

AKADEMIJA TEHNIČKIH ZNANOSTI HRVATSKE

GODIŠNJAK 2025.

AKADEMIJE TEHNIČKIH ZNANOSTI HRVATSKE

Godišnjak Akademije tehničkih znanosti Hrvatske 2025

Izdavač i nakladnik:

Akademija tehničkih znanosti Hrvatske,
Kačićeva 28, 10000 Zagreb, Hrvatska

Glavni i odgovorni urednik:

Prof. emer. dr. sc. Vedran Mornar, predsjednik
Akademije tehničkih znanosti Hrvatske

Urednik:

Prof. dr. sc. Bruno Zelić, dopredsjednik
Akademije tehničkih znanosti Hrvatske

Urednički odbor:

Prof. emer. dr. sc. Vedran Mornar, predsjednik
Akademije tehničkih znanosti Hrvatske
Prof. dr. sc. Bruno Zelić, dopredsjednik
Akademije tehničkih znanosti Hrvatske
Prof. dr. sc. Neven Duić, dopredsjednik
Akademije tehničkih znanosti Hrvatske
Izv. prof. dr. sc. Mario Bačić, vršitelj
dužnosti glavnog tajnika Akademije
tehničkih znanosti Hrvatske
Prof. dr. sc. Vladimir Andročec, član Uprave
Akademije tehničkih znanosti Hrvatske

Suradnice:

Tanja Miškić Rogić, univ. spec. oec.,
poslovna tajnica Akademije tehničkih
znanosti Hrvatske
Adrijana Pavičić, ekon. teh., administrativna
referentica Akademije tehničkih znanosti
Hrvatske

Dizajn naslovnice:

Prof. dr. sc. Jana Žiljak Gršić,
Tehničko veleučilište u Zagrebu

ISSN 2975-657X (Print)

ISSN 2991-1532 (Online)

Godišnjak Akademije tehničkih znanosti
Hrvatske 2025

God. Akad. teh. zn. Hr. 2025

Priprema za tisak:

Tiskara Zelina d.d., Sveti Ivan Zelina

Tisak:

Tiskara Zelina d.d., Sveti Ivan Zelina

Naklada:

200 knjiga

Izjava o dozvoli za korištenje:

Godišnjak Akademije tehničkih znanosti Hrvatske 2025 vlasništvo je Akademije tehničkih znanosti Hrvatske. Radovi, tekstovi, slike, grafikoni, tablice i drugi podaci ne smiju se kopirati, distribuirati niti koristiti u publikacijama koje nisu akademske i znanstvene, bilo u pisanom ili u elektroničkom obliku, u cijelosti ili djelomično, osim uz izričitu dozvolu Akademije tehničkih znanosti Hrvatske.

Akademija tehničkih znanosti Hrvatske dopušta korištenje radova, tekstova, slika, grafikona, tablica i drugih podataka isključivo u akademske i znanstvene svrhe.

Napomena:

Tekstovi radova autora prikazani su prema dostavljenom izvorniku.

Izdavanje Godišnjaka financijski je poduprlo Ministarstvo znanosti, obrazovanja i mladih u okviru projekta „Jačanje publicističke djelatnosti, suradnje s gospodarstvom te nacionalne i međunarodne vidljivosti tehničkih i biotehničkih znanosti kroz programe i aktivnosti Akademije tehničkih znanosti Hrvatske”, na temelju Ugovora o dodjeli financijskih sredstava od 20. svibnja 2026.

AKADEMIJA TEHNIČKIH ZNANOSTI HRVATSKE

God. Akad. teh. zn. Hr. 2025

ISSN 2975-657X (Print)
ISSN 2991-1532 (Online)

**GODIŠNJAK
AKADEMIJE TEHNIČKIH
ZNANOSTI HRVATSKE 2025**



Zagreb, svibanj 2026.

Sadržaj

Uvodna riječ.....	1
<i>Mornar, V.</i>	
Riječ urednika.....	5
<i>Zelić, B.</i>	
Primjena strojnog učenja za predviđanje i procjenu vodostaja i protoka rijeka pod usporom mora.....	9
<i>Lerga, J., Mihel, A. M., Krvavica, N.</i>	
Umjetna inteligencija u višehazardnom ranom upozoravanju kroz prizmu CRISAFE i AI-Warn projekata.....	29
<i>Kovačević, M. S., Bačić, M.</i>	
Primjena umjetne inteligencije u grafičkoj tehnologiji.....	47
<i>Bolanča, Z., Bolanča Mirković, I.</i>	
Povijesni pregled i suvremena primjena umjetne inteligencije u obrazovanju.....	67
<i>Čarapina, M., Žiljak Gršić, J.</i>	
Umjetna inteligencija i spektralni <i>unmixing</i> u analizi pisane baštine.....	89
<i>Modrić, D., Cviljušac, V., Divjak, A., Žiljak Gršić, J.</i>	
Integracija umjetne inteligencije u medicinske sustave i inteligentne sustave vožnje.....	107
<i>Hofman, D., Žagar, M.</i>	
Sigurnost strojnog učenja.....	125
<i>Picek, S.</i>	

Primjena strojnog učenja u kemijskom inženjerstvu	143
<i>Bolf, N., Ujević Andrijić, Ž.</i>	
Primjena umjetne inteligencije u predviđanju i optimiranju sastava vodenih dvofaznih sustava za ekstrakciju enzima	165
<i>Jurinjak Tušek, A., Vičević, R., Bebek, N., Šalić, A., Zelić, B.</i>	
Umjetna inteligencija, dubinsko učenje i kauzalnost u znanosti o materijalima	185
<i>Kurtanjek, Ž.</i>	
IMAGINEHEART nakon završetka projekta: kritički osvrt i preostali izazovi u računalnoj analizi srca i srčanih struktura	193
<i>Galić, I., Habijan, M.</i>	
Određivanje parametara pougljičavanja čelika primjenom neuronske mreže	211
<i>Matijević, B., Lisjak, D.</i>	
Predviđanje kočene snage i brzine vrtnje motora brodova za rasuti teret primjenom metoda strojnog učenja.....	229
<i>Martić, I., Degiuli, N., Valčić, M., Grlj, C. G.</i>	
Primjena umjetne inteligencije za karakterizaciju nanotriboloških svojstava tehnoloških tankih filmova.....	243
<i>Perčić, M., Zelenika, S.</i>	
Primjena metoda umjetne inteligencije u naprednim oksidacijskim procesima: fokus na fotokatalitičku razgradnju organskih mikrozagađivala.....	259
<i>Žmak, I., Ćurković, L., Grobenski, P.</i>	
Usporedba postupka klasifikacije tekstilija primjenom <i>Weka</i> i <i>Orange Data Mining</i> programskih paketa	275
<i>Imamagić, S., Rolich, T., Penava, Ž.</i>	
Primjena umjetne inteligencije za digitalizaciju tekstilnih materijala kod 3D simulacije odjeće.....	291
<i>Petrak, S., Mahnić Naglić, M.</i>	
Autorski indeks	311

Uvodna riječ

Poštovane čitateljice i poštovani čitatelji,

pred vama je Godišnjak Akademije tehničkih znanosti Hrvatske posvećen području koje je u vrlo kratkom vremenu postalo jedna od ključnih pokretačkih sila suvremenoga znanstvenog, tehnološkog i društvenog razvoja: umjetnoj inteligenciji. Iako se posljednjih godina umjetna inteligencija često promatra kroz prizmu velikih jezičnih modela, generativnih sustava i njihove prisutnosti u svakodnevnom životu, radovi okupljeni u ovom izdanju jasno pokazuju da je njezin stvarni značaj mnogo širi, dublji i dugoročniji. Umjetna inteligencija danas više nije samo pomoćni računalni alat, nego metodološki okvir koji mijenja način na koji istražujemo, projektiramo, proizvodimo, analiziramo i upravljamo složenim sustavima.

Posebna vrijednost ovog Godišnjaka upravo je u interdisciplinarnosti. Radovi okupljeni u njemu dolaze iz različitih područja tehničkih i biotehničkih znanosti, ali ih povezuje zajednička ideja: korištenje podataka, računalnih modela i metoda strojnog učenja radi boljeg razumijevanja pojava, optimiranja procesa i potpore donošenju odluka. Time se potvrđuje da umjetna inteligencija nije izdvojena disciplina ograničena na računarstvo, nego tehnologija koja postupno postaje sastavni dio gotovo svih inženjerskih i znanstvenih područja.

U radovima predstavljenima u ovom Godišnjaku umjetna inteligencija pojavljuje se u različitim oblicima: od prediktivnih modela i neuronskih mreža, preko dubokog učenja i računalnog vida, pa sve do analize velikih skupova podataka, inteligentnih sustava potpore i interpretabilnih modela. Pritom je posebno važno naglasiti kako autori ne pristupaju umjetnoj inteligenciji kao univerzalnom rješenju, nego kao alatu čija vrijednost proizlazi iz kvalitetnog povezivanja domenskog znanja i računalnih metoda. Upravo je ta sinergija temelj stvarnih znanstvenih i tehnoloških pomaka.

Radovi posvećeni hidrologiji i sustavima ranog upozoravanja pokazuju kako metode strojnog učenja mogu unaprijediti predviđanje vodostaja, protoka rijeka i višehazardnih događaja, čime umjetna inteligencija postaje važan element otpornosti društva na klimatske promjene i prirodne ugroze. Istodobno, istraživanja u području kemijskog inženjerstva, znanosti o materijalima i naprednih oksidacijskih procesa potvrđuju kako suvremeni modeli omogućuju bolje razumijevanje složenih fizikalno-kemijskih procesa, optimiranje eksperimentalnih postupaka i ubrzanje razvoja novih materijala i tehnologija.

Posebno je zanimljivo pratiti kako se umjetna inteligencija razvija u područjima koja su se donedavno smatrala dominantno eksperimentalnima ili proizvodno orijentiranima. Radovi iz strojarstva, brodogradnje i tribologije pokazuju kako modeli strojnog učenja mogu uspješno predviđati ponašanje tehničkih sustava, parametre procesa i svojstva materijala, pri čemu se otvara prostor za učinkovitije projektiranje, održavanje i upravljanje industrijskim procesima. Takvi pristupi predstavljaju važan korak prema digitalnoj transformaciji industrije i konceptu pametne proizvodnje.

S druge strane, primjene umjetne inteligencije u medicini, analizi srca i inteligentnim sustavima vožnje potvrđuju da suvremeni algoritmi imaju potencijal značajno unaprijediti kvalitetu života i sigurnost ljudi. Međutim, jednako je važno što autori tih radova naglašavaju potrebu za odgovornim razvojem sustava, pouzdanošću modela i suradnjom stručnjaka različitih profila. Umjetna inteligencija ne može zamijeniti ekspertno znanje liječnika, inženjera ili istraživača, ali može postati snažan alat koji im omogućuje preciznije i brže donošenje odluka.

Značajno mjesto u ovom Godišnjaku zauzimaju i radovi posvećeni kulturnoj baštini, obrazovanju, grafičkoj tehnologiji i tekstilnoj industriji. Oni pokazuju da umjetna inteligencija ne mijenja samo visokotehnološke industrije, nego i područja povezana s očuvanjem identiteta, kreativnim procesima i obrazovanjem novih generacija stručnjaka. Hiperspektralna analiza povijesne građe, digitalizacija tekstilnih materijala ili klasifikacija tekstilija primjeri su kako suvremene metode mogu otvoriti nove istraživačke horizonte i unaprijediti postojeće postupke.

Pritom pitanje sigurnosti i pouzdanosti sustava umjetne inteligencije postaje jedno od ključnih pitanja budućeg razvoja. Kako modeli postaju složeniji i prisutniji u kritičnim sustavima, raste i potreba za njihovom transparentnošću, robusnošću i etičkom primjenom. Umjetna inteligencija neće biti uspješna samo zbog svoje računalne snage, nego prije svega zbog razine povjerenja koju će uspjeti ostvariti među korisnicima i društvom u cjelini.

Ovaj Godišnjak stoga ne predstavlja samo pregled suvremenih istraživanja, nego i svojevrsnu sliku trenutka u kojem se nalaze tehničke i biotehničke znanosti. Nalazimo se u razdoblju ubrzanih promjena u kojem granice između pojedinih disciplina postaju sve manje izražene, a suradnja između različitih područja postaje preduvjet stvaranja novih znanja i tehnologija. Upravo zbog toga posebno veseli činjenica da su autori okupljeni u ovom izdanju pokazali visoku razinu znanstvene širine, otvorenosti prema interdisciplinarnosti i spremnosti na prihvaćanje novih metodoloških pristupa.

Važno je naglasiti i da su svi radovi objavljeni na hrvatskom jeziku. Time Godišnjak nastavlja ispunjavati jednu od važnih zadaća Akademije tehničkih znanosti Hrvatske: razvoj i promicanje hrvatskoga znanstvenog i stručnog nazivlja u području suvremenih tehnologija. U vremenu izrazite internacionalizacije znanosti, očuvanje sposobnosti stručnog izražavanja na hrvatskom jeziku predstavlja važan doprinos razvoju domaće akademske i stručne zajednice.

Na kraju, zahvaljujem svim autorima na uloženom trudu, znanju i spremnosti da svoja istraživanja predstave široj stručnoj i znanstvenoj javnosti. Posebnu zahvalnost upućujem uredniku prof. dr. sc. Bruni Zeliću na predanom radu, stručnom vodstvu i velikom angažmanu u pripremi Godišnjaka, kojim je uspješno objedinjena široka i interdisciplinarna primjena umjetne inteligencije u tehničkim i biotehničkim znanostima. Zahvala pripada i svima ostalima koji su sudjelovali u pripremi i realizaciji ovoga izdanja.

Vjerujem da će radovi objavljeni u ovom broju potaknuti nova istraživanja, suradnje i rasprave te dodatno potvrditi važnost umjetne inteligencije kao jednog od ključnih područja razvoja suvremene znanosti i inženjerstva.

Glavni urednik
Prof. emer. dr. sc. Vedran Mornar

Riječ urednika

Poštovani čitatelju,

kada su u jesen 2025. godine Uprava i Znanstveno vijeće HATZ-a razmišljali o mogućim temama Godišnjaka Akademije tehničkih znanosti Hrvatske 2025, gotovo svi uključeni smatrali su kako kao temu treba obraditi umjetnu inteligenciju u tehničkim i biotehničkim znanostima. Prema definiciji koju daje Hrvatska enciklopedija, “umjetna inteligencija dio računalstva koji se bavi razvojem sposobnosti računala da obavlja zadaće za koje je potreban neki oblik inteligencije”. Iako dio računalstva, smatrali smo kako je upravo umjetna inteligencija tema koja u okviru Godišnjaka može okupiti sve odjele Akademije. Naime, ne postoji ni jedno područje u tehničkim i biotehničkim znanostima u kojem se umjetna inteligencija ne koristi u određenoj mjeri. Gotovo u svakom razgovoru kojeg vodimo s kolegama, umjetna inteligencija i način na koji se ona primjenjuje u znanstvenoj i stručnoj zajednici, ali i u svakodnevnom životu, neizostavna su tema. Primjena umjetne inteligencije u nastavi, nekritičko i neracionalno korištenje umjetne inteligencije u različitim oblicima studentskih radova, znanstveni i stručni radovi napisani i recenzirani pomoću umjetne inteligencije, upotreba strojnog učenja, donošenje zaključaka, prilagodljivo ponašanje, složeno planiranje u realizaciji različitih znanstvenih i stručnih projekata, te u konačnici primjena umjetne inteligencije u gospodarstvu, samo su dio tema koje u tim razgovorima na centralno mjesto stavljaju umjetno inteligenciju. Kada se tome doda pretraživanje različitih pojmova, prikupljanje informacija i “traženje pomoći” za kojima svi danas posežemo praktički na dnevnoj bazi, jasno je da je umjetna inteligencija prodrla u praktički sve sfere naših aktivnosti te u konačnici postala i tema Godišnjaka HATZ-a.

U Godišnjaku Akademije tehničkih znanosti Hrvatske 2025 našlo se ukupno 17 izvornih znanstvenih, preglednih i stručnih radova članova HATZ-a. Pri tome su svi radovi napisani na hrvatskom jeziku kako bi se i kroz Godišnjak ostvarila jedna od ključnih misija Akademije tehničkih znanosti Hrvatske, “pridonositi razvoju tehničkih znanosti i prijenosu tehničkih znanja važnih za probitak i napredak hrvatskog gospodarstva”. Kroz radove koje su pripremili članovi Odjela elektrotehnike i elektronike, Odjela građevinarstva i geodezije, Odjela grafičkog inženjerstva, Odjela informacijskih sustava, Odjela kemijskog inženjerstva, Odjela komunikacijskih sustava, Odjela strojarstva i brodogradnje i Odjela tekstilne tehnologije, jasno je vidljiva širina područja primjene umjetne inteligencije u tehničkim i biotehničkim znanostima.

Tako je u radu kojega su priredili profesor Lerga i suradnici strojno učenje primijenjeno za predviđanje i procjenu vodostaja i protoka rijeka pod usporom mora. Time je pokazan velik potencijal za praktičnu primjenu, uključujući unapređenje sustava ranog upozorenja na poplave, optimizaciju upravljanja sustavima navodnjavanja te pružanje potpore procesima donošenja odluka u kontekstu upravljanja vodnim resursima i prilagodbe klimatskim promjenama.

Umjetnu inteligenciju u višehazardnom ranom upozoravanju kroz razvojnu liniju UCPM projekata oVERFLOW, CROSScade, CRISAFE i AIWarn, koje je koordinirao Sveučilište u Zagrebu Građevinski fakultet, prikazuju u preglednom radu profesor Kovačević i profesor Bačić. Pri tome autori pokazuju umjetnu inteligenciju u višehazardnim sustavima ranog upozoravanja ne samo kao samostalnu tehnološku inovaciju, nego i kao logično utemeljen i operativno usmjeren sljedeći korak prema jačanju klimatske otpornosti europskih regija.

Primjenu umjetne inteligencije u grafičkoj tehnologiji prikazuju u preglednom radu profesorica Bolanča i profesorica Bolanča Mirković. Pri tome autorice ističu kako će one tiskarske tvrtke koje će integrirati umjetnu inteligenciju u svoje poslovne procese biti dugoročno konkurentne i nuditi učinkovita rješenja uz trendove prilagodbe i održivosti.

U preglednom radu kojega je priredila profesorica Žiljak Gršić sa suradnicom, dan je povijesni pregled i suvremena primjena umjetne inteligencije u obrazovanju. Autorice posebno naglašavaju kako je danas umjetna inteligencija u tehničkom području istodobno i sadržaj učenja i alat za učenje i poučavanje.

Umjetnu inteligenciju i spektralni unmixing u analizi pisane baštine analiziraju u svom radu profesor Modrić i profesorica Žiljak Gršić sa suradnicima. Pri tome autori zaključuju kako sinergija fizikalno utemeljenih pristupa, multivarijantne analize i nelinearnih modela omogućuje dublje razumijevanje materijalne strukture povijesnih dokumenata te otvara nove mogućnosti u nerazornoj dijagnostici, interpretaciji i očuvanju pisane kulturne baštine.

Kao primjere korištenja umjetne inteligencije profesor Hofman i profesor Žagar opisuju u preglednom radu pristup korišten u medicinskoj robotici i automobilskoj industriji. Autori ističu kako sustavi umjetne inteligencije koji zaista mijenjaju praksu nisu oni koji nastaju iz čiste tehničke izvrsnosti, nego oni koji nastaju iz dijaloškog procesa između inženjera koji razumiju mogućnosti i praktičara koji razumiju potrebe.

U preglednom radu kojega je priredio profesor Picek, dan je osvrt na sigurnost strojnog učenja. Autor posebno naglašava kako robusniji i sigurniji sustavi strojnog učenja neće nastati jednom tehnikom, nego kombinacijom tehničkih, organizacijskih i regulatornih mjera kroz cijeli životni ciklus sustava.

Pregledni rad o primjeni strojnog učenja u kemijskog inženjerstvu priredio je profesor Bolf sa suradnicom. Prema autorima, integracija procesnog znanja s metodama podatkovne znanosti i strojnog učenja predstavlja ključan smjer budućeg razvoja koji otvara nove mogućnosti za unapređenje industrijskih procesa.

U izvornom znanstvenom radu kojega je sa suradnicama priredio profesor Zelić, prikazana je primjena umjetne inteligencije u predviđanju i optimiranju sastava vodenih dvofaznih sustava za ekstrakciju enzima. Umjesto tradicionalne metode pokušaja i pogreške, autori koriste metodologiju temeljenu na racionalnom odabiru formulacija

ekstrakcijskih sustava prema poznatim fizikalno-kemijskim svojstvima koju su dodatno podržali računalnim modeliranjem i optimiranjem.

Umjetnu inteligenciju, dubinsko učenje i kauzalnost u znanosti o materijalima opisuje profesor Kurtanjek u izvornom znanstvenom radu. Autor ističe kako strojno učenje i duboko učenje revolucioniraju znanost o materijalima bitnim za razvoj održivih tehnologija, nove izvore energije, zaštitu okoliša, i razvoj novih lijekova.

U preglednom radu kojega je sa suradnicom priredila profesorica Galić, dan je kritički osvrt nakon završetka projekta IMAGINEHEART te preostali izazovi u računalnoj analizi srca i srčanih struktura. U okviru projekta, prof. Galić i suradnici razvili su metode za obradu i analizu slika kardiovaskularnog sustava u svrhu dobivanja kompletne slike kardiovaskularnog zdravlja.

U izvornom znanstvenom radu kojega je priredio profesor Matijević sa suradnikom, prikazano je određivanje parametara pougljičavanja čelika primjenom neuronske mreže. Autori naglašavaju kako će se sve bolji rezultati u procjeni vremena pougljičavanja primjenom modela neuralnih mreža postići uključivanjem sve većeg broja eksperimentalnih rezultata, dobivenih na čelicima različitog sastava i pri različitim parametrima pougljičavanja, u proces treniranja neuronske mreže.

Predviđanje kočene snage i brzine vrtnje motora brodova za rasuti teret primjenom metoda strojnog učenja prikazuju u izvornom znanstvenom radu profesorica Degiuli i suradnici. Autori ističu kako rezultati dobiveni na temelju zaglađenih podataka pokazuju da modeli ansambla regresijskih stabala ostvaruju uravnotežen kompromis između interpretabilnosti i točnosti, što ih čini posebno prikladnima za praktične inženjerske primjene.

U izvornom znanstvenom radu kojega je priredio profesor Zelenika sa suradnikom, analizirana je primjena umjetne inteligencije za karakterizaciju nanotriboloških svojstava tehnoloških tankih filmova. Dobiveni modeli omogućili su utvrđivanje ovisnosti nanometarskog trenja o procesnim parametrima, vjerno reproducirajući eksperimentalne rezultate na nevidenim skupovima podataka uz dobivanje jednostavnih matematičkih korelacija.

Primjenu metoda umjetne inteligencije u naprednim oksidacijskim procesima, pri čemu je fokus na fotokatalitičkoj razgradnji organskih mikrozagađivala, prikazali su u preglednom radu profesorica Čurković sa suradnicama. Autorice ističu kako će budućí napredak u području naprednih oksidacijskih procesa zahtijevati blisku suradnju kemijskih inženjera, stručnjaka za materijale i znanstvenika u području računalne inteligencije, uz naglasak na razvoj robusnih, fizikalno utemeljenih i interpretabilnih modela koji će fotokatalizu pozicionirati kao pouzdanu tehnologiju zaštite okoliša.

Usporedbu postupaka klasifikacije tekstilija primjenom *Weka* i *Orange Data Mining* programskih paketa analizirali su u izvornom znanstvenom radu profesor Penava i

suradnici. Autori posebno naglašavaju superiornost metoda dubokog učenja u odnosu na filtracijske metode čime se potvrđuje dominacija pristupa dubokog učenja u izdavanju relevantnih značajki ulaznog skupa primjera.

U izvornom znanstvenom radu kojega su priredile profesorica Petrak sa suradnicom, prikazana je primjena umjetne inteligencije za digitalizaciju tekstilnih materijala kod 3D simulacije odjeće. Pri tome autorice zaključuju kako buduća istraživanja trebaju obuhvatiti širi raspon tekstilnih materijala, odjevnih proizvoda i procesa dorade tekstilnih materijala, kao i analize podudarnosti sa stvarnim ponašanjem odjevnih predmeta.

Godišnjak Akademije tehničkih znanosti Hrvatske 2025 objedinio je različita područja primjene umjetne inteligencije. Pri tome su nizom primjera pokrivene teme iz područja elektrotehnike, građevinarstva, grafičke tehnologije, kemijskog inženjerstva, informacijskih sustava, računalstva, strojarstva i brodogradnje te tekstilne tehnologije, što nepobitno pokazuje kako je umjetna inteligencija našla primjenu u različitim inženjerskim disciplinama. Posljedično, Godišnjak 2025 pokazuje i širinu područja koje u okviru svog znanstvenog rada u području umjetne inteligencije obuhvaćaju članovi HATZ-a.

Urednik
Prof. dr. sc. Bruno Zelić

Primjena strojnog učenja za predviđanje i procjenu vodostaja i protoka rijeka pod usporom mora

Jonatan Lerga^{1,2}, Anna Maria Mihel^{1,2}, Nino Krvavica^{2,3}

¹Sveučilište u Rijeci, Tehnički fakultet, Vukovarska 58, 51000 Rijeka

²Sveučilište u Rijeci, Centar za umjetnu inteligenciju i kibernetičku sigurnost, R. Matejčić 2, 51000 Rijeka

³Sveučilište u Rijeci, Građevinski fakultet, R. Matejčić 3, 51000 Rijeka

Sažetak: *Rijeke pod utjecajem mora predstavljaju dinamične sustave u kojima se javljaju složena međudjelovanja toka slatke vode i oscilacija mora. Upravljanje vodnogospodarskim sustavima u takvim okruženjima uvelike ovisi o kvaliteti i pouzdanosti hidroloških podataka. Međutim, nagle i teško predvidljive promjene vodostaja otežavaju primjenu standardnih hidroloških modela, osobito kada je potrebno procijeniti protok na temelju mjerenja vodostaja. U ovom radu istražena je primjena suvremenih metoda strojnog učenja za predviđanje i procjenu hidrodinamičkih značajki rijeka pod usporom mora, s naglaskom na donji tok rijeke Neretve – područje koje je zbog porasta razine mora, sezonskih promjena dotoka slatke vode i čestih ekstremnih događaja prepoznato kao jedno od najosjetljivijih na klimatske rizike.*

U tu svrhu razvijeni su hibridni modeli temeljeni na neuronskim mrežama koji kombiniraju različite pristupe analize vremenskih serija. Za predviđanje vodostaja korišten je model koji povezuje model duge kratkoročne memorije (LSTM) i konvolucijske mreže, dok je za rekonstrukciju protoka primijenjen LSTM model proširen mehanizmom pažnje. Takvi modeli omogućuju učinkovitije prepoznavanje nestacionarnih procesa te složenih signala povezanih s utjecajem plime i riječnih dotoka pogotovo tijekom ekstremnih događaja.

Dobiveni rezultati potvrđuju da hibridni modeli strojnog učenja nadmašuju tradicionalne pristupe, osobito u uvjetima gdje se istodobno javljaju utjecaji rijeke i mora. Praktične primjene ovakvih modela uključuju poboljšanje sustava ranog upozorenja na poplave, optimizaciju upravljanja sustavima navodnjavanja te potporu donošenju odluka u kontekstu prilagodbe klimatskim promjenama.

Ključne riječi: *strojno učenje, predviđanje, procjena, vodostaj, protok*

1. Uvod

Značaj dinamičnih sustava, kao što su rijeke pod utjecajem uspora mora prepoznat je u brojnim područjima, od upravljanja vodnim resursima [1], do razvoja strategija zaštite, uključujući prognoziranje ekstremnih pojava i procijene utjecaja podizanja razine mora [2]. Na složeni tok rijeka pod usporom mora negativno utječu dvije kategorije čimbenika, prirodne i antropogene. Kod prirodnih čimbenika poseban naglasak stavlja se na klimatske promjene, koje su u posljednjem desetljeću dovele do značajnih promjena dinamike toka rijeka, poput učestalijih ekstremnih pojava, kao što su poplave i suše [3]. Takve promjene mogu uzrokovati narušavanje bioloških ekosustava [4] te promjene u hidrološkom režimu rijeka [5]. Istodobno, promjene u hidrološkom režimu rijeke su također posljedica utjecaja urbanizacije, intenzivne poljoprivrede, preinaka poplavnih ravnica kao i drugih antropogenih čimbenika [4, 6].

Osiguranje učinkovitog upravljanje vodnim resursima, kao i uspostava strategija zaštite, omogućuju ne samo pravovremene reakcije kroz analize i praćenje, već i očuvanja prirodnih staništa. Uspješno ostvarivanje navedenih ciljeva moguće je postići kroz uspostavu kontinuiranog praćenja osnovnih hidroloških parametara: vodostaja i protoka rijeke. Podaci o vodostaju rijeke dobivaju se putem izravnih mjerenja koristeći uređaje kao što je limnigraf, radarski uređaji ili satelitski visinomjer. Podaci o protoku rijeke nisu dostupni putem direktnih izmjera, već predstavljaju izvedenu veličinu dobivenu putem izračuna ili procjena. U tu svrhu najčešće se koriste izravno dostupne veličine kao što je brzina strujanja vode i površina proticajnog presjeka rijeke.

Iako je u znanstvenoj literaturi dostupan značajan broj radova koji se bave predviđanjem vodostaja ili protoka rijeka [7 - 9] vrlo je malo radova koji se bave priobalnim rijekama koje su pod utjecajem uspora mora. U nedavno objavljenom preglednom radu sistematizirana su sva relevantna istraživanja u području hidrologije koja se bave primjenom strojnog učenja u predviđanju vodostaja ili protoka u rijekama pod utjecajem uspora mora [10]. Pretraživanjem međunarodnih baza, ukupno je identificirano 47 znanstvenih radova objavljenih do 2025. godine koji se bave ovom tematikom. Tijekom pregleda radova primijećen je relativno spor porast u popularnosti primjene strojnog učenja od 1990. do 2000. godine, nedostatak kontinuiteta u učestalosti obavljenih studija, ograničen broj studija koje proučavaju odnos razine vodostaja i protoka, te neravnomjernu regionalnu zastupljenost, pri čemu su prevladavale rijeke pod usporom mora na području Azije [10, 11].

Protok rijeke istražen je u svega devet radova, počevši s najstarijim radom [12] koji je koristio neuronske mreže za kreiranje protočne krivulje, dok su se ostali radovi uglavnom fokusirali na rekonstrukciju ili predviđanje protoka. Modeli temeljeni na mreži duge kratkoročne memorije (LSTM) primijenjeni su tek nedavno, od 2023.

godine, s dva dostupna rada u području predviđanja protoka [13, 14]. Što se tiče vremenske rezolucije, korištene su skale izražene u danima ili intervalima od pola sata, a ulazni parametri nisu bili ograničeni samo na razinu vodostaja, već su uključivali i varijable poput razine mora, temperature, brzinu protoka ali i druge. Najnoviji rad [15] fokusirao se na praćenja protoka u stvarnom vremenu i istražio je primjenu metodološkog okvira koji omogućuje prilagodljiv odabir algoritma, uz primjenu genetskog algoritma u svrhu optimizacije hiperparametara. Taj okvir se pokazao kao bolje rješenje u odnosu na samostalne modele korištene unutar metodološkog okvira.

Razina vodostaja istražena je u većem broju radova, točnije njih 40. Prva dostupna studija primijenila je osnovnu arhitekturu neuronske mreže za predviđanje razine vodostaja [16]. Primjena modela temeljenih na mreži druge kratkoročne memorije započela je nešto ranije od problema vezanih uz protok, točnije 2018. godine sa studijom usmjerenom na problem plavljenja cestovnog mosta [17]. Recentniji radovi testirali su primjenu navedenog modela kao dijela hibridnih arhitektura, poput modela koji povezuje LSTM s konvolucijskom mrežom [18, 19] ili modela koji povezuje LSTM s hidrodinamičkim modelima [20, 21], što je doprinijelo boljim rezultatima u odnosu na primjenu samostalnog LSTM-a.

U ovom radu prikazana su ključna zapažanja i rezultati doktorskog istraživanja Anne Marie Mihel [11], koji su prethodno objavljeni u nekoliko znanstvenih radova u vrhunskim međunarodnim časopisima [10, 22]. Istraživanje se bavi primjenom metoda strojnog učenja za predviđanje i procjenu razine vodostaja i protoka rijeke Neretve, rijeke koja je pod snažnim utjecajem mora. U okviru istraživanja razvijena su dva hibridna modela temeljena na rekurzivnim neuronskim mrežama. Prvi model koristi pristup duge kratkoročne memorije uz dodatni mehanizam pažnje te se primjenjuje za procjenu i rekonstrukciju protoka u uzvodnom dijelu rijeke. Pri tome se koriste simulirani i mjereni podaci o vodostaju s nizvodnih, srednjih i uzvodnih lokacija. Drugi model povezuje model duge kratkoročne memorije s konvolucijskom neuronskom mrežom te se koristi za predviđanje razine vodostaja i protoka. Osim podataka o vodostaju dobivenih numeričkim modeliranjem na dostupnim mjernim stanicama, model kao ulazni podatak koristi i protok rijeke. Cilj istraživanja bio je pokazati da hibridni modeli, samostalno ili u kombinaciji s dodatnim metodama, mogu smanjiti pogreške u procjeni i predviđanju vodostaja i protoka. Dobiveni rezultati potvrđuju nalaze ranijih istraživanja, uz dodatni doprinos kroz primjenu novih modela i kombinacija metoda.

2. Područje istraživanja i podaci

2.1. Rijeka Neretva

Rijeka Neretva, ukupne duljine 215 km, protječe kroz dvije države. Većim dijelom prolazi kroz Bosnu i Hercegovinu (193 km), dok značajno manji dio toka rijeke prolazi kroz Republiku Hrvatsku (22 km), gdje se ulijeva u Jadransko more [23]. Dionica rijeke koja protječe kroz Hrvatsku predstavlja fokus provedenog istraživanja te se smatra dijelom rijeke pod utjecajem uspora mora.

Utjecaj Jadranskog mora očituje se kroz dva glavna aspekta relevantna za hidrološke uvjete. Za vrijeme malih voda tok Neretve karakterizira izrazita vertikalna uslojenost, pri čemu donji sloj morske vode teče uzvodno prema Metkoviću, dok gornji sloj slatke vode teče nizvodno prema ušću [23]. S druge strane, tijekom velikih voda, razina mora generira uspor i utječe na vodostaje duž donjeg toka rijeke Neretve, čak i kod Metkovića, što može imati ozbiljne implikacije za generiranje poplava [24]. Stoga je zaštita ovog područja od potencijalnih opasnosti uzrokovanih hidrološkim ekstremima od iznimnog značaja za budućnost poljoprivrede, kao i za sigurnost lokalnog stanovništva.

