Upravo radi navedenih mogućnosti metaverzum se sve više koristi u edukativne svrhe [2]. Korištenje metaverzuma omogućuju suvremene tehnologije kao što su virtualna, proširena i miješana stvarnost, umjetna inteligencija, *Big Data*, *IoT*, *Blockchain*, 6G i ostale tehnologije te se metaverzum smatra trećim valom internetske revolucije [3]. Budući da se metaverzum i pripadne mu tehnologije neprestano razvijaju, što uključuje stalna ažuriranja programske podrške, platformi i uređaja, važno je istražiti mogućnosti njegove upotrebe u obrazovanju vodeći računa o instrukcijskom dizajnu aktivnosti učenja [4].

U radu se prezentiraju pedagoški pristupi za primjenu računalom potpomognutog neprekinutog učenja putem metaverzuma kao rezultat istraživanja koje se provodi u okviru projekta MetaRoboLearn. Neprekinuto učenje predstavlja synergiju formalnih, neformalnih i informalnih okolina za učenje. Time se omogućava usvajanje znanja u formalnim okolinama za učenje, koje se pretače u neformalne i informalne te obrnuto. Rezultati istraživanja opisanog u ovom radu predstavljaju prvi korak ka konceptualizaciji metaverzuma kao dijela pedagoškog okvira za usmjeravanje provedbe personaliziranih i suradničkih aktivnosti učenja u trodimenzionalnom prostoru za učenje koji integrira formalna, neformalna i informalna okruženja za učenje. Ovim pristupom jača se znanje i stimulira njegova primjena u različitim kontekstima [5]. Primjenom metaverzuma moguće je stvoriti prilike za učenje izvan učionice koje je vođeno osobnim interesima učenika dok se istovremeno potiče njihov entuzijazam, samopouzdanje, odgovornost, neovisnost i motivaciju.

Rad ističe prednosti korištenja univerzalnog dizajna za učenje (engl. *Universal Design for Learning*, UDL) kao temelja za osmišljavanje aktivnosti učenja u navedenom kontekstu. Načela univerzalnog dizajna za učenje uključuju pružanje različitih načina primanja informacija i stjecanja znanja te višestrukih načina djelovanja i izražavanja [6]. Uz interaktivne materijale koji uključuju tekst, grafike, video i audio zapise, tehnologije metaverzuma omogućuju i korištenje proširene, virtualne i miješane stvarnosti što proširuje mogućnosti za angažiranje učenika kroz realistične simulacije i iskustva koja oponašaju stvarne situacije, čime se povećava relevantnost i primjenjivost stečenog znanja. Pristupi temeljeni na univerzalnom dizajnu za učenje osiguravaju fleksibilno okruženje koje se može prilagoditi potrebama svakog pojedinca [7] pa se njihovom primjenom svim učenicima može osigurati priliku za učenje i uspjeh.

Uz navedeno, u istraživanju se naglašava i prednost korištenja pristupa dizajna za interakciju (engl. *Design for Interaction*). Navedeni pristup prepostavlja potrebu osiguravanja uvjeta za produktivne interakcije među učenicima odnosno istraživanja kako

različiti scenariji strukturiranja suradničkih procesa mogu pridonijeti izgradnji znanja, ali i ostaviti prostor za spontanu suradnju dopuštajući da se interakcija prirodno razvije [8].

Očekuje se da će aktivnosti učenja podržanih metaverzumom koje se temelje na navedenim pedagoškim pristupima poboljšati motivaciju učenika, razumijevanje složenih koncepata te doprinijeti personaliziranom iskustvu učenja. Uz pedagoške pristupe valja naglasiti i važnost odabira odgovarajućeg radnog prostora odnosno identificiranja kombinacije tehnologija koja će osigurati najbolje uvjete za učenje. Ovisno o korištenom pedagoškom pristupu i dizajnu aktivnosti učenja te dostupnim resursima, određene tehnologije metaverzuma mogu se efikasnije koristiti u nekim okruženjima za učenje, a u drugim okruženjima za učenje biti manje prikladne. Naprimjer, učenje uz pomoć obrazovnih robota u formalnom okruženju može zamijeniti simulacija robota uz pomoć tehnologije virtualne stvarnosti u neformalnom okruženju. Na izrađenom konceptualnom okviru za pedagogiju neprekinutog učenja temeljenom na tehnologiji metaverzuma će se temeljiti izrada konceptualnog modela povezivanja tehnologija u metaverzumu tehnološkim mostovima koji će omogućiti prijelaz među heterogenim tehnologijama metaverzuma.