Prvi podaci o vodostaju na tom području datiraju iz 1934. godine, dok su najranija dostupna kontinuirana mjerenjima započela 1957. godine na lokaciji Metković. Unatoč velikoj važnosti ovog područja, kontinuirana mjerenja protoka uspostavljena su tek nedavno, od sredine 2015. godine, na profilu cestovnog mosta, smještenog približno 90 m uzvodno od hidrološke postaje Metković [25].

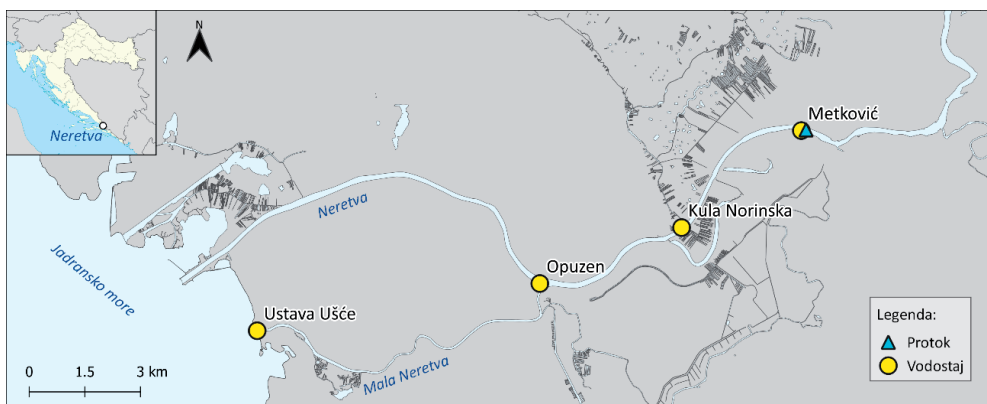
2.2. Skupovi podataka

Za potrebe predmetnog istraživanja korištena su tri skupa podataka. Prvi skup obuhvaća mjerene podatke prikupljene od strane Državnog hidrometeorološkog zavoda te Hrvatskih voda. Iako Državni hidrometeorološki zavod pruža podatke o protocima, oni se uglavnom dobivaju primjenom protočne krivulje, što nije pouzdana metoda za dionice rijeke koje su pod usporom mora. Iz tog razloga, na rijeci Neretvi, Hrvatske vode uspostavile su sustav monitoringa protoka Neretve kod Metkovića pomoću horizontalnog akustičnog Dopplerovog strujomjera (H-ADCP), koji omogućuje pouzdanu procjenu protoka. Naime, za razliku od protočne krivulje koja za procjenu razine vodostaja zahtijeva unaprijed poznat protok, ADCP uređaji omogućuju proračun protoka putem direktno izmjenjenog polja brzina i geometrije poprečnog presjeka korita [26].

Zbog potencijalnih problema povezanih s kvalitetom mjerenih podataka, uključujući nedostajuće podatke, utjecaj nefizičkih oscilacija te nepouzdanost vrijednosti niskih

protoka, u okviru ovoga istraživanja uključeni su i simulirani podatci. Stoga, preostala dva skupa podataka generirana su primjenom hidrauličkih modela HEC-RAS i STREAM 1D. Oba modela omogućuju proračun jednodimenzijskog nestacionarnog toka površinskih voda [11] rješavanjem sustava jednadžbi plitkih voda, u svrhu prognoziranja hidrodinamičkih procesa [27]. Odabrana HEC-RAS simulacija bazira se na pretpostavci homogene gustoća fluida, dok salinitet i temperatura ostaju konstantni na cijeloj dužini analiziranog riječnog toka. STREAM 1D ima poseban naglasak na primjenu u stratificiranim estuarijima, gdje za razliku od jednoslojnog HEC-RAS modela, simulira dvoslojnu strukturu riječnog toka i stoga pruža točniji prikaz hidrauličkih parametara u uvjetima malih voda [11].

Skupovi podataka sadrže podatke o vodostaju s četiri lokacije od ušća do Metkovića. Prva lokacija nalazi se u blizini ušća rijeke Male Neretve, gdje je smještena mareografska postaja, u ovom radu se naziva Ušće. Slijede hidrološke postaje Opuzen (11 km od ušća rijeke), Kula Norinska (16 km od ušća rijeke) i Metković (22 km od ušća rijeke). Podatci o protoku prikupljaju se na lokaciji Metković, 90 m uzvodno od hidrološke postaje. Relevantne postaje prikazane su na Slici 1. Jedina značajnija razlika među korištenim skupovima podataka odnosi se na vremenski raspon podataka. Skup podataka dobiven HEC-RAS modelom korišten je u svrhu preliminarnih analiza te obuhvaća razdoblje od 2016. do kraja 2019. godine, dok preostala dva skupa podataka također započinju 2016. godine, ali traju do 2021. godine.



Slika 1: Nizvodni tok rijeke Neretve pod utjecajem uspora mora, s naglaskom na mareografsku postaju (Ušće), hidrološke postaje (Opuzen, Kula Norinska, Metković), i lokaciju gdje se procjenjuje protok (Metković) [28]

3. Metodologija

Metodologija provedenog istraživanja sastojala se od nekoliko koraka. U prvom koraku provedena je priprema podataka. Problem nedostajućih podataka u mjerenom skupu riješen je primjenom nelinearne korelacije između H-ADCP uređaja. Pažljivi-

vim filtriranjem šuma nastojao se smanjiti utjecaj nefizičkih oscilacija. Provedena je provjera potencijalnog kašnjenja podataka između mjernih stanica. Nakon toga podaci su podijeljeni na skup podataka za treniranje i skup za testiranje u omjeru od 80% - 20%. Za mjerene podatke i simulirane podatke dobivene modelom STREAM 1D, treniranje je obuhvatilo razdoblje od siječnja 2016. do listopada 2020., dok je za HEC-RAS skup podataka obuhvaćalo razdoblje od siječnja 2016. do veljače 2019., a preostali dio podataka korišten je za testiranje.

Zbog različitih raspona vrijednosti vodostaja i protoka provedeno je skaliranje podataka primjenom MinMaxScaler metode u raspon od [0,1]. Nakon skaliranja podaci su pretvoreni u pomični prozor koji je sadržavao podatke od prethodnog dana (24 sata), pri čemu su za procjenu korišteni samo podaci o vodostaju, dok su za scenarije predviđanja uključeni i podaci o protoku. Duljina prozora odabrana je u skladu s plimnim režimom Jadranskog mora [24], s ciljem obuhvaćanja cjelodnevnog plimnog ciklusa koji uključuje i poludnevne i dnevne komponente.

Za potrebe predviđanja primijenjene su dvije metode obrade signala, pretvorba signala u dvodimenzionalne matrice koje predstavljaju spektrograme te napredne metode kao što je varijacijska dekompozicija modova (VMD). Spektrogrami su kreirani koristeći podatke od prethodnog dana (24 sata unazad), međutim, kao ulaz koriste podatke o vodostaju i protoku. VMD metoda na brz i stabilan način razdvaja izvorne signale u zasebne komponente, s naglaskom na smanjenu prisutnost kumulativnih pogreški [29].

Treniranje i validacija modela proveli su se primjenom peterostruke unakrsne validacije s pretraživanjem mreže parametara. Broj podjela odabran je na temelju dostupne količine podataka, ali i „ravnoteže“ između varijance i pristranosti [30]. Za jednostavnije modele strojnog učenja (DT, RF, SVR, LGBM i XGB) korištena je *scikit-learn* knjižnica, dok za PyTorch modele *skorch* i klasu omotača *NeuralNetRegressor*. U pogledu optimizacijskog algoritma, izabran je NAdam (*engl. Nesterov-accelerated Adaptive Moment Estimation*) koji pruža ubrzanu konvergenciju [31], uz dodatno uključenje broja epoha za rano zaustavljanje, točnije njih 15, dok je sveukupan broj epoha iznosio 500.

Glavna mjera pogreške za validaciju modela bila je srednja kvadratna pogreška ili MSE, dok su za testiranje modela korišteni korijen srednje kvadratne pogreške ili RMSE, srednja apsolutna pogreška ili MAE, srednja apsolutna postotna pogreška ili MAPE, Nash-Sutcliffe koeficijent učinkovitosti ili NSE, te koeficijent korelacije ili R. Dodatne mjere korištene u svrhu pronalaska optimalnih parametara VMD metode odnose se na indeks ortogonalnosti i omjer pogreške rekonstrukcije. Dodatni korak odnosi se na pružanje interpretabilnosti modela kao i transparentnosti uz primjenu SHAP metode na jednostavnijim modelima i ciljanog izostavljanja značajki za modele bazirane na LSTM-u.

Korištene su dvije hibridne arhitekture strojnog učenja. Prva arhitektura predstavlja novo predloženo rješenje temeljeno na modelu duge kratkoročne memorije (LSTM) proširenom mehanizmom pažnje [11]. Druga je hibridna mreža koja je već ranije primijenjena za slične zadatke predviđanja, a temelji se na kombinaciji konvolucijske neuronske mreže i LSTM modela [32, 33]. Novo predložena hibridna arhitektura sastoji se od LSTM modela kombiniranog s mehanizmom pažnje, koji završava s potpuno spojenim slojem. Arhitektura korištena za predviđanje sastoji se od dva konvolucijska sloja, jednog Max Pooling sloja, jednog LSTM sloja, regularizacijskog (Dropout) sloja te potpuno spojenog sloja. Detaljan opis arhitektura dostupan je u [11].

4. Rezultati i diskusija

U nastavku su prikazani rezultati četiri smjera istraživanja: (1) procjene protoka, (2) procjene protoka uz primjenu metode dekompozicije signala, (3) predviđanja protoka i (4) predviđanje vodostaja. Prvi smjer istraživanja uspoređuje rezultate predloženog hibridnog modela LSTM-Attention sa samostalnim modelima poput LSTM-a, XGB, LGBM, SVR s rbf i sigmoid jezgrenom funkcijom, RF i DT-om koristeći vremenske serije vodostaja i protoka [22]. Drugi smjer istraživanja uzima dva najbolja modela iz prvog scenarija te uspoređuje rezultate modela nakon što su vremenske serije pretvorene u zasebne kategorije plimnih komponenti koje su zatim korištene za treniranje modela, kako bi se procijenilo je li uz primjenu metode obrade signala moguće smanjiti pogrešku procjene [11]. Zadnja dva smjera istraživanja prikazuju rezultate preliminarnih analiza u pogledu predviđanja protoka i vodostaja, koristeći hibridni model CNN-LSTM [32, 33].

4.1 Procjena protoka

Rezultati predloženog hibridnog modela, LSTM-Attention, uspoređeni su s rezultatima samostalnih modela strojnog učenja na mjerenim i simuliranim podacima. Predloženi model pokazao je najbolje performanse, što je vidljivo iz Tablice 1 koja prikazuju mjere pogreške za različite modele. Drugim najboljim modelom pokazao se samostalni LSTM, koji ima lošije performanse od LSTM-Attention za 9,6% RMSE, 9,7% MAE, 0,5% NSE i 0,1% R za mjereni set podataka, te 14,3% RMSE, 16,7% MAE, 0,2% NSE i 0,1% R za simulirani set podataka.

Rezultati pokazuju konzistentno poboljšanje kroz sve mjere za predloženi hibridni model, kod oba skupa podataka, iako je razlika nešto veća za mjereni skup što je očekivano. Razlika između performansi najboljeg modela za mjereni u odnosu na simulirani skup podataka iznosi 48,7% za RMSE, 47,8% za MAE, 2,0% za NSE, i 0,8% za R metriku. Najveće pogreške procjene rezultata pružile su obje varijante SVR modela.


Tablica 1: Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skup mjerenih i simuliranih podataka (podebljan je rezultat najboljeg modela, a ostali su poredani od najboljih prema lošijim performansama) [22]

Modeli strojnog učenja	RMSE (m ³ /s)	MAE (m ³ /s)	NSE	R
Predloženi model: LSTM-Attention	57,406 / 29,473	43,201 / 22,530	0,974 / 0,993	0,989 / 0,997
LSTM	63,495 / 34,384	47,821 / 27,057	0,969 / 0,991	0,988 / 0,996
XGBoost	73,212 / 48,428	51,836 / 34,739	0,958 / 0,982	0,982 / 0,991
LGBM	73,130 / 53,797	52,260 / 36,341	0,958 / 0,977	0,983 / 0,989
RF	73,306 / 48,729	52,159 / 34,669	0,985 / 0,981	0,982 / 0,991
DT	76,147 / 51,747	54,368 / 37,492	0,955 / 0,979	0,980 / 0,990
SVR-rbf	77,387 / 70,128	54,410 / 36,554	0,953 / 0,962	0,979 / 0,983
SVR-sigmoid	82,155 / 53,010	58,992 / 40,978	0,947 / 0,978	0,947 / 0,990

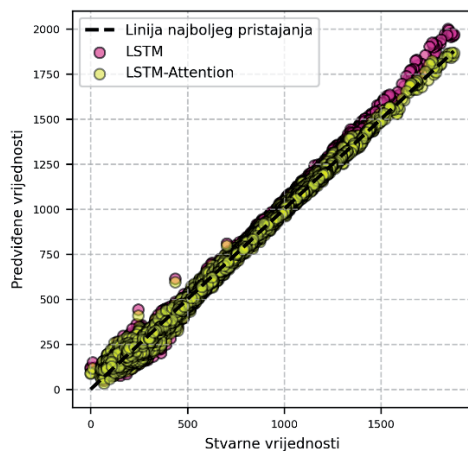
*Mjereni skup podataka / Simulirani skup podataka

Dijagram predviđenih naspram stvarnih vrijednosti prikazan je za dva modela koja su pružila najbolje rezultate, i za oba scenarija (Slika 2). Za slučaj mjerenih podataka odstupanja su slična u usporedbi s cijelim rasponom podataka, s naglaskom na veća za protoke čije vrijednosti prelaze 1000 m³/s, iako hibridni model ima užu raspršenost točaka oko pravca najboljeg pristajanja u odnosu na LSTM. Za slučaj simuliranih podataka najveća odstupanja procjene uočena su za protoke veće od 1000 m³/s za LSTM model, dok je hibridni model adekvatno uhvatio čak i najekstremnije vrijednosti protoka. Najšira raspršenost točaka za simulirane podatke oko pravca najboljeg pristajanja uočena su za najmanje vrijednosti protoka, koje obuhvaćaju najveći dio podataka.

Slika 3 pruža detaljniji uvid kada je riječ o različitim rasponima vrijednosti protoka i distribuciji podataka, te pogrešci MAE za svaku kategoriju protoka i model. Za analizu su generirane četiri grupe raspona protoka: (a) raspon protoka između 0 i 300 m³/s, koji predstavlja kategoriju niskih protoka, (b) protok čije vrijednosti se nalaze u rasponu od 300 do 1050 m³/s, što predstavlja kategoriju srednjih protoka, (c) protoke između 1050 i 1500 m³/s koji predstavljaju kategoriju visokih protoka, te (d) između 1500 i 1900 m³/s, koji predstavljaju najekstremnije visoke vrijednosti protoka, točnije jedan događaj.



(a)




(b)

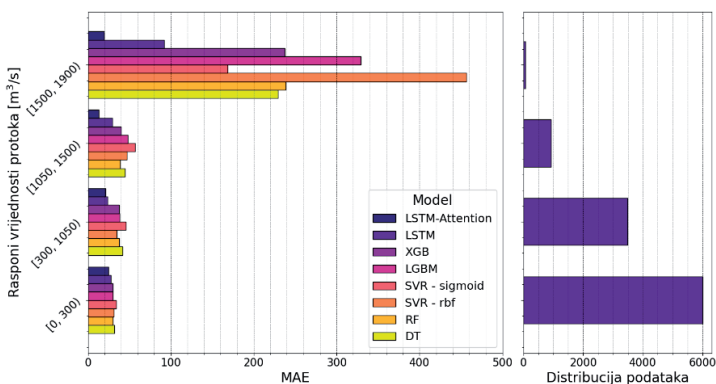
Slika 2: Predviđene naspram stvarne vrijednosti: (a) Mjereni podatci i (b) Simulirani podatci [22]

Većina podataka nalazi se u kategoriji niskih protoka, točnije oko 60% podataka, i za ovu kategoriju uočena su najmanja odstupanja kada je riječ o pogrešci procjene modela. Srednja kategorija protoka koja čini drugu najzastupljeniju kategoriju podataka, s oko 30%, pokazuje veća odstupanja između rezultata mjerenih i simuliranih podataka, sa simuliranim podacima gdje su uočena odstupanja veća i od $20 \text{ m}^3/\text{s}$. Najveće razlike u performansama očit su za visoke i najekstremnije vrijednosti protoka, gdje su modeli temeljeni na rekurzivnim mrežama pokazali značajno manju pogrešku procjene u odnosu na jednostavne modele strojnog učenja. Predloženi LSTM-Attention model pokazao se kao najbolje rješenje u gotovo svim kategorijama i setovima podataka, s iznimkom kategorije ekstremno visokih protoka u mjerenom skupu podataka.

Slika 4 prikazuje analizu doprinosa ulaznih značajki. Za jednostavnije modele analiza je provedena primjenom SHAP metode, pri čemu su kao primjer prikazani rezultati XGB modela. Za predloženi hibridni model LSTM-Attention primijenjena je metoda ciljanog izostavljanja značajki. Budući da je cilj istraživanja procjena protoka na lokaciji Metković, iz prikazanih vizualizacija jasno je vidljivo da razina vodostaja na lokaciji Metković ima najveći utjecaj na rezultate modela. Nakon toga slijedi lokacija Ušće, dok preostale stanice, Opuzen i Kula Norinska, imaju manji, ali i dalje značajan utjecaj.



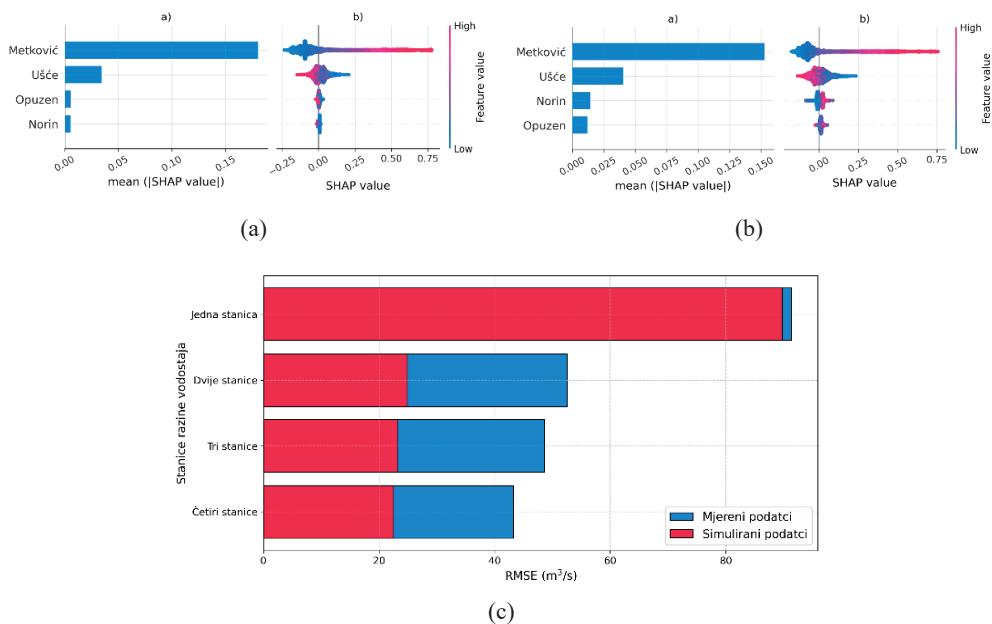
(a)



(b)

Slika 3: Pogreška procjene protoka modela prema različitim rasponima vrijednosti protoka, uz prikaz distribucije podataka za: (a) Mjereni skup podataka i (b) Simulirani skup podataka [22]

Analiza rezultata pokazala je da predloženi hibridni model pruža najbolje rezultate procjene protoka u gotovo svim scenarijama, od niskih do visokih protoka, kroz sva godišnja doba, te za skup mjerenih i simuliranih podataka. Konzistentnost najboljih rezultata bila je vidljiva kroz sve kategorije protoka, što znači da se model pokazao pouzdanim čak i kada postoji problem neuravnoteženosti distribucije podataka, te da je primjenjiv u stvarnim uvjetima ekstremnih sušnih i vodnih prilika.




Slika 4: Analiza doprinosa značajki putem SHAP metode za jednostavnije modele strojnog učenja (a) XGB rezultat za simulirani skup podataka, (b) XGB rezultat za mjereni skup podataka, te (c) metode ciljanog izostavljanja značajki za modele temeljene na rekurzivnoj neuronskoj mreži za oba skupa podataka [22]

4.2 Procjena protoka uz primjenu metode obrade signala

U nastavku istraživanja analizirana su dva modela koja su, prema mjerama pogreške, pokazala najmanje pogreške procjene. Daljnja analiza uključivala je primjenu metoda obrade signala na mjerenim podacima, konkretno varijacijske dekompozicije modova (VMD). Prvi korak sastojao se od dekompozicije signala razine vodostaja u modne funkcije. U tu svrhu istraženi su parametri VMD dekompozicije poput broja modnih funkcija i kvadratnog penalizacijskog parametra. Odabir VMD parametara zasnivao se na pronalasku najmanjeg broja modnih funkcija koji omogućuje dekompoziciju signala u osnovne kategorije plimnih komponenti, ali i kvadratnom penalizacijskom parametru gdje je najmanje prisutno spektralno curenje. Ovaj korak rezultirao je odabirom pet modnih funkcija i kvadratnom penalizacijskom parametru jednakom 5000.

Dobivene modne funkcije svih stanica razina vodostaja klasificirane su u kategorije, dugoperiodne, dnevne, poludnevne, više harmonike i rezidualni signal. Rezidualni signal uz dodatnu dekompoziciju i dalje je ostao jak sadržavajući i poludnevne i dnevne komponente signala, stoga je on pribrojen komponenti viših harmonika, čineći jednu kategoriju koja se referira kao rezidualni miješani signal. Primjer dekompozicije signala razine vodostaja za stanicu Metković prikazan je na Slici 5.




Slika 5: Rezultat dekompozicije signala u plimne komponente za lokaciju Metković [11]

Usporedba rezultata mjera pogreške za različite formate ulaznih podataka prikazana je u Tablici 2. Za format vremenskih serija predloženi hibridni model pokazuje bolje performanse, dok kod korištenja dekomponiranih i klasificiranih plimnih komponenti, samostalni LSTM ostvaruje poboljšanje svih mjera pogreške. Konkretno, samostalni LSTM smanjio je pogrešku procjene za 13,7% RMSE, 12,6% MAE, te 0,2% za NSE u usporedbi s LSTM-Attention modelom treniranim na vremenskim nizovima. Dobiveni rezultati upućuju na činjenicu kako vremenski nizovi rezultiraju manjom pogreškom procjene protoka u Metkoviću, dok jednostavniji modeli poput samostalnog LSTM-a zahtijevaju dodatnu obradu podataka kako bi postigli bolju točnost od predložene hibridne arhitekture.

Tablica 2: Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skupove podataka u formatu vremenskih serija i dekomponiranih signala kategoriziranih u plimne komponente (podebljan je rezultat najboljeg modela zasebno za različiti format ulaznih podataka) [11]

Format ulaznih podataka	Model strojnog učenja	RMSE m ³ /s	MAE m ³ /s	NSE	R
Vremenske serije	LSTM	63,495	47,821	0,969	0,988
	LSTM-Attention	57,406	43,201	0,974	0,989
Plimne komponente	LSTM	49,533	37,776	0,981	0,991
	LSTM-Attention	58,524	43,564	0,973	0,990

Dekompozicija signala protoka u unutardnevne oscilacije (uzrokovane protokom) i međudnevne oscilacije (uzrokovane plimom i osekom) primjenom Butterworthovog filtera na signalu protoka (Slika 6), pružila je dodatni uvid u performanse modela. Međudnevne oscilacije adekvatno su procijenjene putem LSTM-Attention modela treniranog na vremenskim serijama, te u ovom slučaju dekompozicija nije dodatno doprinijela poboljšanju performansi modela već stagnaciju. Suprotan trend uočen je kod samostalnog LSTM modela, čije su procjene bliže stvarnim vrijednostima na dekomponiranim signalima. Međutim, značajnih razlika između ova dva modela nema, stoga u slučaju međudnevnih oscilacija hibridna arhitektura predstavlja dovoljno dobro rješenje. Situacija se mijenja kada se promatraju unutardnevne oscilacije gdje su poboljšanja performansi oba modela uočena nakon dekompozicije signala. Zaključno, predložena hibridna arhitektura predstavlja bolju opciju kada su dostupne sirove vremenske serije, dok samostalni LSTM značajnije prednjači poboljšanju performansi kada je riječ o međudnevnim oscilacijama.



Slika 6: Usporedba rezultata samostalnog LSTM modela i predložene hibridne arhitekture, LSTM-Attention, na dekomponirani signal protoka u Metkoviću podijeljen na unutardnevne i međudnevne oscilacije, gdje (a) prikazuje rezultate dva najbolja modela za unutardnevne, dok (b) prikazuje rezultate dva najbolja modela za međudnevne oscilacije [11]

4.3 Predviđanje protoka

Problem predviđanja protoka do 12 sati unaprijed temeljio se na korištenju ulazne vremenske serije u trajanju od 24 sata, koja je uključivala podatke o vodostaju s četiri lokacije te protoku s jedne lokacije (navedene stanice su prethodno prikazane na Slici 1). Navedeni podatci korišteni su kao ulaz u tri različita formata: prvi u izvornom obliku vremenskih serija, drugi u formatu spektrograma, odnosno dvodimenzionalnih matrica, te treći kao kombinacija vremenskih serija i spektrograma.

Tablica 3: Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skupove podataka u formatu vremenskih serija i dekomponiranih signala kategoriziranih u plimne komponente (podebljan je rezultat najboljeg modela) [32]

Horizont predviđanja	Format ulaznih podataka	RMSE (m ³ /s)	MAPE (%)	NSE
1	Vremenske serije	27,67	8,652	0,988
	Spektrogram	17,696	3,378	0,995
	Vremenske serije i spektrogram	19,309	5,293	0,994
6	Vremenske serije	59,229	14,013	0,943
	Spektrogram	54,406	11,766	0,952
	Vremenske serije i spektrogram	56,603	13,223	0,948
12	Vremenske serije	73,531	16,172	0,915
	Spektrogram	68,532	14,187	0,924
	Vremenske serije i spektrogram	69,523	15,051	0,922


Rezultati provedene studije prikazani su u tabličnom obliku putem mjera pogreške za različite horizonte predviđanja u Tablici 3. Uvođenje vremensko-frekvencijske domene, bilo kao samostalnog formata ulaza ili u kombinaciji s vremenskim serijama, rezultiralo je manjim razlikama u pogreškama predviđanja za područja rijeka pod utjecajem uspora mora. Najveće razlike u performansama između tri formata ulaznih podataka za CNN-LSTM uočene su za prvi sat predviđanja u slučaju vremenskih serija, dok se razlike u pogreškama predviđanja postupno smanjuju s povećanjem horizonta predviđanja.

Provedeno istraživanje dovelo je do zaključka da razmatranje dodatne frekvencijske domene, uz vremensku, pozitivno utječe na rezultate hibridnog modela CNN-LSTM. Iako se razlika između različitih formata ulaznih podataka s produljenjem vremena smanjila, što je bilo očekivano, otvorila se mogućnost budućih istraživanja u pogledu ulaznih podataka koji prethodno nisu bili razmatrani za istraženi tip problema.

4.4 Predviđanje vodostaja

U svrhu predviđanja vodostaja do 24 sata unaprijed korištena je ista hibridna arhitektura modela kao i za problem predviđanja protoka, uz iznimku ulaznih podataka. Osnovni skup podataka, koji sadrži satne izmjere razine vodostaja te protoka, proširen je primjenom metode inženjerstva značajki. Dodatne značajke uključivale su

dnevne, prosječne dnevne i 24-satne pomične prosjeke vrijednosti razine vodostaja i protoka, kao i skup vremenski ovisnih obilježja, uključujući brojne vremenske intervale, počevši od sata, dnevnih razdoblja kao što je jutro, popodne i večer, pa sve do godišnjih doba, mjeseca i godine. Ovisnost značajki o razini vodostaja Metkoviću analizirana je primjenom metode uzajamne informacije, kao što je prikazano na Slici 7. Najmanji utjecaj na razinu vodostaja u Metkoviću imala su dnevna razdoblja, dok su najveći utjecaj imali izvorni sati te dnevne vrijednosti razina vodostaja i protoka.



Slika 7: Analiza doprinosa značajki proširenog skupa podataka (RV predstavlja razinu vodostaja, P protok, * prosječne dnevne vrijednosti, ** 24-satne pomične prosjeke) [33]

Rezultati modela (Tablica 4) koji koristi različite formate ulaznih podataka pokazali su se konzistentnima za sve horizonte predviđanja, osim za prvi sat. Naime, prema RMSE, MAE i NSE mjerama pogreške, najbolje rezultate za predviđanja razine vodostaja u Metkoviću u prvom satu dale su vremenske serije, a zatim spektrogrami. Za horizonte predviđanja od dva sata do 24 sata unaprijed prvim najboljim rješenjem pokazao se scenarij u kojem je osnovni skup podataka proširen metodom inženjerstva značajki, nakon čega slijedi osnovni niz vremenskih serija i spektrogrami. Najlošije rezultate tim horizontima, dao je skup podataka koji sadrži spektrograme proširene metodom inženjerstva značajki.

Tablica 4: Rezultati modela strojnog učenja na skupu podataka za testiranje koristeći skupove podataka u formatu vremenskih serija i dekomponiranih signala kategoriziranih u plimne komponente (podebljan je rezultat najboljeg modela koji koristi određeni format ulaznih podataka) [33]

Horizont predviđanja	Format ulaznih podataka	RMSE (m ³ /s)	MAE (m ³ /s)	NSE
1	Vremenske serije	0,026	0,021	0,994
	Vremenske serije s inženjerstvom značajki	0,055	0,040	0,975
	Spektrogram	0,033	0,024	0,991
	Spektrogram s inženjerstvom značajki	0,081	0,060	0,946
12	Vremenske serije	0,096	0,062	0,925
	Vremenske serije s inženjerstvom značajki	0,080	0,052	0,947
	Spektrogram	0,095	0,056	0,926
	Spektrogram s inženjerstvom značajki	0,112	0,092	0,896
24	Vremenske serije	0,100	0,070	0,919
	Vremenske serije s inženjerstvom značajki	0,093	0,064	0,928
	Spektrogram	0,100	0,069	0,919
	Spektrogram s inženjerstvom značajki	0,115	0,080	0,892

U stvarnom svijetu veći značaj se pridaje duljim predviđanja kako bi se osigurale pravovremene reakcije i zaštita područja, pa se fokus stavlja upravo na takve situacije. Istraživanje je pokazalo da proširenjem postojećeg skupa podataka izvornih vremenskih serija s metodom inženjerstva značajki doprinosi poboljšanju performansi postojećeg hibridnog modela CNN-LSTM.

5. Zaključak

Provedeno istraživanje pokazalo je učinkovitost primjene hibridnog pristupa strojnog učenja za procjenu protoka iz mjerenih vodostaja na više lokacija, u odnosu na samostalne modele strojnog učenja. Dekompozicija signala omogućuje postizanje zadovoljavajućih performansi i primjenom samostalnih modela, poput LSTM-a, uz točnost usporedivu s hibridnim modelima, osobito u analizi unutardnevnih oscilacija protoka. Inženjerstvo značajki pozitivno je unaprijedio performanse modela, među-

tim samo u scenariju gdje se koriste vremenske serije. Uključivanje dodatnih prikaza signala, poput spektrograma uz vremenske serije, može dodatno smanjiti pogrešku procjene modela. Zaključno, provedeno istraživanje ukazuje na mogućnost primjene hibridnih modela strojnog učenja za kontinuirano praćenje i procjenu protoka, koji inače zahtijevaju instalaciju i održavanje skupih mjernih uređaja, poput akustičnih strujomjera. Takvi pristupi pokazuju velik potencijal za praktičnu primjenu, uključujući unapređenje sustava ranog upozorenja na poplave, optimizaciju upravljanja sustavima navodnjavanja te pružanje potpore procesima donošenja odluka u kontekstu upravljanja vodnim resursima i prilagodbe klimatskim promjenama.

6. Literatura

- [1] Phan, T.-T.-H.; Nguyen, X. H.: Combining statistical machine learning models with ARIMA for water level forecasting: The case of the Red River, *Advances in Water Resources*, **142** (2020) 103656, <https://doi.org/10.1016/j.advwatres.2020.103656>
- [2] Orton, P. M.; Conticello, F. R., Cioffi, F., Hall, T. M., Georgas, N., Lall, U., Blumberg, A. F., MacManus, K.: Flood hazard assessment from storm tides, rain and sea level rise for a tidal river estuary, *Natural hazards*, **102** (2020) 2, 729-757, <https://doi.org/10.1007/s11069-018-3251-x>
- [3] Chen, K.; Kuang, C., Wang, L., Chen, K., Han, X., Fan, J.: Storm surge prediction based on long short-term memory neural network in the east China sea, *Applied Sciences*, **12** (2022) 1, 181, <https://dx.doi.org/10.3390/app12010181>
- [4] Renaud, F.G.; Syvitski, J.P., Sebesvari, Z., Werners, S.E., Kremer, H., Kuenzer, C., Friedrich, J.: Tipping from the Holocene to the Anthropocene: How threatened are major world deltas?, *Current Opinion in Environmental Sustainability*, **5** (2013) 6, 644-654, <https://doi.org/10.1016/j.cosust.2013.11.007>
- [5] Bilskie, M. V.; Hagen, S. C., Medeiros, S. C., Passeri, F. L.: Dynamics of sea level rise and coastal flooding on a changing landscape, *Geophysical Research Letters*, **41** (2014) 3, 927-934, <https://doi.org/10.1002/2013GL058759>
- [6] Vercruyssen, K.; Grabowski, R.: Human impact on river planform within the context of multi-timescale river channel dynamics in a himalayan river system, *Geomorphology*, **381** (2021) 107659, <https://doi.org/10.1016/j.geomorph.2021.107659>
- [7] Wee, W. J.; Zaini, N. B., Ahmed, A. N., El-Shafie, A.: A review of models for water level forecasting based on machine learning, *Earth Science Informatics*, **14** (2021) 4, 1707-1728, <https://doi.org/10.1007/s12145-021-00664-9>
- [8] Ibrahim, K. S. M. H.; Huang, Y. F., Ahmed, A. N., Koo, C. H., El-Shafie, A.: A review of the hybrid artificial intelligence and optimization modelling of hydrological streamflow forecasting, *Alexandria Engineering Journal*, **61** (2022) 1, 279-303, <https://doi.org/10.1016/j.aej.2021.04.100>
- [9] Ng, K.; Huang, Y., Koo, C., Chong, K., El-Shafie, A., Najah Ahmed, A.: A review of hybrid deep learning applications for streamflow forecasting, *Journal of Hydrology*, **625** (2023) 130141, <http://dx.doi.org/10.1016/j.jhydrol.2023.130141>

- [10] Mihel, A. M.; Lerga, J., Krvavica, N.: Estimating water levels and discharges in tidal rivers and estuaries: Review of machine learning approaches, *Environmental modelling & software*, **176** (2024) 106033, <https://doi.org/10.1016/j.envsoft.2024.106033>
- [11] Mihel, A. M.: Estimation and prediction of discharges in tidal rivers and estuaries using machine learning, *Dostupan na: https://dabar.srce.hr/object/riteh:5401, Pristupljeno: 2025-12-18*
- [12] Habib, E. H.; Meselhe, E. A.: Stage-Discharge Relations for Low-Gradient Tidal Streams Using Data-Driven Models, *Journal of Hydraulic Engineering*, **132** (2006) 5, 482-492, [https://doi.org/10.1061/\(ASCE\)0733-9429\(2006\)132:5\(482](https://doi.org/10.1061/(ASCE)0733-9429(2006)132:5(482)
- [13] Vu, M.; Jardani, A., Krimissa, M., Zaoui, F., Massei, N.: Large-scale seasonal forecasts of river discharge by coupling local and global datasets with a stacked neural network: Case for the Loire River system, *Science of the Total Environment*, **879** (2023) 165494, <https://doi.org/10.1016/j.scitotenv.2023.165494>
- [14] Chen, Z.; Zong, Y., Wu, Z., Kuang, Z., Wang, S.: Prediction of discharge in a tidal river using the LSTM-based sequence-to-sequence models, *Acta Oceanologica Sinica*, **43** (2024) 7, 40-51, <https://doi.org/10.1007/s13131-024-2343-6>
- [15] Li, Y.; Zhao, X., Wang, Y., Zeng, L.: Deep characteristic learning model for real-time flow monitoring based on H-ADCP, *Journal of Hydrology: Regional Studies*, **57** (2025) 102115, <https://doi.org/10.1016/j.ejrh.2024.102115>
- [16] Supharatid, S.: Tidal-level forecasting and filtering by neural network model, *Coastal Engineering Journal*, **45** (2003) 1, 119-137, <https://doi.org/10.1142/S0578563403000695>
- [17] Jung, S.; Cho, H., Kim, J., Lee, G.: Prediction of water level in a tidal river using a deep-learning based LSTM model, *Journal of Korea Water Resources Association*, **51** (2018) 12, 1207-1216, <https://doi.org/10.3741/JKWRA.2018.51.12.1207>
- [18] Gao, S.; Feng, X., Xu, H., Wu, Y., Feng, W.: A hybrid deep learning model based on emd algorithm for non-stationary water level prediction of estuarine systems, *Estuarine, Coastal and Shelf Science*, **314** (2025) 109128, <https://doi.org/10.1016/j.ecss.2025.109128>
- [19] Shi, X.; Chen, P., Ye, Z., Zhang, X., Wang, W.: Tide level prediction during typhoons based on variable topology in graph convolution recurrent neural networks, *Ocean Engineering*, **312** (2024) 119228, <https://doi.org/10.1016/j.oceaneng.2024.119228>
- [20] Cremer, C. J. M.; Mariegaard, J. S., Andersson, H. J.: A hybrid data assimilation and machine learning approach for enhancing operational forecasting in 2D hydrodynamic models, *Journal of Hydroinformatics*, **27** (2025) 3, 493-507, <https://doi.org/10.2166/hydro.2025.289>
- [21] Zhang, Z.; Zhang, L., Yue, S., Wu, J., Guo, F.: Correction of nonstationary tidal prediction using deep-learning neural network models in tidal estuaries and rivers, *Journal of Hydrology*, **62** (2023) 129686, <https://doi.org/10.1016/j.jhydrol.2023.129686>
- [22] Mihel, A. M.; Krvavica, N., Lerga, J.: Regression-based machine learning approaches for estimating discharge from water levels in microtidal rivers, *Journal of Hydrology*, **646** (2025) 132276, <https://doi.org/10.1016/j.jhydrol.2024.132276>
- [23] Krvavica, N.; Ružić, I.: Assessment of sea-level rise impacts on salt-wedge intrusion in idealized and Neretva River Estuary, *Estuarine, Coastal and Shelf Science*, **234** (2020) 106638, <https://doi.org/10.1016/j.ecss.2020.106638>

- [24] Krvavica, N.; Gržić, M. M., Innocenti, S., Matte, P.: Impact of storm surge and power peaking on tidal-fluvial processes in microtidal Neretva River estuary, *Estuarine, Coastal and Shelf Science*, **234** (2025) 109227, <https://doi.org/10.1016/j.ecss.2025.109227>
- [25] Krvavica, N.; Lončar, G., Oskoruš, D., Ružić, I.: A contribution to improving the system of transitional waters' hydrological measurements: Hydraulic and spectral analyses of the Neretva River flow rate, *Dostupan na*: <https://hrcak.srce.hr/274289>, *Pristupljeno*: 2025-12-16
- [26] Lee, M.; Yoo, Y., Joo, H., Kim, K. T., Kim, H. S., Kim, S.: Construction of rating curve at high water level considering rainfall effect in a tidal river, *Journal of Hydrology: Regional Studies*, **37** (2021) 100907, <https://doi.org/10.1016/j.ejrh.2021.100907>
- [27] Krvavica, N.; Kožar, I., Travaš, V., Ožanić, N.: Numerical modelling of two-layer shallow water flow in microtidal salt-wedge estuaries: Finite volume solver and field validation, *Journal of Hydrology and Hydromechanics*, **65** (2017) 1, 49-59, <https://doi.org/10.1515/johh-2016-0039>
- [28] Mihel, A. M.; Krvavica, N., Lerga, J., Oskoruš, D.: Primjena umjetne inteligencije u procjeni hidroloških parametara priobalnih rijeka, 8. *Hrvatska konferencija o vodama*, Biondić, D., Holjević, D., Vizner, M., 205-212, 978-953-7672-29-4, Poreč, Hrvatska, Studeni 2023, HRVATSKE VODE, Zagreb, Hrvatska (2023)
- [29] Dragomiretskiy, K.; Zosso, D.: Variational mode decomposition, *IEEE Transactions on Signal Processing*, **62** (2014) 3, 531-544, <https://doi.org/10.1109/TSP.2013.2288675>
- [30] Rodriguez, J. D. M; Perez, A., Lozano, J. A.: Sensitivity analysis of k-fold cross validation in prediction error estimation, *IEEE transactions on pattern analysis and machine intelligence*, **32** (2009) 3, 569-575, <https://doi.org/10.1109/TPAMI.2009.187>
- [31] Villeneuve, Y.; Sguin, S., Chehri, A.: AI-Based Scheduling Models, Optimization, and Prediction for Hydropower Generation: Opportunities, Issues, and Future Directions, *Energies*, **16** (2023) 8, 3335, <https://doi.org/10.3390/en16083335>
- [32] Mihel, A. M.; Lenac, K., Krvavica, N., Lerga, J.: Discharge Forecasting in Coastal Rivers Using CNN-LSTM Hybrid Approach, *2023 International Symposium ELMAR*, Muštra, M., Vuković, J., Božek, J., 55-60, 979-8-3503-2513-3, Zadar, Hrvatska, Rujan 2023., IEEE, Zadar, Hrvatska (2023)
- [33] Mihel, A. M.; Pečnik, Š., Vrbančić, G., Lerga, J., Krvavica, N.: Employing Feature Engineering for River Stage Forecasting to Improve Hybrid Model Performance, *2024 International Conference on Software, Telecommunications and Computer Networks (SoftCOM)*, Begušić, D., Radić, J., Šarić, M., 1-6, 979-8-3503-5461-4, Bol, Brač, Hrvatska, Rujan 2024., IEEE, Split, Hrvatska (2024)

Zahvala

Ovaj je rad sufinanciran sredstvima Europske unije iz programa NextGenerationEU kroz projekte Sveučilišta u Rijeci pod brojem uniri-mzi-25-1 i uniri-iz-25-86, Hrvatske zaklade za znanost u okviru projekta IP-2022-10-7598 te EU Horizon projekta „INNO2MARE“ broj 101087348.

Umjetna inteligencija u višehazardnom ranom upozoravanju kroz prizmu CRISAFE i AI-Warn projekata

Meho Saša Kovačević¹, Mario Bačić¹

¹Sveučilište u Zagrebu Građevinski fakultet, Kačićeva 26, 10000 Zagreb

Sažetak: Rad prikazuje primjenu umjetne inteligencije u višehazardnim sustavima ranog upozoravanja kroz razvojnu liniju UCPM projekata oVERFLOW, CROSScade, CRISAFE i AI-Warn, koje je koordinirao Sveučilište u Zagrebu Građevinski fakultet. Posebna se pozornost daje projektu CRISAFE, u kojem je razvijen i u praksi provjeren sustav CHEWS za praćenje oborine, vodostaja i vibracija, s jedinstvenim tijekom prikupljanja podataka, prikazom stanja i pravilima upozoravanja. Na toj osnovi AI-Warn uvodi sljedeći korak prema AI-om potpomognutom ranom upozoravanju kroz višesenzorsku fuziju satelitskih mjerenja, UAV snimanja i gusto raspoređene IoT mreže senzora te rano prepoznavanje neuobičajenih pojava i pouzdaniju potporu odlučivanju službama civilne zaštite i upraviteljima infrastrukture u pilot područjima Dubrovnika i Bruxellesa. Time AI-Warn potvrđuje potencijal AI-om potpomognutih višesenzorskih sustava ranog upozoravanja u jačanju klimatske otpornosti europskih regija.

Ključne riječi: umjetna inteligencija, višehazardni sustavi ranog upozoravanja, kritična infrastruktura, civilna zaštita, potpora odlučivanju

1. Uvod

Uslijed klimatskih promjena i sve učestalijih ekstremnih pojava, raste potreba za sustavima ranog upozoravanja koji učinkovito povezuju praćenje stanja na terenu, procjenu ranjivosti i konkretno operativno djelovanje [1-3]. To je od presudne važnosti u kaskadnim scenarijima gdje se različiti hazardi vremenski i prostorno preklapaju, čime se dodatno povećava rizik za građane i kritičnu infrastrukturu [4-6]. U takvim okolnostima puko prikupljanje podataka više nije dovoljno. Ključni prioritet postaje njihova pouzdana obrada i transformacija u jasne, primjenjive informacije koje službama civilne zaštite i upraviteljima infrastrukture omogućuju donošenje pravovremenih i utemeljenih odluka.

Razvojni put, dan u ovom radu, može se jasno pratiti kroz projekte oVERFLOW, CROSScade i CRISAFE te kroz daljnji razvoj prema projektu AI-Warn. Svi projekti su financirani kroz program mehanizma civilne zaštite Europske Unije. Projekti oVERFLOW (engl. *Vulnerability assessment of embankments and bridges exposed to flooding hazards*) i CROSScade (engl. *Cross-border cascading risk management for critical infrastructure in the Sava river Basin*) uspostavili su metodološku osnovu kroz procjenu ranjivosti kritične infrastrukture, analizu kaskadnih višehazardnih scenarija te strukturiranje rizika u obliku pogodnom za operativnu primjenu [7, 8]. Projekt CRISAFE (engl. *Critical infrastructure early warning system and population awareness for multi hazard cascading events*) je tu osnovu dodatno razradio i povezo u cjeloviti višehazardni okvir koji obuhvaća kvantificirane hazardne scenarije, procjenu ranjivosti i kaskadnu procjenu rizika [9-12].

Za prijelaz prema sustavu ranog upozoravanja orijentiranom k umjetnoj inteligenciji (AI) posebno je važan CRISAFE-ov razvijeni CHEWS sustav (engl. *Cascading Multi-Hazard Early Warning System*), jer predstavlja operativni sloj koji povezuje rezultate analize hazarda, ranjivosti i rizika s podacima terenskog monitoringa [11, 12]. Na taj način su analitički rezultati prevedeni u operativne razine upozorenja i postupke korisne za svakodnevni nadzor i reagiranje. U sklopu projekta, na zagrebačkom pilot području razvijen je i primijenjen IoT sustav za praćenje oborine, vodostaja i vibracija, s jedinstvenim tijekom prikupljanja, prijenosa, pohrane i prikaza podataka, jasno definiranom logikom upozorenja te praćenjem pouzdanosti sustava i kvalitete podataka u gotovo stvarnom vremenu [12].

Na toj osnovi projekt AI-Warn (engl. *Holistic AI-driven Early Warning System for Climate-Induced Hazards in Critical Infrastructure and Civil Protection*) predstavlja sljedeći razvojni korak prema primjeni umjetne inteligencije u višehazardnim sustavima ranog upozoravanja. U odnosu na CRISAFE, naglasak se proširuje na višesenzorsku fuziju podataka koja povezuje satelitska opažanja Zemlje, snimanja bespilotnom UAV letjelicom i gusto raspoređene IoT mreže geotehničkih i hidroloških senzora. Takva integracija izravno je povezana s AI konceptom jer stvara podatkovnu osnovu za naprednu analitiku, rano prepoznavanje neuobičajenih pojava i robusniju potporu odlučivanju, uz zadržavanje ekspertnih pravila i lokacijski specifičnih pragova upozorenja kao važnog dijela sustava.

U skladu s navedenim kontinuitetom, cilj ovoga rada je prikazati kako se na iskustvima CHEWS sustava razvija primjena umjetne inteligencije u projektu AI-Warn kao sljedećem metodološkom i operativnom koraku. Poseban naglasak stavlja se na komponente već potvrđene u praksi unutar CRISAFE projekta te na komponente koje projekt AI-Warn uvodi kao nadogradnju, s ciljem unaprjeđenja potpore odlučivanju službama civilne zaštite i upraviteljima infrastrukture u uvjetima klimatski uvjetovanih višehazardnih događaja.

2. Razvojni okvir projekata iz mehanizma civilne zaštite Europske Unije

Razvojni okvir prikazan u ovom radu temelji se na kontinuitetu četiri projekta iz mehanizma civilne zaštite Europske Unije (engl. *Union Civil Protection Mechanism – UCPM*) projekta koje je koordinirao Sveučilište u Zagrebu Građevinski fakultet. Taj kontinuitet nije samo administrativan, nego metodološki i operativan: od procjene ranjivosti pojedinih elemenata infrastrukture, preko procjene kaskadnog višehazardnog rizika, do razvoja sustava ranog upozoravanja i planiranog uvođenja metoda umjetne inteligencije u obradu i interpretaciju podataka.

U projektu oVERFLOW naglasak je bio na poplavno ugroženoj infrastrukturi, osobito na nasipima za obranu od poplava i mostovima, te na razvoju probabilističkog pristupa procjeni ranjivosti [7]. Posebno je važan doprinos razvoja krivulja ranjivosti, kojima se povezuje intenzitet opterećenja s vjerojatnošću oštećenja ili sloma. Uz to, projekt je uključivao i praktične elemente pregleda i praćenja stanja infrastrukture, uključujući terenske i bespilotne metode, čime je postavljen temelj za kasnije povezivanje modela i podataka monitoringa.

Projekt CROSScade proširio je taj okvir s razine pojedinačne infrastrukture na razinu kaskadnog višehazardnog rizika i prekogranične suradnje, s fokusom na sliv rijeke Save [8]. Pri tome se razmatrala osjetljivost nasipa za obranu od poplava i mostova na kaskadne seizmičke i poplavne događaje. Ključna vrijednost CROSScade-a bila je u povezivanju tehničkih analiza s organizacijskim i operativnim potrebama. U projektu su razvijani komunikacijski okviri i akcijski planovi koji povezuju službe civilne zaštite i upravitelje infrastrukture u scenarijima složenih događaja. Time je napravljen važan iskorak od inženjerske procjene prema sustavu koji može poduprijeti stvarno donošenje odluka u kriznim situacijama.

CRISAFE je taj razvojni niz dodatno proširio povezivanjem kvantificiranih scenarija opasnosti, procjene ranjivosti kritične infrastrukture i procjene kaskadnog višehazardnog rizika u jedinstven okvir [9-11]. Posebno je važna primjena Bayes-ovih mreža za procjenu rizika u scenarijima koji uključuju nesigurnosti, nedostatke podataka i uzročno-posljedične veze između više događaja. U tom se okviru povezuju rezultati scenarija opasnosti, podaci o izloženosti i infrastrukturi te rezultati procjene ranjivosti, uz uključivanje ekspertnog znanja gdje je to potrebno. Na taj način je uspostavljen analitički okvir koji je po svojoj prirodi kompatibilan s kasnijim AI pristupima, jer se temelji na integraciji heterogenih izvora podataka i ažuriranju procjena kako novi podaci postaju dostupni.

Za temu ovoga rada posebno je važan CHEWS sustav razvijen u okviru CRISAFE projekta, jer predstavlja operativni sloj koji povezuje monitoring kritične infrastrukture i okolišnih uvjeta s upozorenjima namijenjenima službama civilne zaštite

i upraviteljima infrastrukture [12]. CRISAFE nije ostao samo na razini modeliranja scenarija, ranjivosti i rizika, nego je razvio i praktičan okvir za praćenje i uzbunjivanje u gotovo stvarnom vremenu. To je ključna prijelazna točka prema AI nadogradnji razmatranoj u ovom radu.

o uspostavljenoj osnovi daljnji razvoj usmjerava se prema povezivanju više izvora podataka, uključujući satelitska opažanja Zemlje, UAV snimanja i gusto raspoređene IoT mreže geotehničkih i hidroloških senzora, te prema uvođenju metoda umjetne inteligencije za analizu obrazaca, detekciju anomalija i potporu odlučivanju. Zbog toga CRISAFE predstavlja ključan most prema toj sljedećoj fazi: on daje validiranu osnovu monitoringa, scenarija, ranjivosti i rizika na koju se može nadograditi AI-potpomognuta obrada i interpretacija podataka.

3. Projekt CRISAFE kao potvrđena osnova za AI nadogradnju

3.1. Scenariji kaskadnih opasnosti

U okviru projekta CRISAFE definirani su i kvantificirani scenariji opasnosti za dvije studije slučaja, grad Zagreb i grad Rotterdam, pri čemu opasnosti nisu promatrane izolirano, nego kao mogući sljedovi međusobno povezanih procesa s kaskadnim posljedicama za kritičnu infrastrukturu i okolni prostor. U zagrebačkom slučaju naglasak je bio na intenzivnim oborinama, vodnim valovima i potresnom djelovanju na sustav bujičnih retencija Medvednice, dok je u Rotterdamu naglasak bio na poplavnim scenarijima i mehanizmima koji mogu ugroziti sigurnost nasipa, uključujući statičku likvefakciju i druge oblike gubitka stabilnosti. Tako je uspostavljena kvantificirana scenarijska osnova za daljnje korake procjene ranjivosti i rizika [9].

3.2. Procjena ranjivosti kritične infrastrukture

Na tako definirane i kvantificirane scenarije opasnosti nadovezala se procjena ranjivosti kritične infrastrukture, provedena na reprezentativnim zagrebačkim retencijama i na dionici nasipa u području Rotterdama. U toj su procjeni povezani terenski i geotehnički podaci, numeričko modeliranje i probabilističke analize, pri čemu su kao ključan rezultat dobivene krivulje ranjivosti koje povezuju intenzitet opterećenja s vjerojatnošću oštećenja ili otkaza. Tako je uspostavljena veza između scenarija opasnosti i očekivanog ponašanja infrastrukture, što je bilo nužno za kasnije definiranje rizika i pragova upozorenja [10].

3.3. Procjena kaskadnog višehazardnog rizika

Sljedeći korak bila je procjena kaskadnog višehazardnog rizika, razvijena primjenom Bayes-ovih mreža kao prikladnog okvira za rad u uvjetima nesigurnosti, nedostatka podataka i složenih uzročno-posljedičnih veza između više događaja. U tom se pristupu povezuju scenariji opasnosti, procjena ranjivosti, podaci o izloženosti i ekspertno znanje, čime se rizik ne promatra kao statičan rezultat, nego kao strukturirana i ažurirana procjena. Takav okvir posebno je važan za kasniji razvoj sustava ranog upozoravanja jer omogućuje povezivanje analitičkih rezultata s operativnim pravilima i podacima iz monitoringa [11].

Na taj je način u projektu CRISAFE uspostavljen logičan slijed od scenarija opasnosti, preko procjene ranjivosti i procjene rizika, do osnove za operativno upozoravanje. Na toj se potvrđenoj osnovi u sljedećem poglavlju razmatra CHEWS kao operativni IoT temelj sustava ranog upozoravanja, koji predstavlja izravni most prema AI-Warn-u [12].

3.4. CHEWS kao operativni IoT temelj sustava ranog upozoravanja


3.4.1. Zagrebački pilot projekt i operativni koncept CHEWS-a

Operativna vrijednost projekta CRISAFE najjasnije se očituje u sustavu CHEWS, kojim su rezultati prethodnih analiza prevedeni u praktičan okvir za monitoring i upozoravanje. Pritom CHEWS nije zamišljen samo kao dodatak modelima hazarda, ranjivosti i rizika, nego kao operativni sloj koji omogućuje njihovu primjenu u svakodnevnom nadzoru i upravljanju.

Zagrebački pilot projekt razvijen je na sustavu retencija na južnim padinama Medvednice iznad grada Zagreba, pri čemu su kao reprezentativne lokacije odabrane retencije Črnomerec, Pusti dol i Jazbina (Slika 1). Odabir tih lokacija omogućio je uspostavu pilot sustava na stvarnoj infrastrukturi koja ima jasno definiranu zaštitnu funkciju u obrani od bujičnih poplava te povezivanje modelskih rezultata iz prethodnih projektnih aktivnosti s konkretnim lokacijama na kojima se mogu pratiti okolišni i infrastrukturni pokazatelji relevantni za rano upozoravanje.

U okviru zagrebačkog pilot projekta razvijena su i ugrađena tri međusobno povezana sustava monitoringa: monitoring oborina, monitoring vodostaja i monitoring vibracija odnosno odziva lokacije na potresno djelovanje. Monitoring oborina daje ranu informaciju o mogućem razvoju bujičnih dotoka, monitoring vodostaja omogućuje neposredno praćenje hidrauličkog odgovora sustava, dok monitoring vibracija omogućuje registriranje potresnog događaja i procjenu potrebe za pojačanim naknadnim nadzorom.

Posebna vrijednost CHEWS-a jest u tome što ta tri sustava nisu razvijena kao odvojena tehnička rješenja, nego kao dijelovi jedinstvenog operativnog okvira usmjerenog na rano upozoravanje i potporu odlučivanju [12].



Slika 1: Odabrane lokacije retencija u gradu Zagrebu za uspostavu CHEWS monitoring sustava

3.4.2 Arhitektura sustava, logika upozorenja i rad u gotovo stvarnom vremenu

Sustav CHEWS razvijen je kao jedinstvena i funkcionalno usklađena arhitektura koja povezuje monitoring oborine, vodostaja i vibracija u zajednički tok prikupljanja, prijenosa, pohrane, obrade i prikaza podataka. Polazna točka sustava su terenski senzorski čvorovi koji prikupljaju podatke i organiziraju ih u standardizirane poruke s identitetom uređaja, vremenskom oznakom i osnovnim informacijama o stanju sustava. Na taj način je već na razini izvora podataka osigurana standardizacija nužna za jedinstven rad cijelog sustava i njegovo buduće proširenje.

Prijenos podataka organiziran je tako da senzorski čvorovi šalju poruke prema središnjem komunikacijskom i poslužiteljskom sloju, gdje se podaci zaprimaju, provjeravaju, pohranjuju i pripremaju za daljnju obradu. Središnji dio arhitekture čine postupci prihvata, pohrane i osnovne obrade podataka, pri čemu se podaci iz različitih skupina senzora prevode u jedinstven oblik prikladan za prikaz i logiku upozoravanja. Time

korisnik više ne mora pratiti više nepovezanih aplikacija ili skupova podataka, nego dobiva objedinjeni prikaz stanja na promatranim lokacijama.

Operativna vrijednost sustava proizlazi iz toga što se mjerni podaci prevode u jasnu i ujednačenu logiku upozorenja. U okviru projekta CRISAFE upozorenja su organizirana kroz tri osnovne razine: informacija, upozorenje i alarm. Sustav pritom razlikuje upozorenja vezana uz oborinu, upozorenja vezana uz vodostaj i promjenu vodostaja, upozorenja vezana uz vibracije i seizmički odziv te kombinirana upozorenja. Za svaku skupinu upozorenja definirani su odgovarajući indikatori i pravila aktivacije, pri čemu se sirovi mjerni podaci najprije prevode u stabilnije i operativno razumljivije pokazatelje. Dodatna stabilnost postiže se pravilima postojanosti uvjeta i histereze, čime se sprječava nepouzdana mijenjanje razina upozorenja zbog šuma, kratkotrajnih oscilacija ili pojedinačnih nerealnih skokova u mjerenju.

Takva arhitektura omogućuje rad u gotovo stvarnom vremenu, pri čemu se podaci nakon mjerenja prenose, zaprimaju i prikazuju s dovoljno malim vremenskim odmakom da mogu služiti kao osnova za operativno upozoravanje. Ujedno se kroz isti sustav omogućuje povezivanje više izvora podataka unutar zajedničke logike upozorenja, uključujući i kombinirane višehazardne situacije. U konačnici je pokazano da se na jedinstvenoj operativnoj arhitekturi može graditi daljnja više-izvorna i AI-potpomognuta nadogradnja [12].

3.4.3 Pouzdanost sustava i kvaliteta podataka kao preduvjet AI nadogradnje


Jedna od najvažnijih značajki CHEWS sustava jest to što pouzdanost sustava i kvaliteta podataka nisu promatrane kao sporedno tehničko pitanje, nego kao sastavni dio same logike ranog upozoravanja. Sustav zato jasno razlikuje stanje u kojem nema opasne pojave od stanja u kojem nema pouzdanih podataka ili sustav ne radi ispravno. Upravo zato su uz fizička upozorenja razvijena i operativno-tehnička upozorenja kojima se prati stanje sustava i vjerodostojnost podatkovnog toka.

Pouzdanost sustava promatra se kroz kontinuitet podatkovnog toka, raspoloživost komunikacije, stanje napajanja, vjerodostojnost mjerenja, cjelovitost zapisa i raspoloživost središnjih servisa. To znači da sustav ne prati samo izmjerene vrijednosti, nego i vrijeme od posljednje poruke, razinu napunjenosti baterije, pojavu nerealnih ili zaglavljenih signala, nepravilnosti u vremenskim oznakama i moguće probleme u prijenosu, bazi podataka ili web-prikazu. Posebno su važna upozorenja povezana s prekidom komunikacije i izostankom podataka, kao i osnovna pravila kontrole kvalitete mjerenja, uključujući provjeru raspona vrijednosti, prepoznavanje nerealnih skokova i prepoznavanje zaglavljenih signala.

Operativna važnost takvog pristupa posebno dolazi do izražaja u korisničkom sučelju, gdje se fizička upozorenja i operativno-tehnička upozorenja prikazuju zajedno,

unutar iste operativne slike sustava (Slika 2). Korisnik pritom mora u vrlo kratkom vremenu moći odgovoriti ne samo na pitanje što se događa, nego i na pitanje koliko je prikazano stanje pouzdano. Takva organizacija nije važna samo za svakodnevni rad sustava, nego i za njegovu buduću AI nadogradnju. Umjetna inteligencija može imati stvarnu operativnu vrijednost samo ako se oslanja na podatke čija je pouzdanost poznata i ako sustav može razlikovati stvarnu anomaliju u ponašanju promatranog procesa od anomalije u samom podatkovnom toku [11, 12].

Kroz projekt CRISAFE pokazano je da višehazardni sustav ranog upozoravanja može biti uspostavljen kao operativno upotrebljiv i tehnički pouzdan okvir koji povezuje kvantificirane scenarije, monitoring, logiku upozorenja i podatkovnu pouzdanost u gotovo stvarnom vremenu. Međutim, CRISAFE je pritom ostao pretežno usmjeren na IoT monitoring i na pravila upozorenja utemeljena na unaprijed definiranim indikatorima i pragovima. U sljedećem poglavlju se razmatra kako se ta potvrđena osnova može proširiti prema višesenzorskoj fuziji podataka, AI-potpomožutoj detekciji anomalija i hibridnoj potpori odlučivanju [12].



Slika 2: Web sučelje za praćenje oborina, koje prikazuje inkrementalnu i kumulativnu količinu oborina na primjeru retencije Jazbina

4. Primjena umjetne inteligencije u projektu AI-Warn

4.1. Potreba za AI nadogradnjom višehazardnih sustava ranog upozoravanja

Sustav CHEWS, razvijen u CRISAFE projektu, ostaje pretežno oslonjen na unaprijed definirane indikatore, pragove i pravila odlučivanja, pri čemu je glavna podatkovna osnova vezana uz IoT monitoring. To je posebno učinkovito u jasno definiranom lokalnom okviru, ali ograničenja sustava postaju izraženija kada se želi obuhvatiti veći broj heterogenih izvora podataka, različite prostorne i vremenske skale hazarda te složenije obrasce razvoja opasnih pojava.

Potreba za takvom nadogradnjom posebno dolazi do izražaja u radu s klimatski uvjetovanim opasnostima različitog karaktera, kao što su ekstremne oborinske nestabilnosti, te s njima povezani odroni i klizišta u strmom i geomorfološki složenom prostoru, odnosno urbane poplave u gusto izgrađenom nizinskom okruženju. Takvi slučajevi zahtijevaju sustav koji može objediniti informacije različitog podrijetla, prostorne pokrivenosti i vremenske razlučivosti te ih prevesti u operativno relevantne pokazatelje za službe civilne zaštite i upravitelje infrastrukture.

Dodatni razlog za AI nadogradnju proizlazi iz same prirode podataka koji se u takvim sustavima koriste. Povezivanje satelitskih opažanja Zemlje, UAV snimanja, ugrađenih IoT senzorskih mreža i postojećih baza podataka otvara mogućnost znatno bogatijeg uvida u razvoj opasnih stanja, ali istodobno postavlja zahtjev za prostornim i vremenskim usklađivanjem, čišćenjem, harmonizacijom i zajedničkom interpretacijom podataka. Ta potreba za radom nad velikim brojem heterogenih i međusobno zavisnih podataka čini umjetnu inteligenciju prirodnim sljedećim korakom u razvoju sustava.

Važan razlog za primjenu umjetne inteligencije jest i činjenica da su višehazardni sustavi ranog upozoravanja često podatkovno bogati, ali stvarnim događajima siromašni. Drugim riječima, na raspolaganju je velik broj mjerenja i snimaka, ali je stvarnih opasnih događaja relativno malo, a njihovo označavanje često je nepotpuno ili neujednačeno. U takvim uvjetima klasični pristupi koji se oslanjaju na velike skupove unaprijed označenih primjera imaju ograničenu primjenjivost.

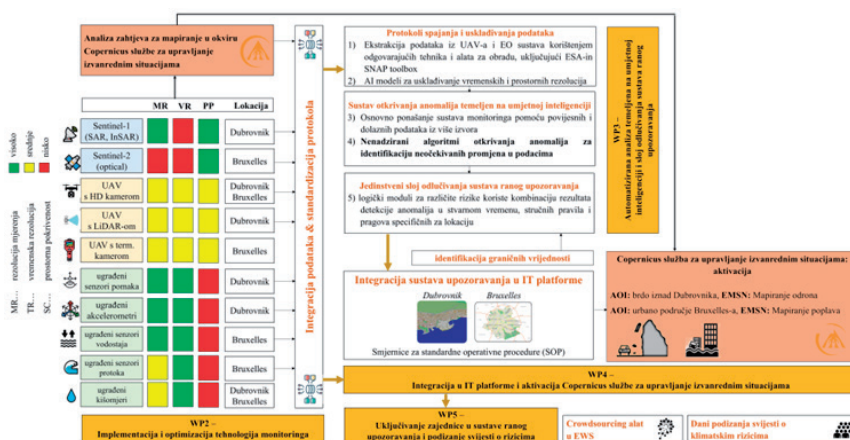
Istodobno, umjetna inteligencija u ovom se radu ne promatra kao zamjena za ekspertna pravila i inženjersko znanje, nego kao njihova nadogradnja. Cilj takvog pristupa nije zamijeniti postojeću logiku sustava ranog upozoravanja, nego povećati njegovu osjetljivost na rane signale, poboljšati povezivanje višeizvornih podataka i ojačati potporu odlučivanju u složenim višehazardnim situacijama.

4.2. Višesenzorska fuzija podataka kao osnova za AI analitiku

Jedna od temeljnih novosti AI nadogradnje u odnosu na CRISAFE jest prijelaz s pretežno IoT usmjerenog sustava na višesenzorsku fuziju podataka. Dok je u CRISAFE-u naglasak bio na povezivanju terenskog monitoringa, pravila upozorenja i procjene pouzdanosti podataka unutar jedinstvene operativne arhitekture, ovdje se taj okvir proširuje uključivanjem satelitskih opažanja Zemlje, UAV snimanja, gusto raspoređenih IoT mreža geotehničkih i hidroloških senzora te postojećih informacijskih sustava relevantnih za upravljanje rizicima.

Takav pristup posebno je važan zato što različiti tipovi opasnosti i različiti prostorni konteksti zahtijevaju i različite tipove podataka. IoT senzori omogućuju kontinuirano lokalno praćenje stanja tla, konstrukcije i hidroloških uvjeta, ali njihova je prostorna pokrivenost ograničena na mjesta ugradnje. Satelitska opažanja Zemlje daju širi prostorni pregled i omogućuju praćenje promjena na razini padina, koridora infrastrukture i urbanih područja, ali s drukčijom vremenskom razlučivošću i drukčijim ograničenjima interpretacije. UAV snimanja pružaju vrlo detaljan lokalni prikaz i mogu popuniti jaz između kontinuiranog terenskog monitoringa i šireg satelitskog promatranja. Zato se pouzdaniji uvid u razvoj opasnih stanja može dobiti tek kada se ti izvori promatraju zajedno, a ne odvojeno.

Višesenzorska fuzija pritom ne znači samo tehničko objedinjavanje različitih nizova podataka u istu bazu. Ona podrazumijeva prostorno i vremensko usklađivanje podataka, njihovu harmonizaciju, čišćenje, provjeru kvalitete i prevođenje u zajednički analitički oblik prikladan za daljnju obradu. Bez takvog koraka umjetna inteligencija ne bi radila na stvarno usporedivim i logično povezanim ulazima, nego na međusobno nepovezanim skupovima podataka ograničene operativne vrijednosti. U tom kontekstu višesenzorska fuzija predstavlja preduvjet, a ne dodatak AI analitici (Slika 3).