Ključne riječi – metaverzum, neprekinuto učenje, projekt MetaRoboLearn, univerzalni dizajn za učenje

Literatura

- [1] F. de Felice, A. Petrillo, G. Iovine, C. Salzano, and I. Baffo, "How Does the Metaverse Shape Education? A Systematic Literature Review," *Applied Sciences*, vol. 13, no. 9, p. 5682, May 2023, doi: 10.3390/app13095682.
- [2] R. Alfaisal, H. Hashim, and U. H. Azizan, "Metaverse system adoption in education: a systematic literature review," *Journal of Computers in Education*, vol. 11, no. 1, pp. 259–303, Mar. 2024, doi: 10.1007/s40692-022-00256-6.
- [3] H. Lin, S. Wan, W. Gan, J. Chen and H. Chao, "Metaverse in Education: Vision, Opportunities, and Challenges," in 2022 IEEE International Conference on Big Data (Big Data), Osaka, Japan, 2022 pp. 2857-2866.
- [4] X. Chen, Z. Zhong and D. Wu, "Metaverse for Education: Technical Framework and Design Criteria," in *IEEE Transactions on Learning Technologies*, vol. 16, no. 6, pp. 1034-1044, Dec. 2023, doi: 10.1109/TLT.2023.3276760.
- [5] S. L. Tudor, "Formal – Non-formal – Informal in Education," *Procedia - Social and Behavioral Sciences*, vol. 76, pp. 821–826, Apr. 2013, doi: 10.1016/j.sbspro.2013.04.213.
- [6] M. Wang, H. Yu, Z. Bell, and X. Chu, "Constructing an Edu-Metaverse Ecosystem: A New and Innovative Framework," *IEEE Transactions on Learning Technologies*, vol. 15, no. 6, pp. 685–696, Dec. 2022, doi: 10.1109/TLT.2022.3210828.
- [7] S. S. Dewi, H. A. Dalimunthe, and Faadhil, "The Effectiveness of Universal Design for Learning," *Journal of Social Science Studies*, vol. 6, no. 1, p. 112, Dec. 2018, doi: 10.5296/jsss.v6i1.14042.
- [8] P. Dillenbourg, É. Polytechnique, and F. de Lausanne, "Some technical implications the distributed cognition approach on the design of interactive learning environments," 1996. [Online]. Available: <https://www.researchgate.net/publication/243772698>

Lucija Žužić

Sveučilište u Rijeci, Tehnički fakultet, Rijeka, Hrvatska

lucija.zuzic@uniri.hr

Predviđanje putanje osobnih plovila korištenjem modela temeljenih na neuronskim mrežama s povratnom vezom

Na prometnim turističkim odredištima velike marine nadziru iznajmljena vozila jer neiskusni vozači predstavljaju opasnost za sve sudionike u pomorskom prometu. Iz tog su razloga neke tvrtke za iznajmljivanje osobnih plovila ugradile sustav praćenja na svoja plovila i postavile granice dopuštene zone vožnje prema geografskoj širini i dužini. Ograničenja brzine provode se kada vozač napusti zonu ili se približi drugom plovilu koje koristi isti sustav za praćenje plovila povezan s uslugama na oblaku koje omogućuju daljinsko upravljanje vozilom. Modul kontinuirano odašilje signale globalnog položajnog sustava (engl. *Global Positioning System - GPS*) za aktiviranje ovih funkcija. Algoritam za ograničenje brzine temeljen na udaljenosti koristi se za sprječavanje sudara između vozila na kojima je navedeni sustav ugrađen.

Ljudi mogu predvidjeti buduće kretanje ostalih sudionika u prometu, što je posebno važno u slučaju gužve ili u uskim prostorima. Adaptivni tempomat (engl. *Adaptive Cruise Control - ACC*) i većina drugih naprednih sustava pomoći vozaču (engl. *Advanced Driver Assistance Systems - ADAS*) za kopnena vozila nemaju tu mogućnost. Takvi sustavi su reaktivni, što znači da je vozač odgovoran za sve odluke. Vozila koja su potpuno autonomna, ali nemaju mogućnosti predviđanja, obično moraju djelovati oprezno u prisutnosti drugih sudionika u prometu kako bi izbjegla opasne situacije, kao što je sudar putničkog autobusa i autonomnog automobila koji se dogodio pri niskoj brzini. Ovakve pojave dokazuju da je točno predviđanje kretanja drugih ostalih ključno za autonomnu vožnju.