Slika 3: Metodološki okvir projekta AI-Warn s višesenzorskom fuzijom podataka, AI analizom i povezivanjem prema sustavu ranog upozoravanja i potpori odlučivanju

4.3. AI-potpomognuta detekcija anomalija i hibridna logika odlučivanja

Nakon uspostave višesenzorske podatkovne osnove sljedeći ključni korak jest razvoj AI-potpomognute detekcije anomalija i njezino povezivanje s logikom odlučivanja u sustavu ranog upozoravanja. Pritom je važno naglasiti da se umjetna inteligencija ne uvodi radi zamjene postojećih pravila upozorenja, nego radi njihove nadogradnje u uvjetima u kojima broj izvora podataka, njihova heterogenost i složenost promatranih procesa nadilaze mogućnosti klasičnog pristupa utemeljenog samo na unaprijed definiranim pragovima.

Posebna vrijednost takvog pristupa jest u tome što je usmjeren na nenadziranu detekciju anomalija. To znači da sustav ne ovisi o velikim skupovima unaprijed označenih opasnih događaja, nego najprije uči uobičajeno ponašanje promatranog sustava na temelju povijesnih i pristiglih podataka, a zatim prepoznaje odstupanja od naučenog obrasca. To je pogodno za višehazardne sustave ranog upozoravanja, jer su stvarni opasni događaji relativno rijetki, a njihova potpuna i pouzdana klasifikacija često nije raspoloživa.

Na taj način umjetna inteligencija ne traži samo prelazak pojedinačnog praga, nego prepoznaje da se sustav ponaša drukčije od očekivanog, što može biti važan rani signal razvoja opasnog stanja. U tome leži njezina glavna operativna vrijednost: uočavanje promjena koje još ne moraju biti vidljive kroz klasična pravila upozorenja, ali mogu upućivati na potrebu pojačanog nadzora ili dodatne provjere.

Međutim, na taj način se ne ostaje na razini izdvojenog AI rezultata, nego podrazumijeva hibridnu logiku odlučivanja u kojoj se AI uvidi kombiniraju s ekspertnim pravilima i lokacijski specifičnim pragovima. Podatkovno vođena analitika se povezuje s fizičkim značenjem opasnosti, ranjivosti infrastrukture i postojećim operativnim pravilima sustava ranog upozoravanja.

4.4. Potpora odlučivanju službama civilne zaštite i upraviteljima infrastrukture

Konačna vrijednost primjene umjetne inteligencije ne očituje se samo u naprednijoj obradi podataka, nego prije svega u kvalitetnijoj potpori odlučivanju službama civilne zaštite i upraviteljima infrastrukture. U sustavima ranog upozoravanja takvi korisnici ne trebaju samo dodatne podatke ili složenije grafove, nego pouzdane i pravodobne informacije koje omogućuju procjenu situacije, određivanje razine pripravnosti i odabir odgovarajućih operativnih postupaka.

Ključna prednost takvog pristupa jest u tome što objedinjeni sustav može povezati višeizvorne podatke, rezultate detekcije anomalija, ekspertna pravila i lokacijski spe-

cifične pragove upozorenja u jedinstvenu operativnu sliku stanja. Ovakvim pristupom korisnicima se ne prenose samo pojedinačni signali ili nepovezani pokazatelji, nego interpretirani rezultati koji upućuju na to razvija li se opasna situacija, koliko je pouzdana takva procjena i zahtijeva li ona pojačani nadzor, dodatnu provjeru ili aktiviranje unaprijed definiranih postupaka.

Za službe civilne zaštite važna je sposobnost sustava da na vrijeme prepozna razvoj situacije i pruži podlogu za procjenu mogućih posljedica i prioriteta djelovanja. Za upravitelje infrastrukture važna je i dodatna razina informacija koja se odnosi na stanje promatranog sustava, potrebu pojačanog nadzora, eventualne znakove degradacije i mogućnost pravodobnog preventivnog djelovanja.

5. Konceptija prijelaza od CHEWS-a sustava do AI-Warn-a

Prijelaz od CHEWS-a sustava do AI-Warn-a može se najjasnije sagledati kroz usporedbu komponenti koje se zadržavaju i onih koje se nadograđuju. AI-Warn ne predstavlja prekid s prethodno razvijenim sustavom, nego njegov metodološki i operativni nastavak prema složenijem višeizvornom i AI-potpomognutom okviru.

5.1. Komponente preuzete iz CHEWS-a

Projekt AI-Warn iz CHEWS-a preuzima logiku povezivanja monitoringa, upozorenja i potpore odlučivanju unutar jedinstvenog digitalnog okvira, kao i na standardizirani tok podataka od senzorskog čvora do baze podataka i operativnog prikaza. Kroz CHEWS je već uspostavljen okvir u kojem monitoring ne služi samo prikazu mjerenja, nego i operativnoj interpretaciji stanja sustava [12].

Iz CHEWS-a se preuzimaju stabilizirana logika upozorenja, povezivanje fizičkih i tehničkih upozorenja te pristup u kojem se podaci uvijek tumače zajedno s procjenom njihove pouzdanosti. Jednako je važna i činjenica da je CRISAFE već uspostavio vezu između scenarija opasnosti, procjene ranjivosti, procjene rizika i operativne logike upozoravanja. Razvijen je okvir u kojem se podaci iz monitoringa ne promatraju izolirano, nego u vezi s prethodno definiranim mehanizmima opterećenja, otkaza i posljedica [9-12].

5.2. Komponente nadograđene u AI-Warn-u

Na tako uspostavljenoj osnovi AI-Warn uvodi tri ključne nadogradnje: višesenzorsku fuziju podataka, AI-potpomognutu detekciju anomalija i objedinjeni sloj potpore od-

lučivanju. U odnosu na CRISAFE, koji je bio pretežno usmjeren na IoT monitoring, pravila upozorenja i operativnu logiku sustava, ovdje se podatkovna osnova proširuje na satelitska opažanja Zemlje, UAV snimanja i druge izvore te se uvodi dodatni analitički sloj za rano prepoznavanje odstupanja.

Pritom se postojeća pravila ne zamjenjuju, nego nadograđuju hibridnim pristupom koji povezuje AI rezultate s ekspertnim pravilima i lokacijski specifičnim pravilima. Ovako se ne mijenja temeljna logika ranog upozoravanja uspostavljena u CRISAFE-u, nego se proširuju podatkovni i analitički kapaciteti sustava. Zadržavaju se potreba za preglednim operativnim prikazom, jasnim pravilima aktivacije upozorenja i stalnim praćenjem pouzdanosti podataka, ali se otvara mogućnost ranijeg prepoznavanja neuobičajenih pojava i boljeg povezivanja višeizvornih informacija.

5.3. Studije slučaja u Dubrovniku i Bruxellesu i operativna primjenjivost

Praktična vrijednost takve nadogradnje posebno dolazi do izražaja u pilot-primjenama u Dubrovniku i Bruxellesu. Te dvije lokacije predstavljaju dva različita klimatski uvjetovana hazardna i operativna konteksta: Dubrovnik, kao strm i geomorfološki složen prostor izložen padinskim nestabilnostima, odronima i klizištima, često potaknutim ekstremnim oborinama, te Bruxelles, kao gusto izgrađeno nizinsko urbano područje osjetljivo na intenzivne oborine i urbane poplave. Izbor tih pilot područja pokazuje da cilj AI nadogradnje nije razvoj sustava za jednu vrstu opasnosti, nego razvoj okvira koji se može prilagoditi različitim uvjetima (Slika 4).



Slika 4: Pilot područja projekta AI-Warn u Dubrovniku i Bruxellesu kao reprezentativni primjeri različitih višehazardnih i operativnih konteksta

U oba slučaja naglasak je na povezivanju monitoringa, procjene ranjivosti, lokacijski specifičnih pragova i sustava potpore odlučivanju u oblik koji je primjenjiv službama civilne zaštite i upraviteljima infrastrukture. Operativna primjenjivost dodatno se pojačava time što se rezultati nastoje uključiti u postojeće informacijske platforme korisnika, umjesto razvoja izdvojenog sustava koji bi djelovao izvan njihovih radnih okruženja. To je značajno zato što povećava vjerojatnost stvarne uporabe sustava u svakodnevnim postupcima praćenja, procjene i reagiranja.

Pilot-primjene u Dubrovniku i Bruxellesu tako pokazuju da prijelaz od CHEWS-a do AI-Warn-a prije svega znači prijelaz od potvrđenog operativnog IoT sustava prema višesenzorskom i AI-potpomognutom okviru prilagođenom različitim hazardnim i operativnim kontekstima. U tome se ujedno vidi i glavna logika ovog rada: umjetna inteligencija ne uvodi se kao izdvojena tehnološka novost, nego kao sljedeći razvojni korak na već potvrđenoj osnovi monitoringa, upozoravanja i potpore odlučivanju.

6. Rasprava

Primjena umjetne inteligencije u višehazardnim sustavima ranog upozoravanja ima svoje opravdanje samo ako se razvija na već strukturiranoj osnovi scenarija opasnosti, procjene ranjivosti, procjene rizika, monitoringa i operativne logike upozoravanja. AI-Warn je važan jer pokušava povezati višeizvorne podatke, rano prepoznavanje odstupanja i potporu odlučivanju bez napuštanja postojećih operativnih pravila.

Glavna mogućnost koja se ovim pristupom otvara jest sposobnost obrade većeg broja heterogenih i međusobno povezanih podataka nego što je to moguće u sustavu koji se oslanja isključivo na fiksne pragove i unaprijed definirana pravila. To je osobito važno u slučajevima kao što su Dubrovnik i Bruxelles, gdje se ne promatra samo jedan dominantan indikator, nego složen skup signala različite prostorne i vremenske razlučivosti. U takvim uvjetima umjetna inteligencija može imati stvarnu vrijednost u ranom prepoznavanju odstupanja, povezivanju više signala u logičnu operativnu sliku te smanjenju opterećenja korisnika količinom podataka koju bi inače morali tumačiti ručno.

Istodobno, postoje i jasna ograničenja. U višehazardnim sustavima ranog upozoravanja najčešće ne postoje veliki i reprezentativni skupovi označenih opasnih događaja na kojima bi se mogli graditi klasični nadzirani modeli. Dodatno, podaci dolaze iz izvora različite kvalitete, različite učestalosti i različite razine interpretabilnosti. Zbog toga je razumno što se ne polazi od ambicije potpune automatizacije odlučivanja, nego od pristupa u kojem umjetna inteligencija služi kao dodatni analitički sloj, a ne kao jedini izvor zaključivanja. Takvo postavljanje umjetne inteligencije kao alata za pojačavanje osjetljivosti sustava, a ne za zamjenu cjelokupne logike upozoravanja, čini se posebno prikladnim za sustave civilne zaštite i upravljanja infrastrukturom. U

tim je sustavima važna ne samo sposobnost ranog otkrivanja odstupanja, nego i transparentnost procjene, mogućnost njezina objašnjenja i povjerenje korisnika u način na koji je upozorenje generirano.

Ključno pitanje nije može li umjetna inteligencija prepoznati anomaliju, nego kako takav rezultat pretvoriti u inženjerski i operativno smislen zaključak. Zbog toga stručno znanje u višehazardnim sustavima ranog upozoravanja ne može biti zamijenjeno, nego mora ostati temelj na koji se AI nadograđuje. U prethodnim poglavljima pokazano je da su scenariji opasnosti, procjena ranjivosti i procjena kaskadnog višehazardnog rizika u CRISAFE-u izgrađeni na geotehničkom, hidrotehničkom i probabilističkom razumijevanju procesa. Bayes-ove mreže dodatno pokazuju da se rizik može modelirati na način koji uključuje i kvantitativne podatke i ekspertno znanje te omogućuje ažuriranje procjena kada se uvedu nova opažanja. To je blisko logici hibridnog pristupa u kojem se podatkovno vođena analitika koristi za rano prepoznavanje odstupanja, ali se rezultati tumače zajedno s ekspertno definiranim pravilima, pragovima i fizičkim razumijevanjem ponašanja infrastrukture i opasnosti.

Hibridni pristup ima dvije važne prednosti. Prvo, povećava robusnost sustava jer smanjuje ovisnost o jednoj vrsti ulaznih podataka ili o jednom analitičkom mehanizmu. Drugo, povećava prihvatljivost sustava za krajnje korisnike, jer se upozorenja i preporuke mogu povezati s poznatim indikatorima, razumljivim pragovima i postojećim operativnim postupcima. To je osobito važno u kontekstu civilne zaštite i upravljanja infrastrukturom, gdje korisnici moraju moći razumjeti zašto je određena razina upozorenja aktivirana i na čemu se takva procjena temelji.

Iz dosadašnje analize proizlazi nekoliko jasnih smjernica za daljnji razvoj. Prvo, validacija AI nadogradnje ne bi smjela biti ograničena samo na točnost AI modula, nego mora obuhvatiti cjelokupni lanac od ulaznih podataka do operativne odluke. To uključuje kvalitetu i pouzdanost podataka, stabilnost višesenzorske fuzije, interpretabilnost anomalijских pokazatelja, dosljednost hibridne logike upozorenja i stvarnu upotrebljivost rezultata u radnim okruženjima službi civilne zaštite i upravitelja infrastrukture.

Drugo, trebalo bi posebno provjeravati kako se sustav ponaša u degradiranim uvjetima, kada su pojedini izvori podataka privremeno nedostupni, jer se u takvim situacijama često testira stvarna operativna vrijednost sustava. Treće, važan dio validacije mora biti i integracija u postojeće platforme korisnika, budući da se stvarna vrijednost sustava ne potvrđuje samo kroz analitičku točnost, nego i kroz njegovu sposobnost da postane dio svakodnevnih operativnih postupaka.

U konačnici, daljnji razvoj treba biti usmjeren na provjeru koliko sustav može pouzdano povezati višeizvorne podatke, rano prepoznati relevantna odstupanja i takve rezultate pretvoriti u operativno upotrebljivu potporu odlučivanju. Tek će cjelovita validacija pokazati stvarnu vrijednost umjetne inteligencije u višehazardnim sustavima ranog upozoravanja.

7. Zaključak

Razvojna linija od projekata oVERFLOW i CROSScade preko CRISAFE-a do AI-Warn-a pokazuje da se primjena umjetne inteligencije u višehazardnim sustavima ranog upozoravanja ne može promatrati izdvojeno od prethodno razvijenih metodoloških i operativnih osnova. U tom je slijedu oVERFLOW uspostavio važan okvir za procjenu ranjivosti infrastrukture, CROSScade proširio pristup prema kaskadnom višehazardnom riziku i operativnoj suradnji, a CRISAFE povezo scenarije opasnosti, procjenu ranjivosti, procjenu rizika i sustav ranog upozoravanja (CHEWS) u jedinstven sustav usmjeren prema upozoravanju i potpori odlučivanju.

CRISAFE je u ovom radu potvrđen kao ključni most prema AI nadogradnji. Razvoj CHEWS-a pokazao je da je moguće uspostaviti operativno upotrebljiv IoT sustav monitoringa i upozoravanja u gotovo stvarnom vremenu, s jasno definiranim logikom upozorenja, kombiniranim pravilima, praćenjem pouzdanosti sustava i kontrolom kvalitete podataka. Time je stvorena potvrđena digitalna i operativna osnova na koju se može nadograditi složeniji višeizvorni sustav ranog upozoravanja.

Na toj osnovi AI-Warn predstavlja sljedeći razvojni korak kroz višesenzorsku fuziju satelitskih opažanja Zemlje, UAV snimanja, IoT mreža i drugih raspoloživih izvora podataka, uz AI-potpomognutu detekciju anomalija i hibridnu logiku odlučivanja. Glavna vrijednost takvog pristupa nije u zamjeni postojećih inženjerskih i ekspertnih pravila, nego u njihovoj nadogradnji dodatnim slojem analitike koji omogućuje ranije prepoznavanje neuobičajenih pojava, bolje povezivanje heterogenih izvora podataka i pouzdaniju potporu odlučivanju službama civilne zaštite i upraviteljima infrastrukture.

Zaključno, najveća vrijednost AI-Warn-a jest u tome što primjenu umjetne inteligencije razvija na već potvrđenoj osnovi scenarija opasnosti, procjene ranjivosti, procjene rizika, monitoringa i operativne logike upozoravanja. Umjetna inteligencija u višehazardnim sustavima ranog upozoravanja pokazuje se ne kao samostalna tehnološka inovacija, nego kao logično utemeljen i operativno usmjeren sljedeći korak prema jačanju klimatske otpornosti europskih regija.

Zahvala

Ovo je istraživanje financirano od strane Mehanizma civilne zaštite Europske unije, u okviru poziva UCPM-2025-KAPP-PVPP, Grant Agreement 101254083, AI-Warn projekt (Holistic AI-driven Early Warning System for Climate-Induced Hazards in Critical Infrastructure and Civil Protection).

8. Literatura

- [1] Basher, R.: Global early warning systems for natural hazards: systematic and people-centred, *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, **364** (2006) 1845, 2167-2182, <https://doi.org/10.1098/rsta.2006.1819>
- [2] WMO: *Multi-hazard Early Warning Systems: A Checklist*, World Meteorological Organization, Geneva, 2018.
- [3] UNISDR: *Developing Early Warning Systems: A Checklist*, Third International Conference on Early Warning (EWC III), Bonn, 2006.
- [4] Kappes, M. S.; Keiler, M., von Elverfeldt, K., Glade, T.: Challenges of analyzing multi-hazard risk: a review, *Natural Hazards*, **64** (2012) 2, 1925-1958, <https://doi.org/10.1007/s11069-012-0294-2>.
- [5] Pescaroli, G.; Alexander, D.: Critical infrastructure, panarchies and the vulnerability paths of cascading disasters, *Natural Hazards*, **82** (2016) 1, 175-192, <https://doi.org/10.1007/s11069-016-2186-3>
- [6] Rinaldi, S. M.; Peerenboom, J. P., Kelly, T. K.: Identifying, understanding, and analyzing critical infrastructure interdependencies, *IEEE Control Systems Magazine*, **21** (2001) 6, 11-25, <https://doi.org/10.1109/37.969131>.
- [7] Bačić, M.; Kovačević, M. S., Jurić Kačunić, D., Librić, L., Car, M., Gavin, K., Stipanović, I., Reale, C.: Classification of a flood protection infrastructure based on its vulnerability to various loads: example of the oVERFLOW project, u: *Proceedings of the 7th International Conference on Road and Rail Infrastructure*, Pula, 11-13 May 2022, str. 611-618, <https://doi.org/10.5592/CO/cetra.2022.1471>.
- [8] Skarić Palić, S.; Stipanović, I., Ganić, E.: *CROSScade Deliverable 4.1: Risk assessment methodology for cross-border cascading hazard scenarios*, 2023.
- [9] Rossi, N.; Bačić, M., Gavin, K., Kovačević, M. S.: *CRISAFE Deliverable 2.1: Current and future cascading multi-hazard scenarios*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.
- [10] Gavin, K.; Reale, C., Rossi, N., Bačić, M., Kovačević, M. S.: *CRISAFE Deliverable 2.2: Vulnerability Assessment of the Critical Infrastructure Subjected to Multi-Hazards*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.
- [11] Pekćec, M.; Stipanović, I.: *CRISAFE Deliverable 3.1: Cascading multi-hazard risk assessment methodology*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.
- [12] Kovačević, M. S.; Bačić, M.: *CRISAFE Deliverable 4.2: Report on the sensors and monitoring of the CHEWS alerts*, UCPM-2023-KAPP, Grant Agreement No. 101140336, 2025.

Primjena umjetne inteligencije u grafičkoj tehnologiji

Zdenka Bolanča¹, Ivana Bolanča Mirković^{1,2}

¹Akademija tehničkih znanosti Hrvatske, Kačićeva 28, 10000 Zagreb

²Sveučilište u Zagrebu Grafički fakultet, Getaldićeva 2, 10000 Zagreb

Sažetak: U radu se diskutira primjena umjetne inteligencije (UI) u konvencionalnom i digitalnom tisku kroz radni proces, pripremu tiska, tisak, doradu i kontrolu kvalitete. UI tehnologije koje se koriste u toj domeni su: algoritmi, neuronske mreže, računalni vid, generativni modeli i prediktivna analitika. Značajna područja primjene umjetne inteligencije u grafičkoj tehnologiji su: obrada i priprema slike, DTP i automatizacija pripreme za tisak, upravljanje bojom i kontrola kvalitete, automatizacija proizvodnje i optimizacija procesa, te personalizirani tisak. Može se zaključiti da se s obzirom na razvoj tehnologija očekuju pozitivni trendovi u domeni grafičke tehnologije i umjetne inteligencije u području ambalaže, razvoju hibridnih sustava i održivosti, jer umjetna inteligencija pomaže smanjenju otpada, optimizaciji materijala i energetske resursa.

Ključne riječi: umjetna inteligencija, grafička tehnologija, UI tehnologije, inovacija

1. Uvod

Prema ISO/IEC standardu umjetna inteligencija (UI) je sposobnost sustava da za zadane ciljeve donosi predviđanja, preporuke i odluke [1]. Praktična primjena UI definira se kao sustav koji simulira kognitivne procese, učenje i zaključivanje, omogućujući automatizaciju, poboljšanje specifičnih procesa i operativnu učinkovitost. Sustavi uče iz podataka, a dobiveni rezultat je u obliku predviđanja, preporuke ili odluke.

Umjetna inteligencija predstavlja jedno od ključnih područja suvremene informacijsko-komunikacijske tehnologije i računalnih znanosti. U znanstvenoj se literaturi najčešće definira kao područje koje se bavi razvojem računalnih sustava sposobnih za izvođenje zadataka koji uobičajeno zahtijevaju ljudsku inteligenciju, uključujući percepciju, učenje, zaključivanje, donošenje odluka i rješavanje problema. Prema Russellu i Norvigu, umjetna inteligencija obuhvaća sustave koji mogu razmišljati i djelovati racionalno na temelju dostupnih informacija iz okoline [2].

Suvremeni autori dodatno naglašavaju da umjetna inteligencija nije samo tehnički fenomen, već i sociotehnički sustav ugrađen u organizacijski i društveni kontekst. UI se danas promatra kao skup algoritamskih, podatkovnih i računalnih struktura koje omogućuju automatizaciju kognitivnih funkcija u realnim uvjetima, pri čemu njezina vrijednost proizlazi iz praktične primjene i interakcije s ljudskim korisnicima [3, 4]. U tom kontekstu, umjetna inteligencija se definira kao temeljna tehnologija digitalne transformacije, s potencijalom velikog utjecaja na gospodarstvo, društvo i način rada organizacija.

Primjena UI sustava danas je prisutna u gotovo svim sektorima društva, uključujući industriju, zdravstvo, financije, obrazovanje, logistiku, marketing i javnu upravu. U domeni industrije UI omogućuje prediktivno održavanje, optimizaciju proizvodnih procesa u realnom vremenu, autonomno upravljanje procesima, analizu velikog skupa podataka [5].

U energetsom sektoru izazovi su dekarbonizacija i digitalizacija, a bitne stavke su rješavanje problematike vezane uz klimatske promjene u kombinaciji sve većom složenosti modernih energetskih sustava što zahtijeva inovativne pristupe [6]. Umjetna inteligencija se može koristiti u ovoj domeni putem napredne analize podataka, autonomnog donošenja odluka i prediktivnog modeliranja. Zhang i Štrbac ističu prednost UI u području optimizacije upravljanja energijom, koordiniranog rada distributivnih resursa i jačanja otpornosti sustava na poremećaje i vanjske uvjete, te smanjenje operativnih troškova [7]. Ovakve primjene pokazuju kako UI osim što rješava tehničke izazove omogućuje nove načine upravljanja resursima s ciljem povećanja pouzdanosti, održivosti i učinkovitosti tehnološkog sustava, smanjuje operativne troškove i povećava autonomiju sustava u realnom vremenu.

Osim navedenog, umjetna inteligencija nudi transformacijski potencijal primjenljiv od tehnološke implementacije do primjena u industriji i društvu kako slijedi: tehnologija, zdravstvo, astronomija, obrazovanje, robotika, transport, automobili, ekonomija, trgovina, sigurnost podataka, zabava i igre [8-15].

Metode umjetne inteligencije su višebrojne. Strojno učenje predstavlja temeljnu metodološku osnovu suvremene UI [16]. Obrada velikih skupova podataka omogućuje UI sustavima ekstrakciju znanja iz strukturiranih i nestrukturiranih izvora, a ključna je za donošenje odluka u složenim digitalnim okruženjima [17, 18]. Integracija UI s robotikom omogućuje razvoj autonomnih robotskih sustava koji mogu percipirati okolinu, planirati akcije i samostalno izvršavati zadatke, a ključna uloga je u industriji 5.0, pametnim tvornicama i logistici [19]. Strojni vid (engl. *machine vision*) omogućuje računalima analizu i interpretaciju vizualnih podataka iz slika i videozapisa, a jedna od primjena uključuje autonomna vozila [20]. Neuronske mreže, osobito one duboke, omogućuju modeliranje kompleksnih nelinearnih odnosa u podacima i temelj su suvremenih aplikacija [21].

Razvoj UI obilježen je inovacijama u algoritmima, računalnoj arhitekturi i dostupnosti podataka. Napredak u grafičkim procesima, računalstvu u oblaku i jezičnim modelima doveo je do eksponencijalnog rasta sposobnosti UI sustava [4]. Umjetna inteligencija se sve više razvija kao generička tehnologija opće namjene s dugoročnim transformacijskim učinkom na društvo [22].

Umjetna inteligencija omogućuje nove poslovne modele temeljene na automatizaciji procesa, personalizaciji usluga i podatkovnoj ekonomiji. U kontekstu održivog razvoja UI doprinosi optimizaciji potrošnje resursa, energetske učinkovitosti i pametnom upravljanju sustavima [23].

Organizacije koriste UI za postizanje konkurentske prednosti kroz inovacije i digitalnu transformaciju.

Prihvatanje UI ovisi o percepciji korisne vrijednosti, jednostavnosti uporabe, povjerenju u sustav, transparentnosti algoritama i etičkim aspektima. Empirijska istraživanja pokazuju da organizacije češće prihvaćaju UI kada postoji jasna poslovna korist, regulatorna podrška i dostupnost stručnih znanja [24].

U digitalnom dobu UI postaje strateški resurs. Organizacije je koriste za unapređenje donošenja odluka, digitalnu transformaciju, automatizaciju poslovnih procesa, razvoj inteligentnih digitalnih platformi.

Umjetna inteligencija se promatra kao ključni element dugoročne organizacijske strategije i izvor održive konkurentske prednosti [24].

Umjetna inteligencija ima ključnu ulogu u postizanju ciljeva održivog razvoja, jer omogućuje učinkovitije upravljanje resursima, optimizaciju energetske sustava te smanjuje negativnog utjecaja na okoliš. U znanstvenoj literaturi UI se prepoznaje kao snažan alat za podršku održivosti kroz pametno upravljanje energijom, optimizaciju logističkih lanaca, prediktivnim održavanjem i smanjenjem otpada [25]. Primjena UI omogućuje modeliranje kompleksnih sustava i simulaciju scenarija održivog razvoja, što olakšava donošenje strateških odluka u području zaštite okoliša, pametnih gradova i kružne ekonomije [26]. Studije pokazuju da UI može pozitivno utjecati na čak 79 % ciljeva održivog razvoja Ujedinjenih naroda, posebice u područjima: energetske učinkovitosti, industrijske inovacije i odgovorne potrošnje [26]. S druge pak strane, znanstveni radovi upozoravaju da sama umjetna inteligencija mora biti razvijena i implementirana na održiv način, uzimajući u obzir energetske potrošnje podatkovnih centara, etičke aspekte i društveni utjecaj automatizacije [27, 28].

Inteligentna proizvodnja predstavlja koncept proizvodnih sustava koji integriraju umjetnu inteligenciju, internet stvari (IoT), analitiku podataka i kibernetičko-fizičke sustave radi postizanja visoke razine autonomije, fleksibilnosti i optimizacije procesa. Ključna prednost inteligentne proizvodnje je sposobnost sustava da u realnom

vremenu prikuplja, analizira i koristi podatke za kontinuirano poboljšanje performansi [6, 28]. Prednosti inteligentne proizvodnje uključuju: povećanje produktivnosti, smanjenje troškova, poboljšanje kvalitete proizvoda, te veću prilagodljivost tržišnim promjenama. Umjetna inteligencija omogućuje prediktivno održavanje, čime se smanjuju zastoji u proizvodnji i produžuje životni vijek opreme [29]. Nadalje, inteligentni sustavi omogućuju personaliziranu proizvodnju i masovnu prilagodbu proizvoda uz zadržavanje visoke učinkovitosti [30]. U kontekstu održivosti, inteligentna proizvodnja doprinosi racionalnoj upotrebi energije i materijala, smanjenju otpada, te integraciji obnovljivih izvora energije u proizvodne procese [31].

Industrija 5.0 predstavlja nadogradnju koncepta Industrije 4.0, te stavlja naglasak na suradnju između ljudi i inteligentnih strojeva, održivosti i društvene vrijednosti tehnologije [32]. Dok je Industrija 4.0 bila primarno usmjerena na automatizaciju i digitalizaciju proizvodnje, Industrija 5.0 promiče humanocentričan pristup u kojem tehnologija služi poboljšanju kvalitete rada i dobrobiti zaposlenika [32, 33]. U okviru Industrije 5.0 UI se koristi kao potpora ljudskom odlučivanju, koristeći kolaborativne robote, prilagodljive proizvodne sustave i pametne radne okoline. Cilj nije zamjena čovjeka strojem, već stvaranje sinergije između kreativnosti i strojne inteligencije [34, 35]. Znanstveni radovi ističu da Industrija 5.0 integrira tri temeljna načela: humanocentričnost, otpornost i održivost [36]. Umjetna inteligencija u tom kontekstu omogućuje ne samo tehnološku učinkovitost, već i društveno odgovornu industrijsku transformaciju [36].

2. Primjena umjetne inteligencije u tiskarskoj industriji

Umjetna inteligencija sve više postaje ključna tehnologija u transformaciji tiskarske industrije. U tom kontekstu bitna je identifikacija: primarne primjene UI u planiranju i kontroli proizvodnje (PPG), upravljanje kvalitetom (QM), upravljanje održavanjem (MM) i upravljanje lancem opskrbe (SCM) [37]. Primjena UI u planiranju i kontroli proizvoda koristi se za optimizaciju raspoređivanja i alokacije resursa, poboljšavajući učinkovitost proizvodnje. Salvin prikazuje primjenu UI u upravljanju opskrbnim lancem, što je često zanemaren aspekt tiskarske industrije [38]. Ovaj rad je posebno važan, jer pokazuje kako se UI koristi za: prognoziranje potražnje, optimizaciju zaliha i planiranje nabave sirovina. U tiskarstvu to izravno znači racionalnije upravljanje, papirom, bojama i potrošnim materijalom, što ima i ekonomske i ekološke implikacije.

Lin prikazuje teorijsku osnovu za razumijevanje primjene UI u proizvodnji, odnosno integracije UI u industrijsko inženjerstvo [39]. Iako nije specifično vezan uz tiskarstvo, rad je sadržajno zaslužan za razumijevanje transfera teoretskih modela iz opće proizvodnje u grafičku industriju.

U domeni upravljanja kvalitetom, često se koristi temeljni referentni okvir, jer sustavno obrađuje prediktivno održavanje, optimizaciju proizvodnih procesa i uprav-

ljanje kvalitetom, strojno učenje i računalni vid (engl. *computer vision*) otkrivaju nedostatke i optimiziranje zastoja, osiguravajući učinkovit rad strojeva. Prediktivno održavanje, jedno je od značajnih područja primjene UI u industriji, što je sadržaj rada Masoda i Zakaria [40]. Autori pokazuju kako se neuronske mreže i regresijski modeli koriste za predviđanje kvarova strojeva na temelju senzorskih podataka. Rad Wanga i Zhanga je izravno fokusiran na tiskarsku industrijsku u kontekstu pametne proizvodnje [41]. Autori analiziraju kako se algoritmi strojnog učenja mogu koristiti za optimizaciju parametara tiska, smanjenje otpada i automatizaciju odlučivanja u realnom vremenu. Navedeni rad posebno je relevantan jer povezuje primjenu umjetne inteligencije s pojmovima kao što su digitalni blizanac, kiber-fizički sustavi i Industrija 4.0. Digitalni blizanac (engl. *digital twin*) omogućuje simulaciju ponašanja tiskarskog stroja u virtualnom okružju, čime se unaprijed mogu predvidjeti kvarovi i optimizirati parametri procesa. Kiber-fizički sustavi predstavljaju integraciju fizičkih procesa, senzora i softverskih algoritama koji omogućuju autonomno upravljanje proizvodnim sustavima. Shah analizira kako digitalne tehnologije, uključujući UI mijenjaju organizaciju rada u tiskarama [42]. Poseban doprinos rada je povezivanje teorije i prakse u grafičkoj proizvodnji.

Prikazane postavke sugeriraju da je umjetna inteligencija obećavajuća, njezina korist ovisi o prevladavanju značajnih izazova implementacije. S obzirom da se tvrtke suočavaju s rastućom konkurencijom i promjenljivim zahtjevima potrošača, usvajanje umjetne inteligencije u tiskarskom sektoru postaje nužnost.

2.1 Primjena umjetne inteligencije u konvencionalnim tehnikama tiska

Ofsetni tisak je danas u hrvatskoj grafičkoj industriji najzastupljenija tehnika tiska. U toj tehnici se proizvode reprezentativni grafički proizvodi. Razlog tome su: visoko kvalitetna konstrukcija strojeva, jednostavan pripremni proces i kvalitetan otisak relativno niske proizvodne cijene. Primjenljivost ove tehnike je u segmentu komercijalnog i ambalažnog tiska. Zbog složenosti parametara procesa, varijabilnosti materijala i potrebe za stabilnom kvalitetom, ofsetni proces još uvijek ovisi o iskustvu operatera i ručnoj kontroli. Značajne varijable su: postavke valjaka, brzina tiska, tlak, parametri vezani uz boje. Upravo u tom segmentu primjena UI može značajno unaprijediti performanse i doprinijeti konkurentnosti proizvodnje.

Jedna od najvažnijih primjena umjetne inteligencije u ofsetom tisku je smanjenje varijacija u kvaliteti otisaka i poboljšanje stabilnosti procesa. Bratić i suradnici razvili su model koji integrira slučajnu šumu engl. *random forest* s metodologijom Six Sigma za identifikaciju kritičnih varijabli procesa i predviđanje odstupanja u kvaliteti otiska uključujući boje, gustoću obojenja i oštrinu [43]. Model slučajne šume primijenjen je za predviđanje odstupanja otiska na temelju ulaznih parametara procesa, čime se omogućuje automatizirana identifikacija kritičkih varijabli. Taj pristup omo-

gućuje prilagodbu parametara i smanjenje varijabilnosti proizvodnje. Rečeno kombinira statističke metode s UI modelima kako bi se dobila objektivna i automatizirana kontrola procesa umjesto tradicionalno subjektivne kontrole operatora.

Tema rada Masod i Masoda i Zakaria je također u području automatizacije kontrole kvalitete ofsetnih otisaka [44]. Primjena algoritama računalnog vida i strojnog učenja omogućuje automatsko otkrivanje vizualnih defekata, kao što su nepravilnosti u registraciji boja, mrlje, pojave linija ili nepravilni otisak. Takvi sustavi mogu u realnom vremenu ocjenjivati tisuće otisaka i signalizirati potrebu za korekcijom procesa, što smanjuje otpad i povećava kvalitetu. Specifični UI modeli za ofsetni tisak još su u razvoju, a opći trendovi u industrijskim primjenama. UI ukazuje na povećanu primjenu takvih sustava u QM unutar tiskarskih postrojenja. Za ofsetne strojeve sve je prisutniji koncept integracije digitalnih blizanaca, virtualnog modela stroja u realnom vremenu [45]. Dakle, Sharma prikazuje tiskarsku proizvodnju na principu Industrije 4.0, što znači prijelaz od analognih procesa na automatizirane i prediktivne sustave [45]. Korištenjem podataka u stvarnom vremenu te integracijom digitalnih blizanaca, prediktivne analitike i vizualizacijskih alata omogućuje se učinkovito upravljanje složenim tijekovima rada, uključujući postavljanje ploča, uvlačenje tiskovne podloge, kontrolu viskoznosti boje, automatizirano usklađivanje boje i otkrivanje nedostataka.

Primjena umjetne inteligencije u ofsetnom tisku kroz optimizaciju procesa, integraciju digitalnih blizanaca, automatiziranu kontrolu kvalitete, prediktivno održavanje, omogućuje ne samo poboljšanje kvalitete otiska, već i poboljšanje učinkovitosti, stabilnosti i konkurentnosti, pa je za očekivati širu primjenu u budućnosti.

Koncept digitalnog blizanca ofsetnog tiskarskog stroja Heidelberg Speedmaster XL 106 sastoji se od povezivanja fizičkog proizvodnog sustava s njegovim virtualnim modelom putem kontinuirane razmjene podataka u realnom vremenu, radi analize, simulacije i optimizacije tiskarskog procesa [46]. Digitalni blizanac koristi prikupljene podatke za predviđanje ponašanja sustava, optimizaciju parametara tiska i podršku odlučivanju u upravljanju proizvodnim procesom. Digitalni blizanac integrira se s višim razinama informacijskih sustava, čime se omogućuje povezivanje operativnih podataka s poslovnim i upravljačkim funkcijama, u skladu s konceptom pametne proizvodnje.

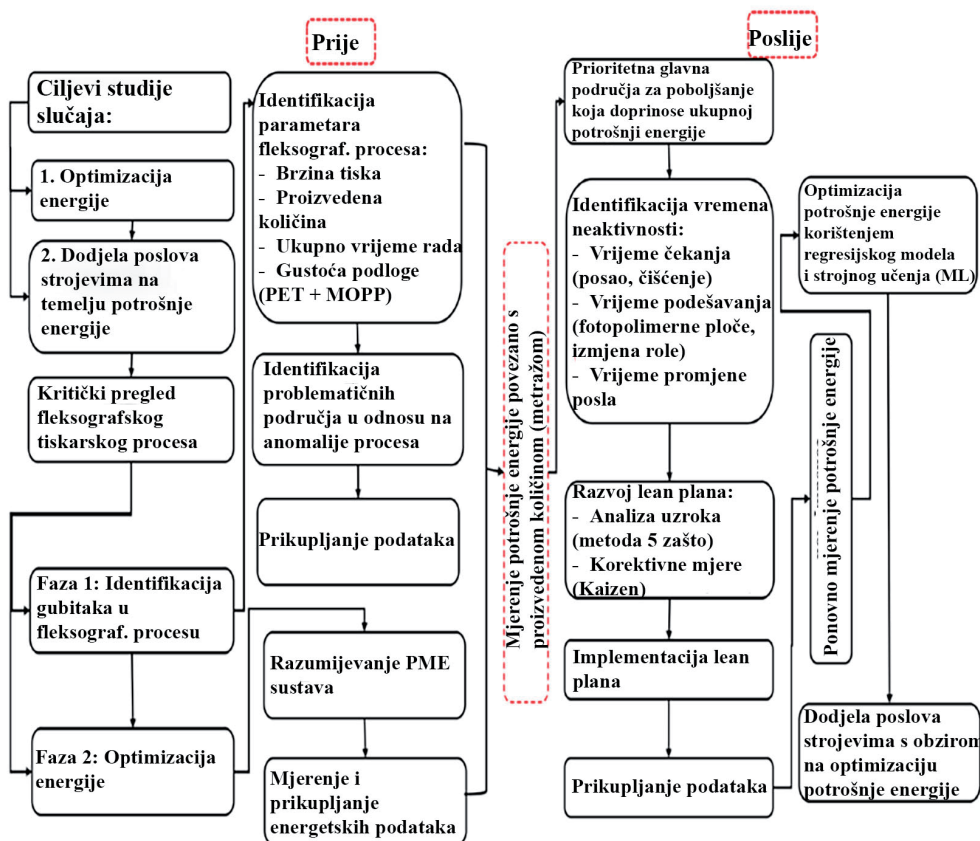
Može se zaključiti da primjena umjetne inteligencije u ofsetnom tisku predstavlja evoluciju konvencionalne grafičke proizvodnje prema automatiziranim, inteligentnim i podatkovno vođenim sustavima. Pomoću integracije digitalnih blizanaca, optimizacije procesa, automatizirane kontrole kvalitete i prediktivnog održavanje, umjetna inteligencija omogućuje poboljšanje kvalitete tiska, povećanje učinkovitosti, stabilnost i konkurentnost. S obzirom da je prepoznatljivo sve uspješnije integriranje UI modela u realne ofsetne procese, očekuje se još šira primjena u budućnosti grafičke industrije.

Bakrotisak je kvalitetna ali tehnološki zahtjevna konvencionalna tehnika tiska. Temelji se na prijenosu boje iz udubljenih tiskovnih elemenata na tiskovnu podlogu, pri čemu ključnu ulogu imaju gravirani cilindri, viskozitet boje, tlak, brzina tiska i sustav za sušenje. Zbog izrazite osjetljivosti procesa tiska na promjene parametara, proces bakrotiska zahtijeva visoku razinu kontrole i stručnosti operatera [47]. Opisana složenost čini bakrotisak pogodnim područjem za primjenu umjetne inteligencije. Posebno treba istaknuti segmente automatizacije, optimizacije procesa, prediktivnog održavanja i kontrole kvalitete.

Jedan od trendova u bakrotisku je primjena umjetne inteligencije za kontrolu kvalitete graviranih cilindara, koji su ključni elementi u dubokom tisku [47]. Tvrtka 4Packaging GmbH, Njemačka koristi umjetne neuronske mreže za analizu podataka senzora koji dolaze od originalnih senzora na stroju i senzora koji su instalirani u kemijskim galvanizacijskim kupkama [48]. Sustavi temeljeni na računalnom vidu i UI analizi slika automatski detektiraju defekte na cilindrima i klasificiraju tip pogreške. Računalni vid pregledava slike i cilindre klasificira u odnosu na vrstu i mjesto nedostatka. Implementacija ovih tehnologija zahtijeva velike količine podataka, kao i kategorije koje su dodijeljene skupu podataka. Primjenom UI modula za nadziranje proizvodnje, smanjuje se broj nepravilnosti i deformacija cilindara za oko 20%, te se postiže značajna ušteda materijala i energije [49]. Osim toga korištenjem neuronskih mreža i računalnog vida postignut je doprinos u domeni održivosti. U području analize podataka senzora smanjen je ugljični otisak za 8-12 tona CO₂, a materijalni otisak za 26-73 tona CO₂ [49]. Schmidt i suradnici željeli su dokazati mogućnost, da je opća sustavna strategija poboljšanja kvalitete i smanjenja otpada moguća korištenjem metode dubokog učenja (DL) i DL algoritama s naglaskom na bakrotisak [50]. Strategija poboljšanja je razrađena u šest koraka, kako slijedi [50]. Prvi korak je sustav vizualnog pregleda nakon bakrenja, što daje informaciju li sustav nedostatke, a podaci se koriste za DL. Drugi korak je bilježenje podataka s korištenih strojeva za bakrenje. Podaci ulaze u DL sustav. DL sustav dobiva podatke vidljivosti procesa bakrenja i zna se koji parametri imaju najveći utjecaj na pojavu nedostataka. U četvrtoj fazi moguće je koristiti podatke, što dalje omogućuje transparentnost i identificirati zašto su se pojavili nedostaci. Integriranjem prognoze poduzimaju se preventivne protu mjere. Ovi koraci se ponavljaju dok se ne postigne potpuna automatizacija kontrole. Brumm i suradnici koriste metodu dubokog učenja za fenomenološku klasifikaciju formiranja uzoraka pri cijepanju fluida u bakro tiskarskom stroju [51]. DL algoritmi koriste se brze video snimke procesa cijepanja fluida između rotirajućeg graviranog cilindra i ciljane podloge koja se pomiče. U radu se diskutira kako se uzorci klasificiraju DL metodama i kako bi to moglo poslužiti za identifikaciju različitih hidrodinamičkih režima. Moglo bi se zaključiti da postoje jasni pokazatelji da se UI, algoritmi strojnog učenja, automatizacija i inovativna proizvodnja u bakrotisku brzo kroz: integraciju UI proizvodne linije za graviranje cilindra, automatiziranu kontrolu kvalitete, kontrolu proizvodnih čimbenika u realnom vremenu i digitalizaciju bakrotiska značajni u tisku ambalaže.

Fleksografski tisak je tehnika tiska koja se široko koristi za tisak ambalaže zbog sposobnosti ispisa na različite materijale uz visoke brzine i relativno niske cijene po jedinici proizvoda. Zbog kompleksne dinamike tiska, pogodan je za primjenu umjetne inteligencije. Chen je prikazao kako se prikupljaju, analiziraju i modeliraju podaci i kako ih se može svakodnevno primijeniti u domeni fleksografskog tiska [52]. Predlaže analizu podataka tiska u fazama kako slijedi: izrada plana proizvodnje, povećanje proizvodnje u stvarnom vremenu, kontinuirana optimizacija proizvodnje i proizvodnja u okviru koncepta Industrije 5.0 uz provođenje prediktivnog održavanja [52]. Basak i Maity su svoja istraživanja usmjerili na integriranje strojnog učenja na mogućnost procjene kvalitete fleksografskog otiska [53]. Analizu podataka i primjenu performansi proveli su korištenjem linearne regresije, stabla odlučivanja (engl. *decision tree*) i algoritma regresije slučajne šume. Algoritam stabla odlučivanja korišten je za modeliranje odnosa između procesnih parametara fleksografskog tiska, kao što su tiskovna podloga, pritisak stroja i svojstva boje te neželjenog prirasta rastertonske vrijednosti (engl. *dot gain*). Poznato je da je jedan od ciljeva grafičke tehnologije postizanje reprodukcije što sličnije originalu, to znači da je uspješno smanjenje prirasta rastertonskih vrijednosti jedan od preduvjeta postizanja kvalitetne reprodukcije. Svaka tiskara treba postići uvjete u kojima će pojava prirasta rastertonskih vrijednosti biti standardizirana na što manje tolerancije, jer prirast u realnoj grafičkoj proizvodnji nije moguće izbjeći.

Optimizacija energije ključna je za smanjenje troškova, povećanje učinkovitosti i minimiziranje utjecaja na okoliš. Za utvrđivanje potroška energije u proizvodnom procesu mogu se koristiti sustavi za praćenje energije, koji pružaju podatke o potrošnji energije u stvarnom vremenu, omogućujući identificiranje područja s visokom potrošnjom. Utvrđeno je da su glavni uzroci potrošnje energije duga razdoblja neaktivnosti stroja i loša raspodjela poslova [54]. Za optimizaciju performansi fleksografskih tiskarskih strojeva korišten je model linearne regresije koji koristi tehnike strojnog učenja i niza ulaznih čimbenika, kako bi predvidjeli potrošnju energije i optimiziral raspoređivanje poslova, što može rezultirati smanjenjem troškova, a u konačnici i uštedom energije.




Slika 1: Dijagram toka metodologije korištene za optimizaciju potrošnje energije u procesu fleksografskog tiska [54]

Studija je pokazala da je lean tehnologija učinkovita za identifikaciju kritičnih područja i poboljšanje korištenja energije u procesu fleksotiska, s uštedom nešto više od 30 % (Slika 1) [54].

Sitotisak se može primijeniti na cijeli niz podloga: papire, različiti polimere, staklo, keramiku i metale. Na kvalitetu otiska djeluju slijedeće varijable: napetost mrežice, viskoznost boje, tlak i brzina rakela, razmak sita od podloge, uvjeti sušenja i drugo. Zbog svoje kompleksnosti sitotisak predstavlja pogodno područje za primjenu umjetne inteligencije u svrhu optimizacije, kontrole kvalitete i prediktivnog održavanja. Sitotisak se između ostaloga koristi i za izradu elektroničkih uređaja. Vizualna kontrola kvalitete uključuje: sustave računalnog vida temeljene na dubokom učenju, i konvolucijske neuronske mreže (engl. *convolutional neural networks*). Time se omogućuje: detekcija defekata u realnom vremenu, prepoznavanje nepravilnog nanosa boje, identifikacija mikrodefekata na tiskanim vodovima kod tiskane elektronike i

kontrola registra višebajnog sitotiska. Gafurov i suradnici razvili su UI modeli integrirali ga sa sustavom sitotiska s role na rolu kako bi se otkrilo razmazivanje, jedan od glavnih nedostataka sitotiska (Slika 2) [55]. UI pristupi značajni su u području strojnog vida, a neuronske mreže, uključujući klasifikaciju slike, detekciju objekta i segmentaciju slike, mogu riješiti otkrivanje nedostataka.



Slika 2: a) Postupak sitotiska s role na rolu, b) Položaj kamera za kontrolu kvalitete opreme za sitotisk [55]


Nyabodza i koautori opisuju kontrolu kvalitete TiO_2 elektroda dobivenih sitotiskom [56]. Upotrebljavaju se metode strojnog učenja: slučajna šuma, stroj potpornih vektora i napredna neuronska mreža, koje se inače najčešće koriste u kontroli kvalitete proizvoda. Slučajna šuma se koristi za praćenje procesa u proizvodnji orijentiranoj na talinu analizom slika, snimljenih tijekom proizvodnje, što predstavlja konkretan primjer UI algoritama u automatskoj kontroli kvalitete sitotiska. Primjer se odnosi na tisak elektroda, međutim metodologija bi se mogla validno prenijeti na kontrolu kvalitete grafičkih sitotiskarskih otisaka u proizvodnji.

Jedno od područja primjene UI u sitotisku je prediktivno modeliranje kvalitete otiska. U toj tehnici tiska mogu se javiti problemi kao što su: neujednačeni prijenos boje, varijacija u debljini boje, nepravilno poravnavanje registra i zamućenje rubova. Primjenom algoritama strojnog učenja, kao što su slučajna šuma, stablo odlučivanja (engl. *decision trees*) i neuronske mreže, moguće je modelirati odnos između procesnih čimbenika, poput viskoznosti boje, napetosti sita i tlaka rakela, te kvalitete ispisa. Zahao i suradnici su u članku opisali metodu automatskog otkrivanja defekata u sitotisku u proizvodnji baterija s naglaskom na usklađivanje stacionarne mreže br-

zinskog polja i L-K algoritma optičkog toka [57]. Opisana metoda može prepoznati i klasificirati različite defekte zamućenja i slična iskrivljenja. U proizvodnji silicijskih solarnih ćelija u kontekstu srebrnih elektroda koristi se sitotisk. U tisku može doći kod linija manjih od 15 μm , odnosno radi nepravilnosti rada, prekida mrežice ili povećanog otpora mrežice do neočekivane potrošnje srebra [58]. Korištenjem metoda strojnog učenja omogućeno je predviđanje trodimenzionalne geometrije, što se može primijeniti za izvođenje zaključaka o utjecaju relevantnih parametara.

2.2 Primjena umjetne inteligencije u digitalnom tisku

Softver za optimizaciju ispisa u digitalnom tisku temeljen na umjetnoj inteligenciji koristi suvremene tehnologije za analizu i poboljšanje zadataka, raspoređivanje poslova te ekonomski opravdano korištenje resursa. Umjetna inteligencija omogućuje prediktivno održavanje, personalizaciju usluga, transformirajući operacije ispisa i poboljšavajući kvalitetu slika. Osim toga, UI pomoću automatizacije optimizira tijek rada i poboljšava ukupne rezultate rada.



Slika 3: Dijagram toka za predviđanje objektivne metrike kvalitete uključujući kontrast, oštrinu slike i homogenost boje [59]

Zhong i suradnici razvili su učinkovitu i pouzdanu metriku za procjenu kvalitete tiskanih slika, koje oponašaju ljudsku vizualnu percepciju. Metodologija za kvantitativnu procjenu kvalitete digitalnog ispisa koristi model umjetne inteligencije temeljen na višeslojnom perceptronu (MPL) [59]. U radu se kombiniraju značajke iz prostorne i frekvencijske domene digitalno otisnutih slika, kako bi se konstruirao multidimenzionalni model. Takav model ima mogućnost predviđanja objektivne metrike kvalitete, uključujući kontrast, homogenost boje i oštrinu slike (Slika 3). U radu je predstavljena pouzdana i učinkovita metrika za procjenu kvalitete otisnutih slika [59].

Umjetna inteligencija može dinamički pokrenuti profile boja ili rezoluciju slike kako bi se postigao željeni rezultat, pa i ušteda resursa. Osim toga može olakšati personalizirani tisak prilagođavanjem materijala za ispis, optimiziranjem radnih procesa i predviđanjem potreba za održavanjem opreme za ispis.

Tablica 1: Primjena UI i prednosti automatizacije u digitalnom tisku [60]

Prednosti	Objasnenje	Primjer
Povećana učinkovitost	UI smanjuje ručni rad, pojednostavljuje procese	UI optimizira čekanje za ispis, smanjuje vrijeme 30%
Smanjena proizvodnja	UI identificira mogućnosti uštede troškova	Prediktivno održavanje, vođeno UI smanjuje troškove za 20 %
Poboljšana kvaliteta ispisa	UI poboljšava oštrinu slike i točnost boja	Algoritmi poboljšavaju rezoluciju za 25 %
Brže vrijeme obrade	UI automatizira, raspoređuje obradu zadataka ispisa	Raspoređivanje poslova temeljno na UI smanjuje vrijeme za 40 %
Poboljšano korištenje resursa	UI optimizira lokaciju resursa	UI dinamički dodjeljuje resurse pisača, smanjujući vrijeme neaktivnosti za 50 %
Minimiziranje pogreške i ponovni ispisi	UI detektira pogreške u stvarnom vremenu	Kontrola kvalitete uz UI smanjuje pogreške za 90 %
Optimizirana upotreba opreme za ispis	UI optimizira korištenje opreme	UI smanjuje vrijeme zastoja za 15 %
Pojednostavljeni tijek rada	UI automatizira zadatke tijekom rada, smanjuje uska grla	Optimizacija tijekom rada vođena UI smanjuje vrijeme procesa za 30 %
Veća fleksibilnost u rasporedu poslova	UI se prilagođava prioritetima i zahtjevima	Softver za raspoređivanje temeljen na UI omogućava prilagodbe rasporeda poslova u hodu

Posebno treba naglasiti da UI analizira preferencije kupaca i u skladu s time prilagođava tisak, što doprinosi zadovoljstvu kupaca.

Prediktivno održavanje revolucionira tiskarsku industriju. Korištenjem UI algoritama pisači mogu predvidjeti potrebu za održavanjem analizirajući mnoštvo podataka, što uključuje očitavanja senzora, koji detektiraju varijacije u temperaturi, vlažnosti i drugim čimbenicima, kao i povijesne zapise, koji dokumentiraju prošle probleme i rješenja. Opisana sposobnost omogućuje tiskarama da pravovremeno zakazuju intervencije, minimiziraju poremećaje u proizvodnji i maksimiziraju proizvodnju. Produktivno održavanje temeljeno na UI osnažuje tiskare da optimiziraju poslovanje, smanje troškove održavanja i pruže pouzdane visokokvalitetne usluge svojim klijentima te time povećaju konkurentnost na tržištu.

Prednosti prediktivnog održavanja su minimiziranje zastoja proizvodnje, pravovremeno održavanje koje sprečava prerano trošenje pisača, mogućnost prilagodbe rasporeda održavanja, omogućavanje daljinsko upravljanja pisačima, smanjenje potrebe za hitnim popravcima, osiguravanje optimalne performanse pisača, minimiziranje vremena zastoja, što doprinosi zadovoljstvu kupaca, osiguravanje pravovremene isporuke kao i kvalitetu ispisa, a optimalne prakse održavanja smanjuju potrošnju resursa, smanjuju otpad, i time pomiču održivost i ekološku odgovornost [61].

Algoritmi strojnog učenja omogućavaju analizu velikog broja procesnih varijabli s ciljem automatskog prilagođavanja parametara u realnom vremenu, stabilizaciju kvalitete ispisa i optimizaciju potrošnje materijala. Prediktivno održavanje u stvarnom svijetu prikazano je na primjerima: Xeroxa, Epsona i HP-a. Xerox koristi UI za praćenje performansi pisača i predviđanje potreba za održavanjem koristi analizu podataka i zapisnike o pogreškama, predviđa kvarove [61]. Epson Precision Core tehnologija uključuje sustave za nadzor rada inkjet mlaznica i automatizira cikluse održavanja koji stabiliziraju rad pri visokim produkcijskim opterećenjima [62]. HP PrintOS platforma omogućuje prikupljanje i analizu podataka o performansama i produktivnosti sustava kroz *cloud* infrastrukturu. Time se omogućuje prostor za implementaciju napredne analitike i modela prediktivnog odlučivanja [63].

2.3 Primjena umjetne inteligencije u personaliziranom ispisu

Personalizirani tisak na osnovu umjetne inteligencije revolucionira tisak korištenjem naprednih algoritama za prilagođavanje sadržaja, slika i poruka pojedinačnim primateljima. Korištenjem podataka o kupcima demografskim podacima algoritmi umjetne inteligencije dinamički prilagođavaju materijale za tisak kako bi odgovarali specifičnim preferencijama. Personalizirani ispis na osnovu UI omogućuje učinkovitiju komunikaciju s kupcima. Tiskani materijali prilagođeni su interesima kupaca i povećavaju vjerojatnost ponovnog poslovanja.

Primjer personaliziranog ispisa na osnovu umjetne inteligencije iz stvarnog svijeta uključuje ispis varijabilnih podataka (VDP). U tom slučaju UI se koristi za personalizaciju teksta, slika i ostalog sadržaja na svakom ispisnom primjerku prema podacima primatelja. Haik i suradnici predlažu sustav za automatsku kontrolu kvalitete varijabilnog tiska temeljen temeljenog na dubokom učenju, koji uspoređuje referentnu digitalnu sliku s otisnutom i skeniranom slikom kako bi otkrio defekte u personaliziranom tisku [64].

Osim toga umjetna inteligencija omogućuje stvaranje personaliziranih kampanja izravne pošte i prilagođene kataloge proizvoda.

3. Zaključak

Ne tako davno činilo se da će uz pomoć digitalnog oglašavanja, društvenih medija i online publikacija doći do irelevantnosti tradicionalnih tiskanih medija. Suprotno tome, tiskarska industrija pronašla je načine opstanka u digitalnom dobu.

Prihvatanjem inovativnih rješenja i tehnologije uvođenja UI, tiskarska industrija mijenja paradigmu. Tiskarske tvrtke koje upotrebljavaju UI imaju koristi od povećanja produktivnosti, uštedi resursa, smanjenju troškova i mogućnosti ispunjavanja visokih standarda kvalitete čime stječu konkurentsku prednost na tržištu.

Koncept Print 2 Web znači da se tisak i digitalni materijali mogu nadopunjavati. Neki tiskani materijali imaju QR kodove ili web poveznice koje čitatelje usmjeravaju na online sadržaje. Varijabilni ispis podataka je inovacija koja omogućuje prilagodbu tiskovnih materijala. Tehnološki napredak NFC, odnosno komunikacija bliskog polja, omogućuje tiskanim materijalima interakciju s pametnim telefonima i drugim NFC uređajima.

Kako tehnologija umjetne inteligencije nastavlja s inovacijama očekuju se inovativne primjene koje će dodatno transformirati tiskarsku industriju. Tiskarske tvrtke koje integriraju umjetnu inteligenciju u svoje poslovne procese bit će dugoročno konkurentne i nudit će učinkovita rješenja uz trendove prilagodbe i održivosti.

4. Literatura

- [1] ISO/IEC 22989:2022 Information Technology-Artificial intelligence- Artificial intelligence concepts and terminology, ISO-International Organisations for Standardisation, 2022. *Dostupan na:* <http://www.iso.org>.> standard, *Pristupljeno:* 2026-01-21
- [2] Russel, S.; Norving, P.: *Artificial Intelligence: A Modern Approach*, Pearson, ISBN 978-0-13, Hoboken, New Jersey (2021)

- [3] Rai, A.; Constantinides, P., Sarker, R.: Next-generation digital platforms: Toward human-AI-hybrids. *Management Information Systems Quarterly*, **43** (2019) 1, 3-9
- [4] Dwivedi, Y. K.; Hughes, L., Ismagilova, E., Aarts, G., Crica, T., Duan, Y., Dwivedi, R., Crick, F., Duan, Y., Dwivedi, R., Edwards, J., Janssen, M., Janes, P., Kumar, K. A., Keskin, H., Kronemann, B., Lal, B., Lucini, B., Medaglia, R., Williams, M. D.: Artificial intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and an agenda for research, practice, and policy, *International Journal of Information Management* **57** (2021) 101994, <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- [5] Lindberg, D.; Harnessing, G.: AI for smart manufacturing: insights from industry 4.0, *Discover Artificial Intelligence*, **5** (2025) 111, <https://doi.org/10.1007/s44163-025-00363-0>
- [6] Alatalo, J.; Hellimo, E., Rantanen, M., Väänänen, O., Sipola, T.: Reducing emissions using artificial intelligence in the energy sector: A scoping review, *Applied Sciences*, **15** (2025) 2, 999, <https://doi.org/10.3390/app15020999>
- [7] Zhang, T.; Štrbac, G.: Novel artificial intelligence applications in energy: A systematic review, *Energies*, **18** (2025) 143747, <https://doi.org/10.3390/en18143747>
- [8] Jenko, S.; Papadopoulou, E., Kumar, V., Overman, S. S., Krepelkova, K., Wilson, J., Dunbarr, E. L., Spice, C., Exarchos, T.: Artificial intelligence in healthcare. How to develop and implement safe, ethical and trustworthy AI systems, *AI*, **6** (2025) 6, 116, <https://doi.org/10.3390/ai6060116>
- [9] Kuo, C.-T.; Xu, D., Friesen, R.: A brief review of unsupervised machine learning algorithms in astronomy: dimensionality reduction and clustering, *Universe*, **11** (2025) 12, 412, <https://doi.org/10.3390>
- [10] Matos, T.; Santos, W., Zdravevski, E., Coelho, Pires, I. M., Madeira, F.: A systematic review of artificial intelligence applications in education: Emerging trends and challenges, *Decision Analytics Journal*, **15** (2025) 100571, <https://doi.org/10.1016/j.dajour.2025.100571>
- [11] Rong, R.; Ma, S., Ren, N., Lin, Q., Ning, J.: Generative artificial intelligence transportation systems: A systematic review of applications, *Frontiers of Engineering Management*, **12** (2025) 1020-1036, <https://doi.org/101007/s42524-025-4241-9>
- [12] Hossain, M. N.: Artificial revolutionising the automotive sector: A holistic review, *Computers, Materials & Continua*, **82** (2025) 3, 59944, <https://doi.org/10.32604/cmc2025>
- [13] Rezaei, A.; Abdellatif, I., Umar, A.: Towards economic sustainability: A comprehensive review of AI and machine learning techniques in improving the accuracy of stock market movements, *International Journal of Financial Studies*, **13** (2025) 1, 28, <https://doi.org/10.3390/ijfs13010028>
- [14] Rong, R.: Generative AI revolution in cybersecurity: A comprehensive review of threat intelligence and operation, *Artificial Intelligence Review*, **58** (2025) 236, <https://doi.org/10.1007/s10462/025/112195>
- [15] Bosque, A.; Arias, P. F., Lampropoulos, G., Vergara, D.: The role of artificial intelligence in gaming, *Applied Sciences*, **15** (2025) 23, 12358, <https://doi.org/10.3390/app152312358>
- [16] Sadashiv, B. S.; Bansal, R., Suny, J., Paul, K., Al Said, N.: Bridging algorithms and intelligence: AI integration in core computer science solution, *International Journal of Environmental Sciences*, **11** (2025) 17, 710-719, <https://doi.org/10.64252/h7ztpv96>

- [17] Shaveta, J.: A review on machine learning, *International Journal of Science and Research Archive*, **9** (2023) 1, 281-285, <https://doi.org/10.30574/ijrsra.2023.9.1.0410>
- [18] Yeh, Y. T.; Eden, R., Filet, E., Syed, R.: The role of use for the business value of big data analytics, *The Journal of Strategic Information Systems*, **34** (2025) 2, 101888, <https://doi.org/10.1016/j.sis.2025.101888>
- [19] Adenubi, A. D.; Oduroye, A.: Robotics and automations in 21st century: Innovation and applications, *Online Journal of Robotics & Automation Technology*, **4** (2025) 1, 9, <https://doi.org/10.33552/OJRAT.2025,04.000580>
- [20] Zhang, E.; Chen, Y., Gao, M., Duan, J., Jing, C.: Automatic defect detection for web offset printing based on machine vision, *Applied Sciences*, **9** (2019) 17, 3598, <https://doi.org/10.3390/app9173598>
- [21] Gajiwala, C.: The rise of deep learning and neural networks: Revolutionising artificial intelligence, *European Journal of Computer Science and Information Technology*, **13** (2025) 17, 88-99, <https://doi.org/10.37745/ejcsit.2013/vol13n178898>
- [22] Makridakis, S.: The forthcoming artificial intelligence revolution, *Futures*, **90** (2017) 46-60, <https://doi.org/10.1016/j.futures.2017.03.006>
- [23] Palmie, M.; Aebersold, A., Oghazi, P., Pashkevich, N., Gassmann, O.: Digital-sustainable business models: definition, systematic literature review, integrative framework and research agenda from a strategic management perspective, *Strategy in the Digital Transformation Era*, **27** (2025) 346-374, <https://doi.org/10.1111/ijmr.12380>
- [24] Berges, A. F. S.; Laurindo, F. J. B., Spinola, M. M., Concavles, R. F.: The strategic use of AI in the digital era: Systematic literature review and future research directions, *International Journal of Information Management*, **57** (2020) 102225, <https://doi.org/10.1016/j.ijinfomgt.2020.102225>
- [25] Costa, A.; Crupi, A., Casaroni, F., Abbate, T.: Exploring the role of artificial intelligence in addressing sustainable development. A semantic analysis of AI patents, *Technovation*, **148** (2025) 103335, <https://doi.org/10.1016/j.technovation.2025.103335>
- [26] Pietrzak, P.; How, A. I.: Can support the sustainable development of organisations? Findings from a literature review, *Issues Information Systems*, **26** (2025) 1, 296-307, https://doi.org/10.48009/1_iis_122
- [27] Toderas, H.: Artificial intelligence for sustainability: A systematic review and critical analysis of AI applications, challenges, and future directions, *Sustainability* **17** (2025) 17, <https://doi.org/10.3390/su17178049>
- [28] Nayak, S.: Enhancing manufacturing with artificial intelligence: An overview of the present situation, insights, obstacles and future trends, *World Journal of Advanced Research and Reviews*, **28** (2025) 3, 9-19, <https://doi.org/10.30574/wjarr.2025.28.3.4033>
- [29] Sallam K.; Mehamed, M., Muhamed, A. W.: Internet of Things (I_OT) in supply chain management: Challenges, opportunities, and best practices, *Strategic Management Innovation Journal*, **2** (2023), <https://doi.org/10.61185/smij.2023.2210>
- [30] Roberts, E.: Supply Chain 4.0: The role of artificial intelligence in enhancing resilience and operational efficiency, *International Journal of Advanced Artificial Intelligence Research*, **2** (2025) 8, 29-34

- [31] Deokar, S.; Bansode, V., Wankhede, S., Kharche, P.: Industry 4.0 moving towards smart manufacturing: A comprehensive review, *International Journal of Science and Research Archive*, **16** (2025) 3, 630-642, <https://doi.org/10.30574/ijsva.2025.16.3>
- [32] Xu, X.; Lu, Y., Vogel-Heuser, B., Wang, L.: Industry 4.0 and Industry 5.0 - Inception, conception and perception, *Journal of Manufacturing Systems*, **61** (2021) 530-535, <https://doi.org/10.1016/j.msy.2021.10.006>
- [33] Kamble, S. S.; Gunasekaran, A., Sharma, R.: Analysis of the driving and dependence power of barriers to adopt industry 4.0 in Indian manufacturing industry, *Computers in Industry*, **101** (2018) 107-119, <https://doi.org/10.1016/j.compind.2018.06.004>
- [34] europa.eu, Industry 5.0: Towards More Sustainable, Resilient and Human, *Dostupno na: http://www.research-and-innovation.eu.europa.eu*, *Pristupljeno: 2026-02-04*
- [35] Nahavandy, S.: Industry 5.0 - A human-centric solution, *Sustainability*, **11** (2019) 4371, <https://doi.org/10.3390/su11164371>
- [36] Nasir, V.; Hosseini, A., Binfield, L., Hasani, N., Ghoth, S., Diederichs, V.: Human-centric Industry 5.0 manufacturing: A multi-level framework from design to consumption within Society 5.0, *International Journal of Sustainable Engineering*, **18** (2025), <https://doi.org/10.1080/19397038.2025.2551000>
- [37] Chu, Z.; Guo, X., Zou, S.: Impact of information and communications technology alignment on supply chain performance in the Industry 4.0 era: mediation effect of supply chain integration, *Journal of Industrial and Production Engineering*, **39** (2022) 7, <https://doi.org/10.1080/21681015.2022.2099472>
- [38] Toorajipour, R.; Sohrabpour, V., Nazarpour, A., Oghazi, P., Fischl, M.: Artificial intelligence in supply chain management: A systematic literature review, *Journal of Business Research*, **122** (2021) 502-517, <https://doi.org/10.1016/j.jbusres.2020.09.009>
- [39] Lin, X.: Artificial Intelligence in the Industrial Engineering, *Advances in Operation Research and Production Management*, **1** (2024) 1, 1-6, <https://doi.org/10.54254/3006-1210/direct/0106>
- [40] Masod, M. Y. B.; Zakaria, S. F.: Artificial intelligence in the printing industry: A systematic review of industrial applications, challenges and benefits, *International Journal of Research and Innovation in Social Science*, **8** (2024) 9, 1713-1732, <https://doi.org/10.47772/IJRISS.2024.8090141>
- [41] Wang, X.; Zhang, Y.: Smart manufacturing and artificial intelligence: Applications in the printing industry, *Computers in Industry*, **129** (2021) 103458 <https://doi.org/10.1016/j.compind.2021.103458>
- [42] Deokar, S.; Bansode, V. H., Wankhede, S., Kharche, P.: Industry 4.0 moving towards smart manufacturing: A comprehensive review, *International Journal of Science and Research Archive*, **16** (2025) 3, 630-642, <https://doi.org/10.30574/ijsva.2025.16.3.2596>
- [43] Bratić, D.; Miljković, P., Jurčević, D., Grabarić, T.: AI-Driven Random Forest Model and the Six Sigma Approach for Enhancing Offset Printing Process and Product Quality, *Applied Sciences*, **15** (2025) 5, 2266, <https://doi.org/10.3390/app15052266>
- [44] Masod, M. Y.; Zakaria, S. F.: How AI and automation are revolutionising the printing industry, *Dostupno na: https://offsetprintingtechnology.com*, *Pristupljeno: 2026-02-10*