Obrasci vožnje mogu biti zahtjevni za obuku modela strojnog učenja. Jedan primjer je vožnja autocestom, gdje su duga razdoblja konstantne brzine isprekidana naglim promjenama, kao što je promjena trake. U nekim se istraživanjima podatci naknadno ručno odabiru ili se prikupljaju za određenu svrhu. Takvi podatci mogu dati netočan prikaz stanja u stvarnom svijetu i negativno utjecati na točnost modela. U ovom radu korišteni su podatci osobnih plovila s različitih lokacija za obuku i testiranje nekoliko inačica zajedničkog univerzalnog modela. Budući da je podataka bez pogrešaka u prijenosu signala bilo malo, primijenili smo ugniježđenu unakrsnu provjeru valjanosti u k preklopa da bismo iscrpno analizirali izvedbu modela. Podjela podataka za obuku, provjeru valjanosti i testiranje bila je stratificirana kako bi se očuvao omjer putanja svakog vozila.

Ovaj rad [1] ima za cilj predvidjeti buduće ponašanje vozača na temelju povijesnih podataka pomoći metoda dubokog učenja kao što su različiti modeli neuronske mreže s povratnom vezom (engl. *Recurrent Neural Network - RNN*) koje koriste jednostavni neprilagođeni sloj s neuronske mreže s povratnom vezom, dugotrajnu kratkoročnu memoriju (engl. *Long Short-Term Memory - LSTM*) ili povratne jedinice s vratima (engl. *Gated Recurrent Unit - GRU*). RNN modeli korišteni su za predviđanje putanja drugih vozila u nekoliko radova, uključujući rad Altchéa i de La Fortellea [2], koji koriste LSTM za predviđanje putanje vozila na autocestama. LSTM-ovi su posebno prikladni za predviđanje vremenskih sljedova budući da mogu pamtitи prethodne ulaze. Odnedavno su LSTM-ovi široko prihvaćeni za predviđanje odredišta vozila na raskrižju i kretanja pješaka. U ovom radu također je primijenjen temeljni model (engl. *foundation model*) [3] koji je nedavno razvijen i uključuje mehanizam pažnje za rješavanje različitih zadatka na vremenskim

sljedovima iz različitih skupova podataka. Nadahnuti tim radom, usporedili smo i mehanizam pažnje koji je izvorno razvijen za strojno prevođenje [4].

Predložena metoda u ovom radu obrađuje različite varijable, uključujući promjene u zemljopisnoj širini i dužini, brzinu i smjer. Promjene zemljopisne širine i dužine koriste se u jednoj od metoda procjene putanje predloženih u ovom radu. Druga predložena metoda koristi brzinu, smjer i stvarni vremenski interval između zapisa u bazi podataka. Vremenski interval predstavlja proteklo vrijeme između zapisa u bazi podataka koji tvore putanju za jedno putovanje vozilom.

Prognoze dobivene predloženom metodom mogu se koristiti za izbjegavanje nepotrebnih ograničenja brzine u situacijama koje nisu opasne. Također je osigurana sigurnost vozača i ostalih sudionika u pomorskom prometu. Pregledom literature nisu pronađeni drugi radovi u kojima su metode dubokog učenja primijenjene za predviđanje putanje osobnog plovila. Koeficijent korelacije R^2 iznosi 90% kada se uspoređuju izvore putanje i pomaci zemljopisne širine i dužine predviđeni temeljnim modelom, koji je postigao najbolje rezultate.

Ključne riječi – predviđanje putanje, povratna neuronska mreža, mehanizam pažnje, temeljni model

Literatura

- [1] L. Žužić, F. Hržić i J. Lerga, “AI-based prediction of trajectories for personal watercrafts,” Book of Abstracts of the 8th Annual PhD Conference on Engineering and Technology MFC 2024., 2024, pp. 16-16
- [2] F. Altché i A. de La Fortelle, “An LSTM network for highway trajectory prediction,” 2017 IEEE 20th international conference on intelligent transportation systems (ITSC), 2017, pp. 353–359.
- [3] S. Gao, T. Koker, O. Queen, T. Hartvigsen, T. Tsiligkaridis i M. Zitnik, “UniTS: Building a Unified Time Series Model,” arXiv preprint arXiv:2403.00131, 2024.
- [4] P. Hiemsch, “Incorporating Attention Mechanisms in RNN-based Encoder-Decoder Models,” tehničko izvješće za Lebanese International University, 2023.



ISBN 978-953-7720-84-1