- [45] Sharma, A.: Architecting data-driven print manufacturing using digital twin technology, *International Journal of Computing and Artificial Intelligence*, **6** (2025) 2, 70-76, <https://doi.org/10.33545/27076571.205.v6.i172>
- [46] Heidelberg, Speedmaster XL 106, *Dostupno na*: <http://www.heidelberg.com>, *Pristupljeno*: 2025-12-11
- [47] Higgins, S. G.; Boughey, F. L., Hills, R., Steinke, J. H. G., Muir, B. V. O., Campbell, A. J.: Quantitative Analysis and Optimization of Gravure Printed Metal Ink, Dielectric, and Organic Semiconductor Films, *ACS Applied Materials & Interfaces*, **7** (2015) 9, 5045-5050, <https://doi.org/10.1021/am508316f>
- [48] Singlaengravureslip.com, How AI and automation are transforming rotogravure cylinder *Dostupno na*: <https://singlaengravureslip.com>, *Pristupljeno*: 2025-12-11
- [49] Green-AI Hub Mittelstand, AI-based quality assurance for rotogravure cylinders, *Dostupno na*: <https://green-ai-hub.de>, *Pristupljeno*: 2026-02-10
- [50] Schmidt, D.; Gevers, R., Schwiep, Ordieres-Mere, J., Villaba-Diez, J.: Deep learning enabling quality improvement in rotogravure manufacturing, *Procedia Manufacturing*, **51** (2022) 330-336, <https://doi.org/10.116/j.promfg.2020.10.047>
- [51] Brumm, P.; Ciotta, N., Sauer, H. M., Blaeser, A., Dörsam, E.: Deep learning study of induced stochastic pattern formation in the gravure printing fluid splitting process, *Journal of Coatings Technology and Research*, **20** (2020) 1, 51-72, <https://doi.org/10.1007/s11998-02200687-x>
- [52] Chen, D.: The application of artificial intelligence (AI) in flexography, *Dostupno na*: <https://www.kyms.com/aitymsg/application-of-ai-flexo.html>, *Pristupljeno*: 2026-02-12
- [53] Basak, S. P. C. S.; Maity, A., Paul, K. C.: Machine learning approach to predict the dot gain of flexographic prints, *Acta Graphica*, **33** (2025) 1, 34-43, <https://doi.org/10.25027/ag.33.1.4>
- [54] Abusaq, Z.; Zahoor, S., Habib, M. S., Rehman, M., Mahmud, J., Kanan, M., Mushtaq, R. T.: Improving energy performance in flexographic printing process through Lens A case study, *Energies*, **16** (2023) 4, 1972, <https://doi.org/1.3390/en16041972>
- [55] Gafurov, A. N.; Phung, F. H., Ryu, B.-H., Kim, I., Lee, T.-H.: AI-aided printed line smearing analysis of the roll-to-roll screen printing process for printed electronics, *International Journal of Precision Engineering and Green Technology*, **10** (2023) 339-352, <https://doi.org/10.1007/s40684-022-0>
- [56] Nyabadza, A.; Azoulay-Younes, L., Vazquez, M., Brabazon, D.: Machine learning-based process quality control of screen- printed titanium dioxide electrodes, *Results in Materials*, **26** (2025) 100692, <https://doi.org/10.1016/j.rinma.2025.100692>
- [57] Nyabadza, A.; Usman, M., Bilal, M., Ashraf, M. A., Abdullahi, A., All, W., Dubey, A., Arepalli, S., Choubey, P., Fernando, D., Azoulay-Younes, L., Brabazon, D.: Artificial intelligence for electrode quality control in battery manufacturing: Evaluating machine learning, deep learning and transfer learning models for tin, zinc and titanium electrodes, *Journal of Engineering Research, In Press*, <https://doi.org/10.1016/j.jer.2026.02.010>
- [58] Singler, M.; Butget, M., Preu, R., Clement., R, Lorerenz, A.: Enhancing inline quality control: Mashine learning for fuul scale 3 D prediction of screen-printed silver contacts, *Solar Energy Maaterials and Solar Cells*, **286** (2025) 113592, <https://doi.org/10.1016/j.solmat.2025.113592>

-
- [59] Zhong, J.; Zhan, H., Xu, F., Zhang, Y.: Research on a multidimensional digital printing image quality evaluation method based on MLP neural network regression, *Applied Sciences*, **14** (2024) 14, 5986, <https://doi.org/10.3390/app14145986>
- [60] Biz4Group: What are the real-world use cases of AI in printing? *Dostupno na:* <http://www.biz4g/cases-of-ai-in-print>, *Pristupljeno:* 2025-12-11
- [61] Xerox, Global Service Experience for Predictive Maintenance, *Dostupno na:* <https://www.xerox.com/en-us/services/remote-services>, *Pristupljeno:* 2025-12-12
- [62] Epson Corporate, PrecisionCore Technology, *Dostupno na:* <http://www.corporate.epson.com/overview>, *Pristupljeno:* 2025-12-11
- [63] HP, PrintOS-HP Print production operating system, *Dostupno na:* <https://www.hp.com/printers>, *Pristupljeno:* 2025-12-11
- [64] Haik, O.: A novel inspection system for variable data printing using deep learning, *Dostupno na:* <http://www.researchgate.net>, *Pristupljeno:* 2026-12-11

Povijesni pregled i suvremena primjena umjetne inteligencije u obrazovanju

Mia Čarapina¹, Jana Žiljak Gršić¹

¹Tehničko veleučilište u Zagrebu, Vrbik 8, 10000 Zagreb

Sažetak: Rad donosi sažeti pregled višedesetljetnog razvoja i primjene umjetne inteligencije u obrazovanju, od prvih računalnih sustava za podršku obrazovanju do suvremene generativne i multimodalne faze. U radu se zatim razmatra primjena generativne umjetne inteligencije u obrazovanju u tehničkom području, s posebnim fokusom na polja računarstvo i grafička tehnologija. Empirijski dio rada temelji se na istraživanju provedenom među studentima Tehničkog veleučilišta u Zagrebu i Sveučilišta u Zagrebu Grafičkog fakulteta o navikama i stavovima uporabe umjetne inteligencije u obrazovanju. Rezultati istraživanja upućuju na učestalu uporabu alata umjetne inteligencije, njihovu integraciju u akademsku praksu te potrebu za jasnijim pravilima uporabe, promišljenijim pedagoškim usmjeravanjem i prilagodbom vrednovanja.

Cljučne riječi: umjetna inteligencija u obrazovanju, generativna umjetna inteligencija, visoko obrazovanje

1. Uvod

Umjetna inteligencija obuhvaća širok skup pristupa i primjena u različitim kontekstima. Pritom se uz termin “umjetna inteligencija” (engl. *Artificial Intelligence*, AI) susreće i termin “proširena inteligencija” (engl. *Augmented Intelligence*), koji naglašava da svrha iste nije zamjena ljudske inteligencije, nego nadopuna i proširenje ljudskih mogućnosti [1]. Početak trećeg desetljeća 21. stoljeća obilježen je porastom interesa za mogućnosti primjene umjetne inteligencije, ponajviše zbog široke dostupnosti alata temeljenih na generativnoj umjetnoj inteligenciji (engl. *Generative Artificial Intelligence*, GenAI), odnosno velikim jezičnim modelima (engl. *Large Language Models*, LLM) [2–4].

U javnom i znanstvenom prostoru primjena umjetne inteligencije u obrazovanju često se prikazuje kroz polarizirane rasprave o očekivanim koristima i mogućim rizicima, pri čemu se istodobno otvaraju pitanja utjecaja na obrazovanje i tržište rada,

kao i potreba da se razvoj i primjena usmjere prema odgovornim i etički utemeljenim načelima [5–8]. Ipak, važno je naglasiti da primjena umjetne inteligencije za podršku obrazovanju nije tek suvremeni trend te da istraživačko područje primjene umjetne inteligencije u obrazovanju (engl. *Artificial Intelligence in Education*, AIED) postoji desetljećima te obuhvaća razvoj i analizu niza pristupa i implementacija u obrazovnom kontekstu, od jednostavnih “imitacijskih strojeva” do adaptivnih pristupa učenju i poučavanju, ekspertnih sustava, inteligentnih tutorskih sustava (engl. *Intelligent Tutoring System*, ITS) i podatkovno vođenih rješenja. Aktualni porast interesa za primjenu umjetne inteligencije u obrazovanju posljednjih godina povezan je, između ostalog, i s razvojem tehnologija koje su postupno proširivale mogućnosti računalne potpore učenju. Primjerice, Zhai i sur. [9], ali i drugi autori [10–12], ističu da je aktualni zamah umjetne inteligencije u obrazovanju usko povezan s napretkom obrade velikih količina podataka (engl. *big data*), dostupnosti računarstva u oblaku (engl. *cloud computing*), napretkom istraživanja iz područja neuronskih mreža (engl. *neural networks*) i metoda strojnog učenja (engl. *machine learning*), čime su postali mogući, ali i pristupačni, skalabilniji, prilagodljiviji i interaktivniji sustavi. Tome pridonosi i razvoj velikih jezičnih modela. Rasprostranjena uporaba alata baziranih na generativnoj umjetnoj inteligenciji može se djelomično povezati i s njihovom jezičnom pristupačnošću, odnosno činjenicom da omogućuju interakciju putem prirodnoga jezika koji je korisnicima blizak i ne zahtijeva poznavanje specijaliziranih naredbi ili formalnih jezika [13].

Ipak, dostupnost i razvijenost tehnologije same po sebi ne jamče obrazovnu vrijednost alata koji se na njima temelje. Iako se generativna umjetna inteligencija u posljednje vrijeme često prikazuje kao tehnološka prekretnica koja preoblikuje dosadašnje poučavanje i učenje, Holmes i Tuomi [4] ističu da su očekivanja o učincima primjene umjetne inteligencije u obrazovanju često utemeljena na pogrešnim pretpostavkama o tome što takvi sustavi doista mogu, kao i na to da je njihova integracija u sustavu obrazovanja nerijetko bez jasnog odgovora na pitanje što se njima želi postići. Selwyn [14] stoga zagovara da bi fokus rasprava o primjeni umjetne inteligencije u obrazovanju trebao biti na “stvarno postojećim” oblicima umjetne inteligencije (engl. *actually existing AI*) [15], odnosno na sustavima koji se doista uvode i koriste u obrazovnoj praksi, sa svim svojim ograničenjima, pogreškama i infrastrukturnim preduvjetima. Time se naglasak nastoji prebaciti s apstraktnih obećanja o transformaciji obrazovanja na empirijski utemeljeno sagledavanje toga što konkretni alati bazirani na umjetnoj inteligenciji (ne)mogu u složenim društvenim kontekstima učinja te kakve su pritom društvene i etičke implikacije. Dodatnu složenost aktualnom trenutku daje i činjenica da generativna umjetna inteligencija u obrazovne ustanove često ne ulazi isključivo kroz planirane procese, nego i spontano, kroz svakodnevnu uporabu učenika i nastavnika, često i izvan formalnog konteksta. Reich i Dukes [16] ovaj fenomen opisuju pojmom “tehnologija koje dolaze” (engl. *arrival technologies*), naglašavajući kako alati poput ChatGPT-a mogu zaobići (i zaobilaze!) uobičajene institucionalne procese nabave, stručne pripreme edukatora i uvođenja u obrazovni

proces, čime istodobno otvaraju nove mogućnosti, ali i stvaraju pedagoške, organizacijske i istraživačke izazove.

Polazeći od navedenoga, cilj ovoga rada je pružiti sažeti uvid u višedesetljetni razvoj i primjenu umjetne inteligencije u obrazovanju, s osvrtom na neke od tehnoloških promjena koje su utjecale na mogućnosti njezine primjene. Rad je strukturiran tako da najprije donosi kratki povijesni pregled razvoja i primjene umjetne inteligencije u obrazovanju, a potom se usmjerava na aktualnu analizu primjene u tehničkom području i prikaz rezultata istraživanja o navikama i stavovima studenata o umjetnoj inteligenciji provedenog među studentima Tehničkog veleučilišta u Zagrebu i Sveučilišta u Zagrebu Grafičkog fakulteta. Naposljetku, raspravlja se o implikacijama dobivenih rezultata na učenje, poučavanje i vrednovanje, kao i smjernicama za integraciju umjetne inteligencije u obrazovanje u tehničkom području.

2. Povijesni razvoj primjene umjetne inteligencije u obrazovanju

Ideja stvaranja “strojeva koji mogu misliti” pojavila se znatno prije razvoja suvremenoga računarstva. Još su u ranim filozofskim i logičkim promišljanjima postojala nastojanja da se ljudsko mišljenje opiše, strukturira i sustavno prikaže pomoću pravila i formalnih načela [17]. Primjerice, MacLennan [18] ukazuje na to da su ideje na kojima se temelji umjetna inteligencija, a osobito one na kojima se temelji simbolička umjetna inteligencija (engl. *symbolic AI*) prisutne još u doba antičke Grčke [19]. Pritom govorimo o umjetnoj inteligenciji baziranoj na hipotezi fizičkog simboličkog sustava (engl. *Physical Symbol System Hypothesis*, PSSH), odnosno teoriji o umjetnoj inteligenciji i kognitivnoj znanosti koju su formulirali Newell i Simon [20] 70-ih godina 20. stoljeća. Ova teorija podrazumijeva da se znanje može reprezentirati simboličkim strukturama, a mišljenje modelirati kao računalna manipulacija tim strukturama prema formalnim pravilima. Formalna pravila pritom označavaju precizno definirane postupke i logičke operacije prema kojima se simboli mogu stvarati, povezivati, preoblikovati i koristiti u procesu zaključivanja. Drugim riječima, pretpostavlja se da računalo koje obrađuje simbole prema unaprijed određenim pravilima može pokazati inteligentno ponašanje nalik ljudskom.

U povijesnim prikazima kao rane prekretnice u području istraživanja i primjene umjetne inteligencije često se izdvaja Turingov znanstveni rad “Computing Machinery and Intelligence” [21] iz 1950. godine u kojem autor predlaže “Igru oponašanja” (engl. *Imitation game*), kasnije poznatu kao Turingov test, kojom se ispituje ljudska percepcija ponašanja stroja, odnosno može li čovjek prepoznati vodi li razgovor s računalom, odnosno strojem, ili s drugim čovjekom. Kao sljedeća ključna prekretnica često se navodi dokument “A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence” [22] iz 1955. godine, u kojem se termin “umjetna inteligenci-

ja” pojavljuje već u samom naslovu, a predlaže se održavanje ljetnoga istraživačkog projekta 1956. godine na Dartmouth Collegeu u Sjedinjenim Američkim Državama. Upravo se ovaj projekt uobičajeno opisuje kao simboličko “rođenje” istraživačkog područja, odnosno kao događaj koji je okupio prve istraživače i usmjerio istraživanja u području umjetne inteligencije kao zasebno područje [23].

Razvoj umjetne inteligencije obilježen je izmjenom i paralelizmom različitih paradigmi, od spomenutih simboličkih pristupa utemeljenih na pravilima i reprezentacijama znanja do podatkovno vođenih metoda strojnog učenja, neuronskih mreža i generativne umjetne inteligencije u novijem razdoblju [24]. Dok simbolički pristupi polaze od eksplicitno zadanih pravila, logičkih struktura i unaprijed definiranih modela znanja [25], podatkovno vođene metode temelje se na prepoznavanju obrazaca u skupovima podataka te na učenju zakonitosti, bez potrebe da sva pravila budu unaprijed definirana [26]. Generativna umjetna inteligencija na temelju učenja iz velikih količina podataka ne služi samo za klasifikaciju, predviđanje ili prepoznavanje obrazaca, nego i za stvaranje novog sadržaja, poput teksta, slika, zvuka, videozapisa ili programskog koda [27, 28]. Do danas, istraživačko se područje umjetne inteligencije postupno širilo izvan temeljnih teorijskih pitanja o prirodi inteligencije prema brojnim primjenama u različitim domenama, uključujući obrazovanje, kao i prema razvoju sustava sposobnih za predviđanje, klasifikaciju, prilagodbu i generiranje sadržaja u složenim i dinamičnim okruženjima.

Ovakav sažeti povijesni okvir pruža nužan uvod u kontekst primjene umjetne inteligencije u obrazovanju, jer se obrazovne primjene u pravilu oslanjaju na tehničke mogućnosti određenoga vremena, ali ih istodobno usmjeravaju specifični pedagoški ciljevi i institucionalni kontekst [24]. Razvoj istraživačkog područja umjetne inteligencije u obrazovanju odvijao se kroz isprepletanje različitih istraživačkih tradicija, tehnoloških dostignuća i obrazovnih očekivanja. Holmes i Tuomi [29] tako razlikuju tri međusobno povezana pristupa razvoju “inteligentnih” sustava. Prvi je umjetna inteligencija temeljena na znanju (engl. *knowledge-based/symbolic AI*), koja se u literaturi ponekad naziva i umjetnom inteligencijom temeljenom na pravilima (engl. *rule-based AI*) jer se oslanja na eksplicitno definirana pravila i inferencijske mehanizme. Drugi je podatkovno vođena umjetna inteligencija (engl. *data-driven AI*), koja se temelji na strojnom učenju i statističkom modeliranju na velikim skupovima podataka. Treći je hibridni, neuro-simbolički pristup (engl. *neuro-symbolic*), koji nastoji kombinirati prednosti podatkovno vođenih i simboličkih metoda. Prema njihovoj analizi, pristup utemeljen na pravilima dugo je prevladavao u obrazovnim primjenama, dok podatkovno vođene metode osobito jačaju u novijem razdoblju. Povijesni prikaz u nastavku strukturiran je u četiri razdoblja koja odražavaju značajnije tehnološke promjene i njihov utjecaj na učenje i podučavanje, s naglaskom na primjenu umjetne inteligencije za podršku obrazovanju.

2.1 Rani temelji

Rani primjeri primjene umjetne inteligencije u obrazovanju sredinom 20. stoljeća bili su povezani s pokušajima mehanizacije poučavanja i provjere znanja te najčešće utemeljeni na jasno strukturiranim zadacima, postupnom napredovanju i pružanju povratne informacije učeniku [30]. To znači da se tehnološki korijeni pristupa dizajnu i razvoju sustava usmjerenih učeniku (engl. *learner-centered design*) mogu pratiti već u ovom ranom periodu, od prvih mehaniziranih uređaja za vježbu do nešto kasnijih adaptivnih strojeva za poučavanje [4]. Primjerice, početkom 50-ih godina 20. stoljeća Skinner [30] razvija stroj za poučavanje (engl. *teaching machine*) te ističe učinak usporediv s individualnim podučavanjem, čime se anticipiraju kasniji inteligentni tutorski sustavi. Jedan od poznatijih i često etiketiran kao jedan od prvih ITS sustava bio je Carbonellov SCHOLAR [31] iz 70-ih, koji je generirao odgovore na temelju semantičke mreže pojmova. U istom se razdoblju, 50-ih godina 20. stoljeća, pojavljuju i prvi adaptivni sustavi. Primjerice, Paskov SAKI (engl. *Self-Adaptive Keyboard Instructor*, SAKI) [32] prilagođavao je zadatke prema prethodnom uspjehu. Nešto kasnije, 60-ih i 70-ih godina, prevladavaju ponešto drukčiji adaptivni sustavi temeljeni na pristupu poučavanja uz pomoć računala (engl. *Computer-Aided Instruction*, CAI). Prvi značajniji primjer takvog sustava bio je PLATO (engl. *Programmed Logic for Automatic Teaching Operations*, PLATO) koji je studentima omogućavao pristup nastavnim materijalima, od kojih su neki bili interaktivni, na središnjem računalu putem udaljenih terminala, pri čemu je sustav istodobno moglo koristiti i do tisuću studenata. Ipak, CAI sustavi nisu bili široko prihvaćeni, ponajprije zbog visoke cijene i ograničene dostupnosti glavnih računala potrebnih za njihovo izvođenje [1].

U obrazovnom smislu, navedene tehnološke promjene i prvi prototipi obrazovnih sustava baziranih na umjetnoj inteligenciji pridonijeli su jačanju ideje da se proces poučavanja može strukturirati, sekvencirati i individualizirati uz pomoć računala. Skinnerov koncept stroja za poučavanje [30] označio je početak tehnološki posredovane podrške učenju, utemeljene na postupnom usvajanju sadržaja kroz manje cjeline i na pružanju neposredne povratne informacije učeniku, čime je otvoren prostor za sustavnije promišljanje individualiziranog učenja u tehnološki posredovanom okruženju [30, 33]. Premda su takvi sustavi bili tehnički ograničeni i usmjereni ponajprije na dobro strukturirane zadatke, oni su oblikovali važno načelo koje će ostati prisutno i u kasnijim fazama razvoja i primjene umjetne inteligencije u obrazovanju. Riječ je o shvaćanju da se tehnologija ne mora upotrebljavati samo kao medij za distribuciju i digitalizaciju sadržaja, nego i za prilagodbu nastavnog sadržaja i procesa individualnim obrascima učenja. Drugim riječima, već se u ovom ranom razdoblju pojavljuje začetak personalizacije učenja i adaptivnosti te promišljanje o tome kako računalni sustavi mogu preuzeti dio funkcija koje su se dotad smatrale isključivo domenom nastavnika, poput odabira zadatka, prepoznavanja pogreške i davanja ciljane povratne informacije [30, 32, 34].

2.2 Formiranje umjetne inteligencije u obrazovanju kao istraživačkog područja

Tijekom 80-ih i 90-ih godina 20. stoljeća područje istraživanja i primjene umjetne inteligencije u obrazovanju postupno se profilira kao prepoznatljivo istraživačko područje, kroz početak održavanja specijaliziranih znanstvenih događaja i formiranje publikacijskih kanala. Tako je 1983. godine u Exeteru u Ujedinjenom Kraljevstvu održana prva međunarodna konferencija “International Conference on Artificial Intelligence and Education” [33]. Zanimljivo je da se krajem 80-ih postepeno mijenja priroda odnosa između umjetne inteligencije i obrazovanja u formalnom nazivu područja te se prvotni veznik “i” (engl. *and*) zamjenjuje s “u” (engl. *in*), odnosno uz naziv “Artificial Intelligence *and* Education” pojavljuje se i naziv “Artificial Intelligence *in* Education”. Iako naizgled minorna, ova promjena simbolično definira daljnji smjer istraživanja s većim naglaskom na primjenu umjetne inteligencije u obrazovanju [33]. Nadalje, formalni status područja dodatno potvrđuje pokretanje specijaliziranog znanstvenog časopisa “International Journal of Artificial Intelligence in Education” (ijAIED) [35] 1989. godine.

Ovaj period karakterizira jedna od nekoliko značajnih tehnoloških promjena koje su se dogodile do kraja 20. stoljeća. Pojava i financijska pristupačnost osobnih računala (engl. *Personal Computer*, PC) početkom 80-ih pridonijele su većoj dostupnosti tadašnjih CAI sustava, čime su stvoreni preduvjeti za njihovu širu primjenu. Ipak, glavni nedostatak gotovo svih tadašnjih CAI sustava bio je izostanak “stvarne” prilagodljivosti individualnom korisniku, jer su redoslijed sadržaja, ponuđene informacije i odgovori sustava bili unaprijed zadani i jednaki za sve studente [36]. Međutim, dostupnost osobnih računala značajno je odredila daljnji smjer primjene računala u obrazovanju te razvoja metoda za prilagodbu individualnom korisniku.

U ovom razdoblju intenzivno se razvijaju inteligentni tutorski sustavi koji, povijesno gledano, predstavljaju najčešći oblik primjene umjetne inteligencije za podršku učenju i podučavanju. Prema jednoj od definicija [37] inteligentni tutorski sustavi su računalni sustavi i programi koji primjenjuju tehnike umjetne inteligencije za interakciju s učenicima i pružanje iskustava prilagođenih njihovim trenutačnim potrebama. Izvorno je taj pojam obuhvaćao samo sustave koji modeliraju učenikovo znanje u razvoju, no kasnije definicije često uključuju i sustave koji se prilagođavaju obrascima učenikove aktivnosti te procjenama onoga što učenik zna. Osnovna značajka ovih sustava je integracija nekoliko različitih modela, odnosno pojednostavljenih računalnih prikaza specifičnih znanja o stvarnome svijetu. Tako primjerice mogu sadržavati model domene (engl. *domain model*), model učenika (engl. *learner model*), pedagoški model (engl. *pedagogical model*) te druge modele ovisno o kontekstu primjene. Holmes i Tuomi [4] pritom ističu da su tutorski sustavi temeljeni na znanju relativno uspješniji u formalnim i strukturiranim područjima poput matematike i fizike, gdje je lakše izgraditi stabilne modele domene.

U širem smislu, ovo razdoblje učvršćuje ključnu premisu primjene umjetne inteligencije u obrazovanju da računalo nije samo medij prijenosa sadržaja, nego može preuzeti određene funkcije poučavanja, odnosno dijagnostiku pogrešaka, adaptivno vođenje i ciljanu povratnu informaciju, u mjeri u kojoj je moguće modelirati domenu i učenikove postupke [4]. Time se obrazovna tehnologija pomiče prema dijagnostičko-podržavajućoj ulozi, odnosno nastojanju da sustav “pokušava razumjeti” gdje učenik griješi te usmjeravanju prema ispravnom rješenju [33, 38]. Posljedično, istraživanja u području primjene umjetne inteligencije u obrazovanju tijekom 80-ih i 90-ih godina bila su ponajviše usmjerena na razvoj podrške strukturiranom i individualiziranom učenju, čime je obrazovanje dobilo snažnije alate za personalizaciju učenja [4, 38].

2.3 Digitalno širenje i podatkovni zaokret

Krajem 90-ih godina 20. stoljeća dolazi do dvije tehnološke promjene koje značajno utječu na daljnji razvoj sustava za podršku obrazovanju te mogućnosti primjene umjetne inteligencije. Sve šira javna dostupnost i raširena uporaba interneta nakon prve polovice 90-ih godina, zajedno sa širenjem World Wide Weba, stvorile su preduvjete za razvoj mrežno utemeljenih obrazovnih sustava te omogućile pristup udaljenim obrazovnim sadržajima. Posljedično se od 2000-ih nadalje intenzivno razvijaju te postaju široko rasprostranjeni razni sustavi za e-učenje (engl. *e-learning*) i platforme za upravljanje učenjem (engl. *Learning Management System*, LMS) [39], a s njima i novi oblici primjene umjetne inteligencije u obrazovanju, uključujući adaptivne i inteligentne web-bazirane obrazovne sustave (engl. *Adaptive and Intelligent Web-based Educational Systems*, AIWES) koji, oslanjajući se na model učenika, prilagođuju sadržaj i navigaciju različitim skupinama i pojedincima [40]. Početkom 2000-ih Brusilovsky i suradnici [40] izdvajaju pet tehnologija koje se mogu primjenjivati u takvim sustavima: adaptivnu hipermediju (engl. *adaptive hypermedia*), adaptivno filtriranje informacija (engl. *adaptive information filtering*), inteligentno praćenje (engl. *intelligent monitoring*), inteligentno suradničko učenje (engl. *intelligent collaborative learning*) i inteligentno poučavanje (engl. *intelligent tutoring*). Svakako, ovisno o izvoru, postoje i druge klasifikacije adaptivnih i inteligentnih tehnologija i sustava.

Ono što se u ovom razdoblju također počinje intenzivnije razvijati su sustavi za podršku računalom podržanom suradničkom učenju (engl. *Computer-supported Collaborative Learning*, CSCL) kojima se naglasak stavlja na podršku grupnom, odnosno suradničkom, radu. U takvim se sustavima nastoje pratiti i poduprijeti obrasci suradnje, sudjelovanje članova grupe, grupna dinamika, razmjena ideja i regulacija zajedničkoga rada, pa se razvijaju rješenja poput alata za svijest o radu grupe i njenih članova (engl. *group awareness*), sustava za praćenje interakcije te inteligentnog usmjeravanja (engl. *scaffolding*) i pružanja povratne informacije grupama i edukatorima [41, 42].

Kasnije, sredinom prvog desetljeća 21. stoljeća, pojavljuju se i prvi masovni otvoreni mrežni kolegiji (engl. *Massive Open Online Course*, MOOC) [43, 44], koji dodatno proširuju mogućnosti mrežno utemeljenog obrazovanja prema otvorenijim, dostupnijim i skalabilnijim oblicima učenja. Takvi su kolegiji, osobito zbog velikog broja polaznika i digitalnog praćenja njihovih aktivnosti, otvorili dodatni prostor za primjenu umjetne inteligencije u personalizaciji učenja, preporučivanju sadržaja, automatiziranim vrednovanju i analizi obrazovnih podataka [45, 46].

Treća bitna tehnološka promjena koja je znatno pridonijela digitalnom širenju i podatkovnom zaokretu bila je razvoj pametnih telefona (engl. *smartphone*) i drugih mobilnih uređaja, uključujući tablet računala (engl. *tablet computer*), kao i njihova šira dostupnost krajem prvog desetljeća 21. stoljeća. Time se primjena tehnologije u obrazovanju širi na mobilno učenje (engl. *mobile learning*, *m-learning*), obilježenom učenjem u pokretu, odnosno većom prostornom i vremenskom fleksibilnošću te mogućnošću uključivanja konteksta uporabe uređaja, poput lokacije i vremena [47].

Sve navedene tehnološke promjene dovele su do sustavnog bilježenja i pohrane većeg broja digitalnih zapisa o aktivnostima učenja. Holmes i Tuomi [29] tako povezuju razvoj istraživačkog područja primjene umjetne inteligencije u obrazovanju s ubrzanim rastom područja rudarenja obrazovnih podataka (engl. *Educational Data Mining*, EDM) [48] i analitike učenja (engl. *learning analytics*) [49], čiji doprinosi sve češće postaju relevantni ne samo za istraživanje, nego i za obrazovnu politiku i praksu. Također, razvoj računarstva u oblaku dodatno je učvrstio infrastrukturnu osnovu za pohranu, obradu i analizu obrazovnih podataka [50].

Ovakav podatkovni zaokret utjecao je na obrazovanje na najmanje tri razine [51–53]. Prvo, omogućio je preciznije praćenje učenja i pravodobniju povratnu informaciju učenicima. Drugo, nastavnicima i institucijama pružio je nove uvide za donošenje odluka o podršci, prilagodbi sadržaja i prepoznavanju rizičnih obrazaca ponašanja. Treće, pridonio je razvoju ideje skalabilne personalizacije, odnosno mogućnosti da se individualizirana podrška pruža većem broju učenika nego što je to izvedivo isključivo ljudskim resursima.

2.4 Generativna i multimodalna faza

Početak 2020-ih obilježen je naglim porastom vidljivosti i dostupnosti alata umjetne inteligencije u obrazovanju, ponajprije zbog tehnološkog napretka u obradi prirodnog jezika i računalnog vida te razvoja velikih jezičnih modela i multimodalnih sustava [3, 54]. Veliki jezični modeli omogućili su naprednu obradu i generiranje prirodnoga jezika, generativna umjetna inteligencija proširila je te mogućnosti na stvaranje novoga sadržaja, a multimodalni sustavi dodatno su omogućili povezivanje i obradu različitog sadržaja, poput teksta, slike, zvuka i videa, što je otvorilo nove

mogućnosti njihove primjene u obrazovanju [55–57]. Time se umjetna inteligencija, iz do tada često pozadinske analitičke infrastrukture, premješta u samo središte svakodnevnih obrazovnih aktivnosti, uključujući pisanje, sažimanje, objašnjavanje, generiranje ideja, programiranje, pripremu nastavnih materijala i ostalo. Pritom je značajno da takvi sustavi omogućuju interakciju putem prirodnog jezika, što povećava vjerojatnost “spontanog” ulaska tehnologije u svakodnevnu obrazovnu praksu. Tako, za razliku od obrazovnih tehnologija koje se uvode planski, kroz postupke odabira i nabave, alati bazirani na generativnoj umjetnoj inteligenciji u obrazovne institucije često “ulaze” mimo tih procesa, kroz neplaniranu uporabu učenika i nastavnika te kroz brzu integraciju značajki baziranih na umjetnoj inteligenciji u već postojeće digitalne alate.

Istodobno, recentne analize i kritički osvrti na upotrebu generativne umjetne inteligencije u obrazovanju upozoravaju na potrebu razboritog razlikovanja tehničkih mogućnosti i obrazovne vrijednosti korištenih alata. Primjerice, Selwyn [14] naglašava da se rasprave o umjetnoj inteligenciji u obrazovanju trebaju usmjeriti na matematičke i statističke granice umjetne inteligencije u modeliranju složenih društvenih konteksta, odnosno pokušaja da se društveni odnosi, interakcije i okolnosti u kojima se odvija učenje prikažu u obliku podataka i računalnih modela, te rizike pretjeranih obećanja i problematike “AI kazališta” (engl. *AI theatre*), odnosno prikazivanja umjetne inteligencije kao naprednije, autonomnije ili korisnije nego što stvarno jest. U tom smislu, generativna i multimodalna faza donosi pomak u dostupnosti i interakciji [58], ali istodobno otvara i nova pitanja o odgovornom uvođenju, pouzdanosti, pristranosti, privatnosti [59] i dugoročnim posljedicama reorganizacije obrazovanja prema onome što je strojno čitljivo i podatkovno upravljivo [60].

3. Generativna umjetna inteligencija u obrazovanju u tehničkom području

U obrazovanju unutar tehničkog područja, u aktualnoj generativnoj i multimodalnoj fazi razvoja umjetne inteligencije, očituje se njezina dvostruka uloga. S jedne se strane sve jasnije prepoznaje potreba da se umjetnoj inteligenciji posveti više prostora kao sadržaju učenja, dok se s druge strane naglašava potreba za sustavnijim korištenjem njezina potencijala kao alata za učenje i poučavanje.

Primjerice, u dosadašnjem pristupu poučavanju programiranja naglasak je bio na postupnom usvajanju sintakse, struktura podataka i algoritamskog razmišljanja kroz samostalno rješavanje zadataka, uz podršku nastavnika i postupno uvođenje složenijih obrazaca. Studenti računarstva danas ne uče samo o programskim paradigmatama, nego istodobno koriste alate umjetne inteligencije za modeliranje, generiranje koda, pronalaženje i ispravljanje pogrešaka, pronalaženje objašnjenja i primjera, analizu i

izradu dokumentacije i drugo [61–64]. Štoviše, istraživanja o korištenju Copilota kod programera početnika ukazuju na dinamiku rada sličnu tehnici programiranja u paru (engl. *pair programming*) u kojoj studenti često iteriraju kroz prijedloge alata i razvijaju nove obrasce samoregulacije (npr. provjera, uspoređivanje rješenja, testiranje) [65, 66]. Pritom se ističu i rizici prevelikog oslanjanja na alat kada se odgovor čini uvjerljivim. U širem smislu, ovakvi alati postaju dio svakodnevne infrastrukture rada u računarstvu, pa se poučavanje sve više mora baviti ne samo time kako napisati kod, nego i time kako procijeniti generirani kod, odnosno je li takav kod funkcionalan, učinkovit, čitljiv i usklađen sa zadatkom kojeg treba riješiti [8, 67].

Slično tomu, studenti u polju grafičke tehnologije ne usvajaju samo znanja o grafičkoj pripremi i produkcijskim procesima, vizualnoj komunikaciji i digitalnoj obradi slike, nego se istodobno služe alatima umjetne inteligencije za automatizaciju pojedinih faza u procesu grafičke produkcije te izradu i prilagodbu grafičke dokumentacije [68]. Istodobno se naglašava da takvi alati ne zamjenjuju potrebu za stručnom prosudbom, nego je dodatno ističu [68, 69]. Odnosno, studenti moraju moći procijeniti primjerenost generiranog sadržaja, njegovu tehničku izvedivost, usklađenost s projektnim zadatkom te pitanja autorstva, izvornosti i etičke prihvatljivosti [70].

U tom se kontekstu pojavljuju i kompetencije koje ranije nisu bile eksplicitno adresirane. Neke od njih su oblikovanje upita (engl. *prompt engineering*) kao specifičan način artikulacije problema i zahtjeva [3, 71, 72], interpretacija i evaluacija izlaza generiranog alatom baziranog na umjetnoj inteligenciji [73, 74] te metodično provjeravanje rješenja (npr. izrada testova, analiza rubnih slučajeva, provjera složenosti i sigurnosnih implikacija) [65, 75]. Sve navedeno odražava potrebu da se uporaba generativne umjetne inteligencije usmjeri prema odgovornom i kritičkom djelovanju, a ne prema nekritičkom preuzimanju sadržaja i rješenja [3, 8]. U računarstvu se to dodatno pojačava činjenicom da nedovoljno optimiziran ili neispravan kod može izgledati ispravno, pa se sustavno testiranje i kritička procjena nameću kao ključna vještina [14]. Digitalna pismenost u tehničkim, ali i drugim disciplinama, tako zahtjeva i razumijevanje osnovnih načela rada velikih jezičnih modela te razumijevanje ograničenja, primjerice da generativni sustavi proizvode vjerojatne izlaze, a ne jamčeno točne odgovore.

3.1 Istraživanje o navikama i stavovima studenata o umjetnoj inteligenciji

Kako bi se dublje istražile navike i stavovi studenata o primjeni alata umjetne inteligencije u visokom obrazovanju u Hrvatskoj, u svibnju 2025. godine provedeno je anketno istraživanje među studentima nekoliko visokih učilišta u Zagrebu. Provedeno istraživanje odobrilo je Etičko povjerenstvo Tehničkog veleučilišta u Zagrebu pod ur. br. 251-375-01-25-2 te su svi ispitanici bili upoznati s ciljevima istraživanja

te načinima prikupljanja, pohrane i obrade podataka. Sudjelovanje u istraživanju bilo je dobrovoljno i anonimno te su ispitanici mogli odustati u bilo kojem trenu tijekom provedbe istraživanja. Podaci su prikupljeni pomoću alata LimeSurvey, a studenti su upitnik uglavnom ispunjavali na fizičkim lokacijama unutar matične obrazovne ustanove, neposredno prije početka ili kraja redovne nastave. U nastavku su prikazani kontekst i rezultati dijela spomenutog istraživanja provedenoga na dvjema visokoo-brazovnim institucijama iz tehničkog područja, Tehničkom veleučilištu u Zagrebu (TVZ) i Sveučilištu u Zagrebu Grafičkom fakultetu (GRF). Detaljni rezultati cjelokupnog istraživanja i predložak anketnog upitnika dostupni su na zahtjev.

3.1.1 Demografska statistika ispitanika

U istraživanju provedenom na TVZ-u i GRF-u sudjelovalo je ukupno 520 studenata, od čega 391 student TVZ-a i 129 studenata GRF-a. U uzorku TVZ-a dominantno su bili zastupljeni studenti muškog spola (76,47 %), uz 19,44 % studentica i 4,09 % ispitanika koji se nisu izjasnili o spolu. S druge strane, uzorak GRF-a karakterizira dominantna zastupljenost studentica (82,17 %), dok su studenti činili 17,83 % ispitanika.

U oba su uzorka bili zastupljeni studenti različitih godina studija, pri čemu su u većem udjelu bili zastupljeni studenti prijediplomskih studija. Na TVZ-u je najveći udio ispitanika dolazio sa stručnog prijediplomskog studija Računarstvo, smjer Programsko inženjerstvo (28,13 %). Slijede studenti stručnog prijediplomskog studija Informatika, smjer Informatički dizajn (11,76 %), stručnog prijediplomskog studija Informatika, smjer Organizacija i informatizacija ureda (11,25 %) te stručnog prijediplomskog studija Informatika, smjer Elektroničko poslovanje (8,18 %). Među zastupljenijim skupinama bili su i studenti stručnog prijediplomskog studija Graditeljstvo, smjer Visokogradnja (7,16 %) i smjer Građevinsko poduzetništvo (5,63 %), kao i studenti stručnog prijediplomskog studija Računarstvo, smjer Inženjerstvo računalnih sustava i mreža (4,35 %). Ostali studijski smjerovi bili su zastupljeni u manjim udjelima, uključujući elektrotehniku, mehatroniku, strojarstvo i pojedine diplomske studije. Na GRF-u najzastupljeniji su bili studenti prijediplomskog sveučilišnog studija Dizajn grafičkih proizvoda (55,04 %), zatim studenti prijediplomskog sveučilišnog studija Tehničko-tehnološki smjer (26,36 %), studenti diplomskog sveučilišnog studija Dizajn grafičkih proizvoda (13,18 %) te studenti diplomskog sveučilišnog studija Tehničko-tehnološki smjer (5,43 %).

3.1.2 Rezultati

Rezultati pokazuju da studenti obje ustanove vlastitu informatičku pismenost procjenjuju pretežito visokom. Na TVZ-u 85,17 % ispitanika smatra da posjeduje visoku razinu informatičke pismenosti, 12,53 % srednju, a 2,30 % nisku, dok je na

GRF-u 79,07 % studenata procijenilo svoju informatičku pismenost visokom, 19,38 % srednjom, a 1,55 % niskom. Uočena je razlika u rezultatima o samoprocjeni formalnoj izloženosti temama umjetne inteligencije između studenata TVZ-a i GRF-a. Na TVZ-u je tek 27,37 % studenata navelo da je slušalo teme ili kolegije iz područja umjetne inteligencije, dok je na GRF-u taj udio gotovo upola veći i iznosi 50,39 %. Nadalje, 69,76 % studenata GRF-a djelomično se ili u potpunosti slaže s tvrdnjom da može razumjeti alate i resurse povezane s umjetnom inteligencijom, dok je na TVZ-u taj udio nešto niži i iznosi 58,06 %.

Kada je riječ o učestalosti korištenja alata umjetne inteligencije, na obje ustanove prevladava učestala upotreba. Na TVZ-u 31,71 % studenata koristi alate umjetne inteligencije više puta tjedno, 21,99 % svakodnevno, a 7,42 % nekoliko puta dnevno, dok ih 16,88 % koristi više puta mjesečno i 16,37 % povremeno. Na GRF-u najviše studenata također navodi korištenje više puta tjedno (26,36 %), zatim više puta mjesečno (21,71 %) i povremeno (20,93 %), dok 15,50 % studenata alate umjetne inteligencije koristi svakodnevno, a 4,65 % nekoliko puta dnevno. Usporedno promatrano, studenti TVZ-a iskazuju nešto intenzivniji obrazac uporabe alata umjetne inteligencije nego studenti GRF-a.

Odgovori na pitanje o svrsi korištenja alata umjetne inteligencije upućuju na to da je pretraživanje informacija njihova najčešća namjena, što navodi 78,26 % ispitanih studenata TVZ-a i 83,72 % studenata GRF-a. Na TVZ-u se uz to posebno ističe i upotreba u svrhu kodiranja, odnosno programiranja (63,94 %), zatim obrade i izrade teksta (37,34 %) te statističke obrade podataka (24,30 %), dok su upotreba u svrhu obrade i izrade slika zastupljene u 19,69 % odgovora. Na GRF-u, nakon pretraživanja informacija (83,72 %), najčešće se navodi upotreba u svrhu obrade i izrade teksta (41,86 %), kodiranja i programiranja (24,81 %), obrade i izrade slika (21,71 %) te upotreba u svrhu statističke obrade podataka (17,83 %). Preciznije, na obje ustanove ChatGPT je najčešće korišten alat umjetne inteligencije. Njegovu uporabu navodi 92,84 % studenata TVZ-a i 95,35 % studenata GRF-a. Na TVZ-u se, uz ChatGPT, spominju i DeepSeek (24,04 %), Microsoft Copilot (15,09 %) i Google Gemini (12,53 %), dok su na GRF-u, nakon ChatGPT-a, najzastupljeniji Google Gemini (15,50 %), DeepSeek (10,08 %) i Microsoft Copilot (6,20 %). Budući da su u navedenom pitanju mogući odgovori bili unaprijed ponuđeni, važno je napomenuti da su ispitanici imali mogućnost upisati i vlastiti odgovor te su studenti TVZ-a dodatno istaknuli da koriste Perplexity, Claude, GitHub Copilot, Cursor i NotebookLM, dok studenti GRF-a navode Perplexity, Midjourney, Grammarly i Mistral AI.

Kada se uporaba alata umjetne inteligencije promatra specifično u odnosu na studiranje, na obje ustanove studenti najviše ističu primjenu za pomoć pri učenju i za pretraživanje informacija. Na TVZ-u 75,45 % ispitanih studenata koristi alate umjetne inteligencije za pomoć pri učenju i pripremi za provjere znanja, a 75,70 % za pretraživanje informacija vezanih uz vježbe, seminare, laboratorijske zadatke i pripreme.

Uz to, 28,39 % studenata navodi uporabu alata umjetne inteligencije za kreativne projekte vezane uz studij. Na GRF-u 69,77 % ispitanih studenata koristi te alate za pretraživanje informacija, 57,36 % za pomoć pri učenju, a 36,43 % za kreativne projekte povezane sa studijem. Pritom je udio studenata koji navode da ne koriste alate umjetne inteligencije u studijskom kontekstu relativno nizak i iznosi 7,16 % na TVZ-u te 6,20 % na GRF-u.

U odgovorima na pitanje na koji bi način nastavnici trebali spriječiti zlouporabu ChatGPT-a i sličnih alata umjetne inteligencije ispitani studenti najviše podupiru pristup koji ne počiva na zabrani, nego na jasnijem pedagoškom i etičkom usmjeravanju. Na TVZ-u 70,33 % studenata smatra da bi trebalo dopustiti korištenje umjetne inteligencije uz okvire i smjernice u skladu s akademskom čestitošću, a na GRF-u njih 72,09 %. Nasuprot tomu, zabranu korištenja umjetne inteligencije podržava tek manji dio studenata, odnosno 4,09 % ispitanika s TVZ-a i 8,53 % ispitanika s GRF-a. Osim potrebe za jasnijim pravilima, studenti u velikoj mjeri ističu i važnost drukčijeg oblikovanja nastavnih aktivnosti. 46,04 % ispitanika s TVZ-a i 51,94 % ispitanika s GRF-a smatra da bi nastavnici trebali kreirati aktivnosti i zadatke koji zahtijevaju aktivan angažman, aktivno razmišljanje i pristup utemeljen na rješavanju problema. Uz navedene unaprijed definirane odgovore koji su bili ponuđeni na spomenuto pitanje, pojedini odgovori iz slobodnog unosa dodatno potvrđuju da studenti pitanje zlouporabe ne promatraju isključivo kao pitanje discipliniranja, nego ga povezuju i s potrebom prilagodbe nastave suvremenim uvjetima. U tim se odgovorima, osobito na TVZ-u, pojavljuju stavovi da je zlouporabu teško ili nemoguće u potpunosti spriječiti, da bi zadatke trebalo prilagoditi tako da umjetna inteligencija može pomoći, ali ne i riješiti cijeli zadatak te da bi studente trebalo poučavati kako se tim alatima koristiti na koristan i odgovoran način. Na GRF-u među otvorenim se odgovorima također pojavljuje stav da uporabu umjetne inteligencije treba dopustiti jer će ona biti važna i u budućem profesionalnom radu, ali uz naglasak na razumijevanju njezine uloge kao alata pomoći, a ne zamjene za vlastiti rad.

Nadalje, studenti nastavničko poticanje na upotrebu alata umjetne inteligencije uglavnom ne doživljavaju kao izrazito učestalo. Na TVZ-u 22,76 % studenata navodi da ih nastavnici nikada ne potiču na korištenje alata, 40,15 % da se to događa rijetko, 32,99 % ponekad, a tek 4,09 % vrlo često. Na GRF-u raspodjela je slična. 13,95 % studenata navodi da ih nastavnici nikada ne potiču, 47,29 % da se to događa rijetko, 34,11 % ponekad, a 4,65 % vrlo često. Slično tomu, studenti većinski ne percipiraju stav svojih nastavnika prema korištenju alata baziranih na umjetnoj inteligenciji u nastavne svrhe kao izrazito pozitivan ili izrazito negativan, nego ponajprije kao neutralan. Na TVZ-u neutralan stav većine nastavnika prepoznaje 38,87 % studenata, pozitivan 18,67 %, negativan 21,48 %, dok 20,97 % ne može procijeniti stav svojih nastavnika. Na GRF-u neutralan stav navodi 34,88 % ispitanika, pozitivan i negativan po 19,38 %, a 26,36 % studenata ne može procijeniti kakav stav većina njihovih nastavnika zauzima.

Posebno valja istaknuti da među ispitanim studentima prevladava namjera daljnjeg korištenja alata baziranih na umjetnoj inteligenciji. Na TVZ-u 57,54 % ispitanika u potpunosti se slaže s tvrdnjom da će u budućnosti nastaviti koristiti takve alate, dok se dodatnih 21,74 % s tom tvrdnjom djelomično slaže. Sličan obrazac vidljiv je i na GRF-u, gdje se 62,79 % ispitanika u potpunosti slaže s tvrdnjom da će u budućnosti nastaviti koristiti alate utemeljene na umjetnoj inteligenciji, dok se dodatnih 20,93 % s tom tvrdnjom djelomično slaže.

3.2 Diskusija

Ukupno gledano, rezultati istraživanja o navikama i stavovima studenata TVZ-a i GRF-a upućuju na to da studenti umjetnu inteligenciju već integriraju u svoju svakodnevnu akademsku praksu, ali na načine koji odražavaju specifičnosti njihovih studijskih područja. Takav obrazac u skladu je s recentnim istraživanjima koja pokazuju da se u tehničkom području u polju računarstva umjetna inteligencija češće koristi za programiranje, analizu i rješavanje problema [64], dok se u grafičkoj tehnologiji snažnije povezuje s razradom koncepta, generiranjem i obradom vizualnog sadržaja te podrškom kreativnom radu [68].

Rezultati sugeriraju da studenti ne zagovaraju restriktivan pristup umjetnoj inteligenciji, nego očekuju promišljenije pedagoško usmjeravanje njezine uporabe što se podudara s ostalim istraživanjima koja pokazuju da studenti u visokom obrazovanju uglavnom ne podržavaju zabranu generativne umjetne inteligencije, nego traže jasnije politike, transparente okvire dopuštene uporabe i veću uključenost nastavnika u oblikovanje tih pravila. Primjerice, Johnston i sur. [76] u svom istraživanju ističu da studenti traže jasne institucionalne smjernice i smatraju da takve tehnologije ne bi trebalo zabranjivati, nego pedagoški regulirati, dok sustavni pregled Wu i sur. [77] pokazuje da se u literaturi dosljedno ističu potreba za etičkim smjernicama, institucionalnim pravilima i odgovornom integracijom generativne umjetne inteligencije u nastavu.

U tom se svjetlu i rezultati ovoga istraživanja mogu tumačiti kao pokazatelj da studenti umjetnu inteligenciju doživljavaju kao postojeći i budući dio akademskog okruženja, ali istodobno očekuju da se njezina uporaba jasnije didaktički usmjeri. Posebno je važno istaknuti da studenti, umjesto isključivo represivnih mjera, podupiru oblikovanje zadataka koji zahtijevaju aktivno promišljanje, razumijevanje i rješavanje problema. Takva očekivanja odgovaraju i rezultatima već spomenutih istraživanja [76, 77] prema kojima studenti generativnu umjetnu inteligenciju vide kao alat podrške učenju a ne kao zamjenu za vlastiti rad, pri čemu se upravo kvaliteta dizajna nastave i zadataka pokazuje ključnom za smanjivanje površne ili neetične uporabe.

Istodobno, rezultati prema kojima je poticanje uporabe alata baziranih na umjetnoj inteligenciji od strane nastavnika još uvijek pretežito povremeno i ograničeno, a stu-

dentska percepcija nastavnčkog stava često neutralna ili neodređena, upućuju na to da je institucionalna i pedagoška integracija umjetne inteligencije još uvijek u prijelaznoj fazi. To je u skladu i sa sustavnim pregledom Nikolic i sur. [78], koji pokazuje da su stavovi nastavnika prema umjetnoj inteligenciji u visokom obrazovanju često obilježeni istodobnim prepoznavanjem koristi ali i izraženom nesigurnošću u pogledu pouzdane, etične i pedagoški opravdane primjene. Slične tvrdnje vidljive su i ostalim istraživanjima o iskustvima nastavnika, koja pokazuju da generativna umjetna inteligencija povlači znatnu dozu neizvjesnosti i netransparentnosti, osobito kada je riječ o vrednovanju, akademskoj čestitosti i redefiniranju uloge nastavnika [79, 80].

Naposljetku, izražena namjera studenata da će i ubuduće koristiti alate bazirane na umjetnoj inteligenciji dodatno potvrđuje da je riječ o tehnologiji koja je već uključena u njihove obrasce učenja i rada. To je također u skladu s recentnim istraživanjima koja pokazuju pretežito pozitivne ili pragmatično pozitivne studentske stavove prema generativnoj umjetnoj inteligenciji, osobito kada je ona povezana s učinkovitošću, dostupnošću i budućom profesionalnom relevantnošću [81]. U tom smislu, rezultati ovoga istraživanja sugeriraju da glavni izazov za obrazovanje više nije pitanje treba li umjetnu inteligenciju dopustiti, nego kako osmisliti jasne, etički utemeljene i pedagoški smislene modele njezine uporabe.

U uvjetima u kojima generativni alati mogu u vrlo kratkom vremenu proizvesti cjelovito rješenje, veću pozornost potrebno je usmjeriti na oblikovanje ishoda učenja koji izravno obuhvaćaju razumijevanje i dokumentiranje procesa izrade rješenja, a ne samo njegov konačni oblik. To uključuje sposobnost obrazlaganja donesenih odluka, argumentiranja izbora (npr. algoritma), tumačenja pogrešaka te kritičkog razmatranja kompromisa između točnosti, učinkovitosti, čitljivosti i sigurnosti, kako bi se u vrednovanju pouzdano razlikovalo stvarno razumijevanje od mehaničkog preuzimanja generiranog rezultata. Kada je završni proizvod (npr. programski kod, izvještaj ili esej) moguće brzo generirati uz pomoć alata, postaje znatno teže pouzdano utvrditi koliki je stvarni individualni doprinos studenta i na kojoj je razini njegovo razumijevanje [82, 83]. Stoga UNESCO naglašava potrebu da se metode provjere i politike vrednovanja prilagode tako da smanjuju poticaje za neprimjerenu uporabu, ali istodobno omogućuju pedagoški smislenu i odgovorno korištenje generativne umjetne inteligencije [3].

Kao odgovor na navedene izazove, preporuka je kombinirati više metoda vrednovanja. To uključuje strukturiranje zadatka koji traže objašnjavanje i obranu rješenja, zadatke s varijantama i parametrima koje je teško mehanički "prepisati" bez stvarnog razumijevanja, vrednovanje procesnih tragova rada, kao što su verzioniranje koda ili refleksije o postupku rješavanja te naglasak na refaktoriranju, ispravljanju pogrešaka i kritičkoj evaluaciji već postojećih rješenja. Možemo reći da pojava generativne umjetne inteligencije donosi i potencijalno izrazito pozitivnu transformaciju obrazovanja jer usmjerava pozornost na potrebu stavljanja većeg naglaska na proces učenja i poučavanja, uz odmak od isključivog vrednovanja konačnih rezultata.

4. Zaključak

Zaključno, ovaj rad pokazuje da primjena alata umjetne inteligencije u obrazovanju nije tek suvremeni trend, nego istraživačko područje koje se razvija od druge polovice 20. stoljeća. U tehničkom području umjetna inteligencija danas je istodobno i sadržaj učenja i alat za učenje i poučavanje. Rezultati istraživanja provedenog među studentima Tehničkog veleučilišta u Zagrebu i Sveučilišta u Zagrebu Grafičkog fakulteta potvrđuju njezinu integraciju u akademsku praksu te sugeriraju potrebu za transparentnim i strukturiranim pravilima uporabe, promišljenijim pedagoškim usmjeravanjem i prilagodbom vrednovanja, kako bi se potencijal umjetne inteligencije koristio odgovorno, etički i obrazovno smisleno.

5. Literatura

- [1] Holmes, W.; Bialik, M., Fadel, C.: *Artificial Intelligence in Education. Promise and Implications for Teaching and Learning.*, 978-1794293700, (2019)
- [2] Maslej, N.; Fattorini, L., Perrault, R., Parli, V., Reuel, A., Brynjolfsson, E., Etchemendy, J., Ligett, K., Lyons, T., Manyika, J., Niebles, J.C., Shoham, Y., Wald, R., Clark, J.: *Artificial Intelligence Index Report 2024*, (2024)
- [3] Miao, F.; Holmes, W.: UNESCO: *Guidance for generative AI in education and research*, UNESCO, 978-92-3-100612-8, (2023)
- [4] Holmes, W.; Tuomi, I.: State of the art and practice in AI in education, *European Journal of Education*, **57** (2022) 4, 542-570, <https://doi.org/10.1111/ejed.12533>
- [5] UNESCO: *Recommendation on the Ethics of Artificial Intelligence*, UNESCO, (2021)
- [6] World Economic Forum: *The Future of Jobs Report 2023*, 978-2-940631-96-4, (2023)
- [7] OECD: *OECD Employment Outlook 2023: Artificial Intelligence and the Labour Market*, Paris, (2023)
- [8] Selwyn, N.: The future of AI and education: Some cautionary notes, *European Journal of Education*, **57** (2022) 4, 620-631, <https://doi.org/10.1111/ejed.12532>
- [9] Zhai, X.; Chu, X., Chai, C.S., Jong, M.S.Y., Istenic, A., Spector, M., Liu, J.-B., Yuan, J., Li, Y.: A Review of Artificial Intelligence (AI) in Education from 2010 to 2020, *Complexity*, **2021** (2021) 1, 8812542, <https://doi.org/10.1155/2021/8812542>
- [10] Tatnall, A. ed.: *Artificial Intelligence in Education*, U *Encyclopedia of Education and Information Technologies*, Springer International Publishing, 978-3-319-60013-0, Cham, (2019), 1-16
- [11] Hariyanto; Kristianingsih, F.X.D., Maharani, R.: Artificial intelligence in adaptive education: a systematic review of techniques for personalized learning, *Discover Education*, **4** (2025) 1, 458, <https://doi.org/10.1007/s44217-025-00908-6>
- [12] Wang, S.; Wang, F., Zhu, Z., Wang, J., Tran, T., Du, Z.: Artificial intelligence in education: A systematic literature review, *Expert Systems with Applications*, **252** (2024) 124167, <https://doi.org/10.1016/j.eswa.2024.124167>

- [13] Menon, D.; Shilpa, K.: “Chatting with ChatGPT”: Analyzing the factors influencing users’ intention to Use the Open AI’s ChatGPT using the UTAUT model, *Heliyon*, **9** (2023) 11, e20962, <https://doi.org/10.1016/j.heliyon.2023.e20962>
- [14] Selwyn, N.: On the Limits of Artificial Intelligence (AI) in Education, *Nordisk tidsskrift for pedagogikk og kritikk*, **10** (2024) <https://doi.org/10.23865/ntpk.v10.6062>
- [15] Siddarth, D.; Acemoglu, D., Allen, D., Crawford, K., Evans, J., Jordan, M., Weyl, E.G.: *How AI Fails Us*, (2022)
- [16] Reich, J.; Dukes, J.: The future of education technology after the arrival of ChatGPT, *Phi Delta Kappan*, **107** (2025) 3-4, 19-23, <https://doi.org/10.1177/00317217251405516>
- [17] Zalta, E.N.; Nodelman, U. eds.: Aristotle’s Logic, U *The Stanford Encyclopedia of Philosophy*, Metaphysics Research Lab, Stanford University, (2022)
- [18] Khosrow-Pour Mehdi, D.B.A. ed.: History of Artificial Intelligence Before Computers, U *Encyclopedia of Information Science and Technology, Second Edition*, IGI Global Scientific Publishing, 9781605660264, Hershey, PA, USA, (2009), 1763-1768
- [19] McCorduck, P.: *Machines Who Think: A Personal Inquiry into the History and Prospects of Artificial Intelligence*, (1979)
- [20] Newell, A.; Simon, H.A.: Computer science as empirical inquiry: symbols and search, *Commun. ACM*, **19** (1976) 3, 113-126, <https://doi.org/10.1145/360018.360022>
- [21] Turing, A.: Computing machinery and intelligence, *Mind*, **59** (1950) 236, 433-460, <https://doi.org/10.1093/mind/LIX.236.433>
- [22] McCarthy, J.; Minsky, M.L., Rochester, N., Shannon, C.E.: A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955, *AI Magazine*, **27** (2006) 4, 12, <https://doi.org/10.1609/aimag.v27i4.1904>
- [23] Collins, C.; Dennehy, D., Conboy, K., Mikalef, P.: Artificial intelligence in information systems research: A systematic literature review and research agenda, *International Journal of Information Management*, **60** (2021) 102383, <https://doi.org/10.1016/j.ijinfomgt.2021.102383>
- [24] Zalta, E.N.; Nodelman, U. eds.: Artificial Intelligence, U *The Stanford Encyclopedia of Philosophy*, Metaphysics Research Lab, Stanford University, (2026)
- [25] Brachman, R.J.: The basics of knowledge representation and reasoning, *AT&T Technical Journal*, **67** (1988) 1, 7-24, <https://doi.org/10.1002/j.1538-7305.1988.tb00230.x>
- [26] Jordan, M.I.; Mitchell, T.M.: Machine learning: Trends, perspectives, and prospects, *Science*, **349** (2015) 6245, 255-260, <https://doi.org/10.1126/science.aaa8415>
- [27] Sengar, S.S.; Hasan, A. B., Kumar, S., Carroll, F.: Generative artificial intelligence: a systematic review and applications, *Multimedia Tools and Applications*, **84** (2025) 21, 23661–23700, <https://doi.org/10.1007/s11042-024-20016-1>
- [28] Cao, Y.; Li, S., Liu, Y., Yan, Z., Dai, Y., Yu, P., Sun, L.: A Survey of AI-Generated Content (AIGC), *ACM Comput. Surv.*, **57** (2025) 5, <https://doi.org/10.1145/3704262>
- [29] Holmes, W.; Tuomi, I.: State of the art and practice in AI in education, *European Journal of Education*, **57** (2022) 4, 542-570, <https://doi.org/10.1111/ejed.12533>

- [30] Skinner, B.F.: Teaching Machines, *The Review of Economics and Statistics*, **42** (1960) 3, 189-191, <https://doi.org/10.2307/1926170>
- [31] Carbonell, J.R.: AI in CAI: An Artificial-Intelligence Approach to Computer-Assisted Instruction, *IEEE Transactions on Man-Machine Systems*, **11** (1970) 4, 190-202, <https://doi.org/10.1109/TMMS.1970.299942>
- [32] Pask, G.: SAKI: Twenty-five years of adaptive training into the microprocessor era, *International Journal of Man-Machine Studies*, **17** (1982) 1, 69-74, [https://doi.org/10.1016/S0020-7373\(82\)80009-6](https://doi.org/10.1016/S0020-7373(82)80009-6)
- [33] Doroudi, S.: The Intertwined Histories of Artificial Intelligence and Education, *International Journal of Artificial Intelligence in Education*, **33** (2023) 4, 885-928, <https://doi.org/10.1007/s40593-022-00313-2>
- [34] Carbonell, J.R.: AI in CAI: An Artificial-Intelligence Approach to Computer-Assisted Instruction, *IEEE Transactions on Man-Machine Systems*, **11** (1970) 4, 190-202, 1 <https://doi.org/10.1109/TMMS.1970.299942>
- [35] Self, J.: The Birth of IJAIED, *International Journal of Artificial Intelligence in Education*, **26** (2016) 1, 4-12, <https://doi.org/10.1007/s40593-015-0040-5>
- [36] Dede, C.: *Intelligent Computer-Assisted Instruction: A Review and Assessment of ICAI Research and Its Potential for Education*, (1985)
- [37] Lesgold, A.: Intelligent Tutoring Systems, U *Encyclopedia of Cognitive Science*, 9780470018866, (2006)
- [38] Kulik, J.A.; Fletcher, J.D.: Effectiveness of Intelligent Tutoring Systems: A Meta-Analytic Review, *Review of Educational Research*, **86** (2016) 1, 42-78, <https://doi.org/10.3102/0034654315581420>
- [39] Kruse Otto and Rapp, C. and A.C.M. and B.K. and C.E. and D.A. and S.A. ed.: Learning Management Systems (LMSs), U *Digital Writing Technologies in Higher Education : Theory, Research, and Practice*, Springer International Publishing, 978-3-031-36033-6, Cham, (2023), 173-182
- [40] Brusilovsky, P.; Peylo, C.: Adaptive and Intelligent Web-based Educational Systems, *International Journal of Artificial Intelligence in Education*, **13** (2003) 2-4, 159-172
- [41] Casamayor, A.; Amandi, A., Campo, M.: Intelligent assistance for teachers in collaborative e-learning environments, *Computers & Education*, **53** (2009) 4, 1147-1154, <https://doi.org/10.1016/j.compedu.2009.05.025>
- [42] Kumar, R.; Kim, J.: Special Issue on Intelligent Support for Learning in Groups, *International Journal of Artificial Intelligence in Education*, **24** (2014) 1, 1-7, <https://doi.org/10.1007/s40593-013-0013-5>
- [43] Mahajan, R.; Gupta, P., Singh, T.: Massive Open Online Courses: Concept and Implications, *Indian Pediatrics*, **56** (2019) 6, 489-495, <https://doi.org/10.1007/s13312-019-1575-6>
- [44] Baturay, M.H.: An Overview of the World of MOOCs, *Procedia - Social and Behavioral Sciences*, **174** (2015) 427-433, <https://doi.org/10.1016/j.sbspro.2015.01.685>

- [45] Fauvel, S.; Yu, H., Miao, C., Cui, L., Song, H., Zhang, L., Li, X., Leung, C.: Artificial Intelligence Powered MOOCs: A Brief Survey, *2018 IEEE International Conference on Agents (ICA)*, 56-61, IEEE, (2018)
- [46] Papadimitriou, A.: Adaptive and Intelligent MOOCs: How they Contribute to the Improvement of the MOOCs' Effectiveness, *International Journal of Research in E-learning*, **9** (2023) 1-21, <https://doi.org/10.31261/IJREL.2023.9.1.01>
- [47] Vallejo-Correa, P.; Monsalve-Pulido, J., Tabares-Betancur, M.: A systematic mapping review of context-aware analysis and its approach to mobile learning and ubiquitous learning processes, *Computer Science Review*, **39** (2021) 100335, <https://doi.org/10.1016/j.cosrev.2020.100335>
- [48] Romero, C.; Ventura, S.: Educational Data Mining: A Review of the State of the Art, *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, **40** (2010) 601–618, <https://doi.org/10.1109/TSMCC.2010.2053532>
- [49] Mougiakou Sofia and Vinatsella, D. and S.D. and P.Z. and G.M. and I.D.: Learning Analytics, *U Educational Data Analytics for Teachers and School Leaders*, Springer International Publishing, 978-3-031-15266-5, Cham, (2023), 131-188
- [50] González-Martínez, J.A.; Bote-Lorenzo, M.L., Gómez-Sánchez, E., Cano-Parra, R.: Cloud computing and education: A state-of-the-art survey, *Computers & Education*, **80** (2015) 132–151, <https://doi.org/10.1016/j.compedu.2014.08.017>
- [51] Romero, C.; Ventura, S.: Educational data mining and learning analytics: An updated survey, *WIREs Data Mining and Knowledge Discovery*, **10** (2020) 3, e1355, <https://doi.org/10.1002/widm.1355>
- [52] Cerezo, R.; Lara, J.-A., Azevedo, R., Romero, C.: Reviewing the differences between learning analytics and educational data mining: Towards educational data science, *Computers in Human Behavior*, **154** (2024) 108155, <https://doi.org/10.1016/j.chb.2024.108155>
- [53] Chen, M.-S.; Hsu, T.-C., Tu, Y.-F.: The use of learning analytics and educational data mining to analyze teachers' teaching in online environments: a systematic literature review, *Interactive Learning Environments*, **33** (2025) 5, 3317-3332, <https://doi.org/10.1080/10494820.2024.2443070>
- [54] OpenAI; Achiam, J., Adler, S., Agarwal, S., Ahmad, L., Akkaya, I., Aleman, F., Almeida, D., Altenschmidt, J., Altman, S., Anadkat, S., Avila, R., Babuschkin, I., Balaji, S., Balcom, V., Baltescu, P., Bao, H., Bavarian, M., Belgum, J., Zoph, B.: *GPT-4 Technical Report*, (2023)
- [55] Shi, Y.; Yu, K., Dong, Y., Chen, F.: Large language models in education: a systematic review of empirical applications, benefits, and challenges, *Computers and Education: Artificial Intelligence*, **10** (2026) 100529, <https://doi.org/10.1016/j.caeai.2025.100529>
- [56] Law, L.: Application of generative artificial intelligence (GenAI) in language teaching and learning: A scoping literature review, *Computers and Education Open*, **6** (2024) 100174, <https://doi.org/10.1016/j.caeo.2024.100174>
- [57] Mohammadi, M.; Tajik, E., Martinez-Maldonado, R., Sadiq, S., Tomaszewski, W., Khosravi, H.: Artificial intelligence in multimodal learning analytics: A systematic literature review, *Computers and Education: Artificial Intelligence*, **8** (2025) 100426, <https://doi.org/10.1016/j.caeai.2025.100426>

- [58] Küchemann, S.; Avila, K.E., Dinc, Y., Hortmann, C., Revenga, N., Ruf, V., Stausberg, N., Steinert, S., Fischer, F., Fischer, M., Kasneci, E., Kasneci, G., Kuhr, T., Kutyniok, G., Malone, S., Sailer, M., Schmidt, A., Stadler, M., Weller, J., Kuhn, J.: On opportunities and challenges of large multimodal foundation models in education, *npj Science of Learning*, **10** (2025) 1, 11, <https://doi.org/10.1038/s41539-025-00301-w>
- [59] Fu, Y.; Weng, Z.: Navigating the ethical terrain of AI in education: A systematic review on framing responsible human-centered AI practices, *Computers and Education: Artificial Intelligence*, **7** (2024) 100306, <https://doi.org/10.1016/j.caeai.2024.100306>
- [60] Hepp Andreas Jarke, J.; K.L. ed.: Reconfiguring Education Through Data: How Data Practices Reconfigure Teacher Professionalism and Curriculum, U *New Perspectives in Critical Data Studies: The Ambivalences of Data Power*, Springer International Publishing, 978-3-030-96180-0, Cham, (2022), 217-241
- [61] Groothuijsen, S.; van den Beemt, A., Remmers, J.C., van Meeuwen, L.W.: AI chatbots in programming education: Students' use in a scientific computing course and consequences for learning, *Computers and Education: Artificial Intelligence*, **7** (2024) 100290, <https://doi.org/10.1016/j.caeai.2024.100290>
- [62] Sun, D.; Boudouaia, A., Yang, J., Xu, J.: Investigating students' programming behaviors, interaction qualities and perceptions through prompt-based learning in ChatGPT, *Humanities and Social Sciences Communications*, **11** (2024) 1, 1447, <https://doi.org/10.1057/s41599-024-03991-6>
- [63] Barke, S.; James, M.B., Polikarpova, N.: Grounded Copilot: How Programmers Interact with Code-Generating Models, *Proceedings of the ACM on Programming Languages*, **7** (2023) OOPSLA1, <https://doi.org/10.1145/3586030>
- [64] Agbo, F.J.; Olivia, C., Oguibe, G., Sanusi, I.T., Sani, G.: Computing education using generative artificial intelligence tools: A systematic literature review, *Computers and Education Open*, **9** (2025) 100266, <https://doi.org/10.1016/j.caeo.2025.100266>
- [65] Prather, J.; Reeves, B.N., Denny, P., Becker, B.A., Leinonen, J., Luxton-Reilly, A., Powell, G., Finnie-Ansley, J., Santos, E.A.: "It's Weird That it Knows What I Want": Usability and Interactions with Copilot for Novice Programmers, *ACM Transactions on Computer-Human Interaction*, **31** (2023) 1, <https://doi.org/10.1145/3617367>
- [66] Rahe, C.; Maalej, W.: How Do Programming Students Use Generative AI?, *Proceedings of the ACM on Software Engineering*, **2** (2025) FSE, <https://doi.org/10.1145/3715762>
- [67] Moradi Dakhel, A.; Majdinasab, V., Nikanjam, A., Khomh, F., Desmarais, M.C., Jiang, Z.M. (Jack): GitHub Copilot AI pair programmer: Asset or Liability?, *Journal of Systems and Software*, **203** (2023) 111734, <https://doi.org/10.1016/j.jss.2023.111734>
- [68] Alsswey, A.: Examining students' perspectives on the use of artificial intelligence tools in higher education: A case study on AI tools of graphic design, *Acta Psychologica*, **258** (2025) 105190, <https://doi.org/10.1016/j.actpsy.2025.105190>
- [69] Lee, C.-W.: Application of Generative Artificial Intelligence in Design Education: An Exploration and Analysis to Enhance Student Creativity, *Engineering Proceedings*, **98** (2025) 1, <https://doi.org/10.3390/engproc2025098029>

- [70] Hwang, Y.; Wu, Y.: Graphic Design Education in the Era of Text-to-Image Generation: Transitioning to Contents Creator, *International Journal of Art & Design Education*, **44** (2025) 1, 239-253, <https://doi.org/10.1111/jade.12558>
- [71] Knoth, N.; Tolzin, A., Janson, A., Leimeister, J.M.: AI literacy and its implications for prompt engineering strategies, *Computers and Education: Artificial Intelligence*, **6** (2024), 100225, <https://doi.org/10.1016/j.caeai.2024.100225>
- [72] Federiakin, D.; Molerov, D., Zlatkin-Troitschanskaia, O., Maur, A.: Prompt engineering as a new 21st century skill, *Frontiers in Education*, **9** (2024) <https://doi.org/10.3389/educ.2024.1366434>
- [73] Pallant, J.L.; Blijlevens, J., Campbell, A., Jopp, R.: Mastering knowledge: the impact of generative AI on student learning outcomes, *Studies in Higher Education*, **0** (2025) 0, 1-22, [10.1080/03075079.2025.2487570](https://doi.org/10.1080/03075079.2025.2487570)
- [74] Park, J.: A systematic literature review of generative artificial intelligence (GenAI) literacy in schools, *Computers and Education: Artificial Intelligence*, **9** (2025) 100487, <https://doi.org/10.1016/j.caeai.2025.100487>
- [75] Maatta, S.: How Do Programmers Evaluate AI-Generated Code?, *ACM/IEEE International Symposium on Empirical Software Engineering and Measurement (ESEM)*, 522-527, 979-8-3315-9147-2, IEEE Computer Society, (2025)
- [76] Johnston, H.; Wells, R.F., Shanks, E.M., Boey, T., Parsons, B.N.: Student perspectives on the use of generative artificial intelligence technologies in higher education, *International Journal for Educational Integrity*, **20** (2024) 1, 2, <https://doi.org/10.1007/s40979-024-00149-4>
- [77] Wu, F.; Dang, Y., Li, M.: A Systematic Review of Responses, Attitudes, and Utilization Behaviors on Generative AI for Teaching and Learning in Higher Education, *Behavioral Sciences*, **15** (2025) 4, <https://doi.org/10.3390/bs15040467>
- [78] Nikolic, S.; Wentworth, I., Sheridan, L., Moss, S., Duursma, E., Jones, R.A., Ros, M., Middleton, R.: A systematic literature review of attitudes, intentions and behaviours of teaching academics pertaining to AI and generative AI (GenAI) in higher education: An analysis of GenAI adoption using the UTAUT framework, *Australasian Journal of Educational Technology*, **40** (2024) 6, 56-75, <https://doi.org/10.14742/ajet.9643>
- [79] Farazouli, A.; Pargman, T.C., Laksov, K.B., McGrath, C.: Navigating uncertainty: university teachers' experiences and perceptions of generative artificial intelligence in teaching and learning, *Studies in Higher Education*, **0** (2025) 0, 1–16, <https://doi.org/10.1080/03075079.2025.2550766>
- [80] Lyu, W.; Zhang, S., Chung, T., Sun, Y., Zhang, Y.: Understanding the practices, perceptions, and (dis)trust of generative AI among instructors: A mixed-methods study in the U.S. higher education, *Computers and Education: Artificial Intelligence*, **8** (2025) 100383, <https://doi.org/10.1016/j.caeai.2025.100383>
- [81] Park, J.: A systematic literature review of generative artificial intelligence (GenAI) literacy in schools, *Computers and Education: Artificial Intelligence*, **9** (2025) 100487, <https://doi.org/10.1016/j.caeai.2025.100487>

- [82] Cotton, D.R.E.; Cotton, P.A., Shipway, J.R.: Chatting and cheating: Ensuring academic integrity in the era of ChatGPT, *Innovations in Education and Teaching International*, **61** (2024) 2, 228-239, <https://doi.org/10.1080/14703297.2023.2190148>
- [83] Bikanga Ada, M.: Programming Challenges and Perceptions: A Study of Separate Groups before and after the Release of ChatGPT, *ACM Transactions on Computing Education*, **26** (2026) 2, 1,29, <https://doi.org/10.1145/3777904>

Umjetna inteligencija i spektralni *unmixing* u analizi pisane baštine

Damir Modrić¹, Vladimir Cviljušac¹, Alan Divjak², Jana Žiljak Gršić³

¹Sveučilište u Zagrebu Grafički fakultet, Getaldićeva 2, 10000 Zagreb

²Sveučilište Algebra Bernays, Gradišćanska ul. 24, 10000 Zagreb

³Tehničko veleučilište u Zagrebu, Vrbik 8, 10000 Zagreb

Sažetak: *Primjena umjetne inteligencije (UI) u multispektralnoj i hiperspektralnoj analizi značajno proširuje mogućnosti istraživanja pisane kulturne baštine. Klasične metode poput PCA, ICA i linearnih modela spektralnog unmixinga ograničene su pretpostavkom linearnosti i stabilnih spektralnih potpisa, što u povijesnim rukopisima često nije zadovoljeno zbog nelinearnog miješanja pigmenata, utjecaja podloge i degradacije veziva. U radu se analiziraju teorijske osnove spektralne reflektancije, kalibracije (IRF) i multivarijantne obrade podataka te se razmatra doprinos dubokog učenja u modeliranju nelinearnih interakcija pigment-vezivo-podloga. Na primjerima iluminiranih rukopisa 14. i 15. stoljeća pokazuje se kako kombinacija hiperspektralne analize i naprednih algoritama omogućuje precizniju identifikaciju pigmenata, detekciju naknadnih intervencija i poboljšanje čitljivosti degradiranog teksta. Rezultati potvrđuju da UI predstavlja metodološki iskorak u nerazornoj dijagnostici kulturne baštine.*

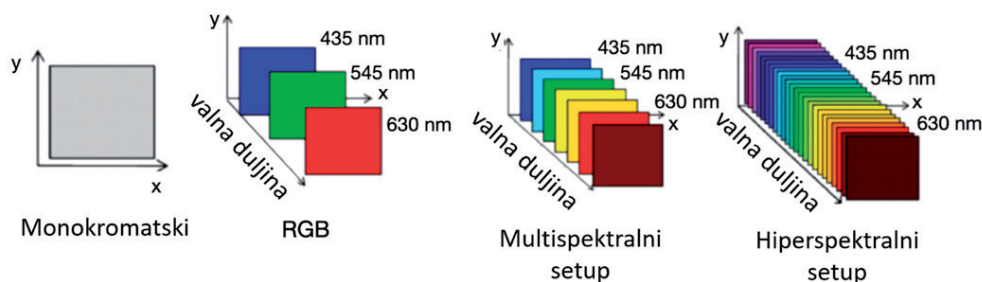
Ključne riječi: *umjetna inteligencija, hiperspektralna analiza, spektralni unmixing, pisana baština, identifikacija pigmenata*

1. Uvod

Pisana kulturna baština, uključujući iluminirane rukopise, predstavlja složene materijalne sustave u kojima se mikroskopski miješaju pigmenti, veziva i podloge nastali stoljećima primjenom tradicionalnih tehnika i fizikalno-kemijskih procesa degradacije. Analiza takvih objekata zahtijeva nerazorne metode jer je uzimanje uzoraka često neprihvatljivo zbog njihove povijesne i kulturne vrijednosti.

Hiperspektralno snimanje (HSI) omogućuje registraciju reflektancije objekta u velikom broju uskih spektralnih kanala (Slika 1), stvarajući podatkovnu kocku u kojoj se za svaki piksel dobiva potpuni spektralni potpis. Time se dobiva prostorno-spektralna

mapa koja može otkriti informaciju o materijalima koji su inače nevidljivi na običnim RGB snimkama [1, 2]. HSI je široko primijenjen u dokumentaciji i dijagnostici kulturne baštine jer omogućuje mapiranje i identifikaciju pigmentata, poboljšanje vizualizacije tekstualnih i slikovnih elemenata, kao i detekciju naknadnih intervencija i degradacije bez fizičkog kontakta s objektom [2].



Slika 1: Usporedba monokromatskog, RGB snimanja i multi/hiperspektralne kocke slike (prilagođeno od Zhang i sur. [3]). Definicija različitih pristupa snimanju temelji se na spektralnoj rezoluciji. Kod RGB snimanja, spektralna osjetljivost za svaku boju vizualizirana je sivom bojom

Međutim, analiza hiperspektralnih podataka suočava se s nekoliko izazova. Visoka dimenzionalnost spektralnih podataka znači da tradicionalne metode analize (npr. analiza glavnih komponenti - PCA) služe prvenstveno za redukciju dimenzija i otkrivanje dominantnih komponenti, ali često ne mogu u potpunosti modelirati kompleksne nelinearne odnose među materijalima u stvarnim povijesnim slojevima [3]. U kontekstu pigmentnih analiza, linijski modeli za spektralni *unmixing* pretpostavljaju da miješani spektar može biti predstavljen kao linearna kombinacija *endmembers*, što često ne drži u uvjetima slojevitih ili nelinearnih optičkih interakcija prisutnih u stvarnim artefaktima [4, 5].

Daljnji izazov predstavlja obrada višedimenzionalnih hiperspektralnih podataka pri čemu se oslanjanje na klasične statističke tehnike, poput PCA ili ICA (analize nezavisnih komponenti), pokazalo korisnim za vizualizaciju struktura i segmentaciju signala, ali ograničenim u smislu interpretabilnosti i kvantifikacije materijalnih doprinosa [3]. S druge strane, metode strojnog učenja, uključujući konvolucijske neuronske mreže i druge pristupe dubokom učenju, sve se više koriste za klasifikaciju materijala i modeliranje nelinearnih odnosa u hiperspektralnim podacima, zahvaljujući sposobnosti učenja kompleksnih karakteristika iz velikih skupova spektralnih informacija [6].

U kontekstu identifikacije pigmenata u umjetničkim djelima i rukopisima, recentni radovi pokazuju da HSI može biti povezan s metodama strojnog učenja kako bi se izgradili podatkovni modeli koji istovremeno klasificiraju čiste i miješane spektre te omogućuju mapiranje spektralnih obilježja kroz cijelu površinu objekta. Ovi pristupi nadmašuju tradicionalne linearne metode u preciznosti identifikacije i kvantitativnoj procjeni pigmenata, osobito kad su prisutni složeni miješani spektar i varijabilna pozadina materijala [1, 6].

Cilj ovog rada je pružiti teorijsko i metodološko utemeljenje primjene hiperspektralnog snimanja, kombinirano s multivarijantnom analizom i umjetnom inteligencijom, u nerazornoj analizi pisane kulturne baštine. Posebna se pozornost posvećuje problemu spektralnog *unmixinga* i ulozi nelinearnih modela u poboljšanju identifikacije materijala u uvjetima kompleksnih spektralnih interakcija.

2. Fizikalne osnove spektralne reflektancije i hiperspektralnog snimanja

2.1 Spektralna reflektancija i optičke interakcije u slojevima boje

Spektralna reflektancija $R(\lambda)$ definira se kao omjer reflektirane i upadne zračne energije pri određenoj valnoj duljini. U idealiziranom slučaju homogenog pigmentnog sloja reflektancijski spektar primarno ovisi o apsorpcijskim svojstvima pigmentnih čestica. Međutim, u stvarnim povijesnim rukopisima pigmenti su dispergirani u vezivu i nanoseni na podlogu (pergament ili papir), pri čemu dolazi do višestrukog raspršenja i parcijalne transmisije svjetlosti.

U takvim višeslojnim sustavima spektralni odziv rezultat je kombinacije selektivne apsorpcije pigmenta, raspršenja na česticama različite granulacije, refleksije na podlozi, interakcije pigment-vezivo i degradacijskih promjena tijekom vremena.

Optičko ponašanje slojeva boje u umjetničkim djelima detaljno je opisano u literaturi koja povezuje hiperspektralnu analizu s fizikalnim modelima refleksije [2]. Istraživanja mineralnih pigmenata pokazala su da spektralne varijacije unutar iste kromatske zone mogu proizlaziti iz promjene granulacije ili veziva, a ne nužno iz promjene kemijskog sastava [7, 8].

To znači da usporedba izmjerene spektra s referentnim spektrom čistog pigmenta predstavlja tek prvi korak u interpretaciji, ali ne i konačni dokaz identifikacije.

2.2 Linearni i nelinearni modeli spektralnog miješanja

U obradi hiperspektralnih podataka često se primjenjuje linearni model miješanja:

$$r = \sum_{i=1}^n a_i e_i + \varepsilon$$

gdje su:

r – izmjereni spektar,

e_i – spektar i -te čiste komponente (*endmember*),

a_i – udio komponente,

ε – rezidualni signal (šum).

Linearni model pretpostavlja da foton interagira s jednom komponentom prije izlaska iz sustava. U praksi iluminiranih rukopisa ta pretpostavka često nije u potpunosti zadovoljena zbog višestrukog raspršenja i slojevitosti.

Istraživanja spektralnog *unmixinga* na oslikanim artefaktima pokazala su da varijabilnost spektra može biti značajna čak i unutar istog pigmentnog područja, osobito kada su prisutne promjene u podlozi ili debljini sloja [7]. Usporedba linearnih i nelinearnih pristupa u identifikaciji miješanih pigmenata pokazuje da linearni modeli mogu generirati stabilna matematička rješenja, ali ne uvijek fizikalno najtočnija [8].

Nelinearni modeli uključuju dodatne interakcijske članove, ali povećavaju računalnu složenost i zahtijevaju napredne optimizacijske algoritme. Upravo tu umjetna inteligencija, posebno duboko učenje, omogućuje implicitno modeliranje nelinearnih odnosa bez eksplicitnog definiranja funkcionalnog oblika miješanja [9].

2.3 Instrumentalni aspekti hiperspektralnog snimanja

Svaki hiperspektralni sustav karakteriziraju spektralna rezolucija, radiometrijska osjetljivost, *signal-to-noise* omjer i instrumentalna funkcija odziva (IRF).

Izmjerena digitalna vrijednost $D(\lambda)$ može se aproksimirati relacijom:

$$D(\lambda) = E(\lambda) \cdot R(\lambda) \cdot S(\lambda) \quad (1)$$

gdje su:

$D(\lambda)$ – izmjereni digitalni signal,

$E(\lambda)$ – spektralna raspodjela izvora svjetla,

$R(\lambda)$ – reflektancija objekta,

$S(\lambda)$ – spektralna osjetljivost sustava.

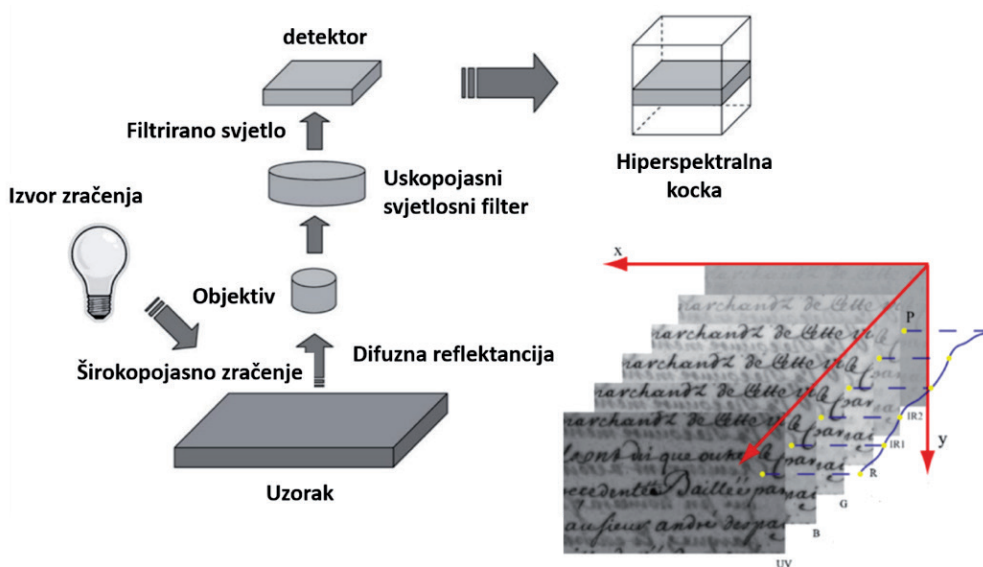
Bez kalibracije (tamni signal, bijeli referentni standard, korekcija osvjetljenja) nemoguće je dobiti fizikalno interpretabilne podatke. U kontekstu kulturne baštine istaknuto je da je standardizirana radiometrijska kalibracija preduvjet pouzdane klasifikacije materijala [5].

2.3.1 Laboratorijski sustav za multispektralno snimanje pisane baštine

U ovom istraživanju korišten je laboratorijski sustav (shematski prikaz je dat na Slici 2) za multispektralno snimanje razvijen za potrebe dokumentacije i analize pisane povijesne građe. Sustav je koncipiran kao modularna konfiguracija optimizirana za visoku radiometrijsku stabilnost, spektralnu selektivnost i reproduktivnost mjerenja.

Središnja komponenta sustava je industrijska monokromatska kamera s CMOS senzorom rezolucije 5472×3648 piksela (≈ 20 MP). Senzor je formata 1", s veličinom piksela $2,4 \mu\text{m}$. Dinamički raspon iznosi 12 stopa (≈ 72 dB), dok A/D konverzija radi u 12-bitnom režimu. Spektralna osjetljivost detektora obuhvaća područje približno od 300 do 1000 nm.

Visoka prostorna rezolucija i relativno mala veličina piksela omogućuju preciznu dokumentaciju detalja iluminacija, dok 12-bitna kvantizacija osigurava 4096 diskretnih razina signala, što je važno za očuvanje finih tonalnih prijelaza u spektralnim analizama.



Slika 2: Laboratorijski postav za hiperspektralno skeniranje iluminacija rukopisa

Uz kameru se koristi objektiv visoke razlučivosti žarišne duljine 25 mm, maksimalnog otvora blende $f/2,8$ i minimalne udaljenosti fokusa 0,3 m. Horizontalni i vertikalni vidni kut iznose $28,7^\circ$ i $21,7^\circ$. Manualna kontrola fokusa i otvora blende omogućuje optimizaciju dubinske oštine i ekspozicije u skladu s karakteristikama analiziranog artefakta.

3. Spektralna selekcija – uskopojasni filtri

Ključnu ulogu u formiranju spektralne kocke podataka imaju uskopojasni interferencijski filtri. Sustav koristi 21 uskopojasni filtar u vidljivom području, te 12 filtara u blisko infracrvenom području, sa širinom pojasa približno 10 nm oko vršne valne duljine. Tako se dobivaju ukupno 33 diskretna spektralna kanala. U odnosu na klasične hiperspektralne *push-broom* sustave, ovakav pristup predstavlja sekvencijalnu multispektralnu akviziciju visoke selektivnosti.

Širina pojasa od 10 nm omogućuje detekciju uskih apsorpcijskih minimuma, diferencijaciju spektralno sličnih pigmenta i smanjenje integracije neželjenih spektralnih komponenti. Međutim, treba naglasiti da diskretna akvizicija uvodi vremensku komponentu snimanja, što zahtijeva stabilne uvjete osvjetljenja i nepomičnost artefakta.

3.1. Prednosti i ograničenja konfiguracije

3.1.1 Prednosti sustava

Konfiguraciju našeg sustava odlikuje visoka prostorna rezolucija (20 MP), diskretna spektralna selektivnost (razlučivost do 10 nm), širok spektralni raspon (bliski UV + VIS + NIR), kontrolirani laboratorijski uvjeti te visoki dinamički raspon (72 dB). Takva konfiguracija omogućuje precizno mapiranje spektralnih karakteristika iluminacija i pisane građe.

3.1.2 Ograničenja

Ipak, potrebno je imati na umu da sustav ima i određena ograničenja: diskretni (ne kontinuirani) spektralni uzorak, potencijalna varijabilnost između sekvencijalnih snimanja, ovisnost o stabilnosti osvjetljenja i potrebe za strogo definiranom kalibracijom.

Ova ograničenja posebno su relevantna pri primjeni algoritama spektralnog *unmixing*-a i modela strojnog učenja, jer varijacije koje nisu materijalnog podrijetla mogu utjecati na generalizacijsku sposobnost modela [10, 14].

3.2 Implikacije za daljnju obradu podataka

Konfiguracija sustava izravno utječe na kvalitetu PCA separacije, stabilnost NMF/ICA dekompozicije i uspješnost nelinearnih AI modela. Pri čemu diskretni 10 nm kanali čine sustav pogodnim za klasifikacijske modele, regresijske modele procjene sastava, te hibridne spektralno-prostorne CNN arhitekture.

U kontekstu ovog rada, naš sustav predstavlja temelj za razvoj naprednih modela spektralnog *unmixinga* i identifikacije materijala u iluminiranim rukopisima.

3.3 Prostorno-spektralna analiza

Jedna od ključnih prednosti HSI-a u odnosu na točkaste metode (npr. FORS) jest mogućnost istodobne prostorne i spektralne analize. Time se omogućuje mapiranje distribucije pigmentata, segmentacija tekstualnih i slikovnih zona i analiza heterogenosti unutar iste boje.

Primjena metoda poput NMF i ICA pokazala je da se miješani pikseli mogu razložiti na dominantne komponente koje odgovaraju pojedinim pigmentnim doprinosima [7]. Međutim, preciznost takve dekompozicije ovisi o modelu miješanja i kvaliteti podataka.

Integracija prostornih značajki u klasifikacijske modele (npr. konvolucijske neuronske mreže) dodatno povećava robusnost identifikacije pigmentata jer se uzima u obzir i morfologija površine [8].

4. Kalibracija i instrumentalna funkcija odziva (IRF)

4.1 Radiometrijska osnova kalibracije

Hiperspektralno snimanje u području kulturne baštine ima smisla samo ako je izmjereni signal moguće povezati s fizikalnom veličinom – reflektancijom površine. Izmjerena digitalna vrijednost ovisi ne samo o objektu, nego i o izvoru osvjetljenja i osjetljivosti sustava, što je opisano relacijom (1). Kako bi se izolirala reflektancija $R(\lambda)$, potrebno je ukloniti utjecaj spektralne raspodjele izvora $E(\lambda)$ i spektralne osjetljivosti sustava $S(\lambda)$. U tu svrhu primjenjuje se radiometrijska kalibracija koja se temelji na referentnim mjerenjima poznate reflektancije. Postupak kalibracije omogućuje kompenzaciju instrumentalnih i iluminacijskih varijacija te osigurava usporedivost podataka između različitih sesija snimanja. U kontekstu analize umjetničkih djela naglašeno je da bez dosljedne kalibracije spektralna usporedba s referentnim bibliotekama nije pouzdana [10].

4.2 Instrumentalna funkcija odziva (IRF)

Instrumentalna funkcija odziva (IRF) opisuje ukupnu spektralnu osjetljivost sustava, uključujući optičke elemente (leće, filtre), disperzijski sustav, detektor i elektroniku pojačanja signala.

IRF je valno ovisna funkcija i može značajno varirati u UV, vidljivom i NIR području. Ako se IRF ne uzme u obzir, dolazi do sistematskih pogrešaka u obliku spektra, osobito na rubovima spektralnog raspona.

U radovima koji se bave primjenom hiperspektralnog snimanja u arheologiji i konzervaciji naglašeno je da varijacije instrumentalnog odziva mogu dovesti do pogrešne klasifikacije pigmentata ako nisu pravilno kompenzirane [10]. Dodatno, u klasifikacijskim modelima temeljenim na strojnome učenju pokazano je da neujednačena kalibracija smanjuje generalizacijsku sposobnost modela [11].

IRF se može procijeniti eksperimentalno snimanjem poznatih referentnih materijala ili matematičkom aproksimacijom odziva detektora i optičkog sustava.

4.3 Spektralna rezolucija i omjer signal-šum

Spektralna rezolucija definira širinu spektralnog kanala ($\Delta\lambda$) i izravno utječe na sposobnost razlučivanja uskih apsorpcijskih značajki. U identifikaciji pigmentata, osobito mineralnih, točna identifikacija uskih apsorpcijskih vrpca može biti presudna za diferencijaciju kemijski srodnih spojeva [9].

Omjer signal – šum (engl. *signal-to-noise ratio*) (SNR) definira se kao:

$$\text{SNR} = \mu / \sigma$$

gdje su:

μ – srednja vrijednost signala,

σ – standardna devijacija šuma.

Nizak SNR može maskirati suptilne spektralne razlike između sličnih pigmentata. U hiperspektralnoj analizi kulturne baštine preporučuje se optimizacija ekspozicije i višestruko usrednjavanje kako bi se smanjio utjecaj šuma [10].

4.4 Standardizacija i reproduktivnost

Jedan od ključnih izazova u primjeni hiperspektralnog snimanja u kulturnoj baštini jest reproduktivnost rezultata. Različiti sustavi, različiti izvori osvjetljenja i različiti

geometrijski uvjeti snimanja mogu generirati spektralne razlike koje nisu povezane s materijalnim sastavom objekta.

Recentna istraživanja pokazuju da standardizirani protokoli snimanja i kalibracije značajno poboljšavaju točnost klasifikacijskih modela i spektralnog *unmixinga* [7, 11]. Posebno je važno da modeli strojnog učenja budu trenirani na podacima dobivenima pod kontroliranim i dokumentiranim uvjetima, jer u suprotnom dolazi do tzv. *domain shift* problema [12].

U kontekstu pisane kulturne baštine, gdje je svaki artefakt jedinstven, dosljedna kalibracija i dokumentiranje instrumentalnih parametara predstavljaju preduvjet znanstvene vjerodostojnosti rezultata.

5. Multivarijantne metode u spektralnoj analizi

Hiperspektralni podaci mogu se promatrati kao matrica X dimenzija $m \times n$, gdje je m broj piksela (ili uzoraka), a n broj spektralnih kanala. Svaki red matrice predstavlja jedan spektar, a svaki stupac intenzitet pri određenoj valnoj duljini. Zbog visoke dimenzionalnosti i koreliranosti kanala, izravna interpretacija podataka nije praktična. Multivarijantne metode omogućuju redukciju dimenzionalnosti, izdvajanje dominantnih varijacijskih obrazaca, segmentaciju materijalnih zona i pripremu podataka za napredne modele (uključujući UI). U našoj analizi koristimo metode koje su ukratko prikazane u poglavljima koja slijede.

5.1 Analiza glavnih komponenti (PCA)

PCA transformira izvorne varijable u novi skup ortogonalnih komponenti maksimalne varijance. Matematički, postupak se temelji na dekompoziciji kovarijacijske matrice:

$$C = (1 / (m - 1)) \cdot X^T X$$

Rješenje se dobiva eigendekompozicijom:

$$C v_i = \lambda_i v_i$$

gdje su:

v_i – eigenvektori (glavne komponente),

λ_i – eigenvrijednosti (varijanca komponente).

Prva komponenta sadrži najveći udio varijance, druga sljedeći itd.

U hiperspektralnoj analizi umjetničkih djela PCA se široko koristi za uklanjanje šuma, vizualizaciju skrivenih struktura i pojačavanje kontrasta između tekstualnih i slikovnih elemenata [14].

U radu koji uspoređuje NMF i ICA u pigmentnim analizama pokazano je da PCA učinkovito razdvaja glavne varijacijske obrasce, ali ne garantira fizikalnu interpretabilnost komponenti [8].

5.2 Analiza nezavisnih komponenti (ICA)

Za razliku od PCA, koja maksimizira varijancu, ICA traži statistički nezavisne izvore signala. Model se može zapisati kao:

$$X = AS$$

gdje su:

X – matrica opaženih spektara,

A – matrica miješanja,

S – matrica nezavisnih komponenti.

Cilj je pronaći S takvu da su njezini redovi statistički nezavisni.

U kontekstu iluminiranih rukopisa ICA može omogućiti razdvajanje pigmentne komponente, podloge, mrlja ili degradacijskih produkata [15], preslikanog (engl. *bleed-through*) teksta. Usporedba ICA i NMF pristupa pokazala je da ICA često daje jasnije razdvajanje zona gdje su pigmenti pomiješani, ali je osjetljivija na šum i inicijalne uvjete [9]. U iluminacijama s plavim i crvenim zonama ICA bi mogla izdvojiti komponentu vezanu uz bakrene pigmente i zasebnu komponentu podloge, što omogućuje prostornu mapu raspodjele materijala.

5.3 Ne-negativna matrična faktorizacija (NMF)

Za razliku od PCA i ICA, NMF nameće uvjet ne-negativnosti:

$$X \approx WH \quad \text{gdje su } W \geq 0 \text{ i } H \geq 0.$$

Ovo je posebno važno u spektralnoj analizi jer reflektancija i udjeli pigmenata ne mogu biti negativni. Prednosti NMF-a su bolja fizikalna interpretabilnost, prirodna dekompozicija na “dijelove” i kompatibilnost s linearnim *unmixing* modelom. U analizi miješanih pigmenata pokazano je da NMF može bolje rekonstruirati komponente u usporedbi s PCA, ali uz veću računalnu složenost [8].

5.4 Ograničenja klasičnih multivarijantnih metoda

Iako su PCA, ICA i NMF iznimno korisne, njihova ograničenja leže u pretpostavci linearnog miješanja, osjetljivosti na šum i kalibracijske pogreške te ovisnosti o inicijalizaciji (ICA, NMF). Recentna istraživanja spektralnog *unmixinga* u umjetničkim djelima pokazuju da linearnost nije uvijek zadovoljena, osobito kod tankih ili polutransparentnih slojeva [7].

Ovo izravno motivira prijelaz prema nelinearnim modelima i metodama strojnog učenja.

5.5 Prijelaz prema umjetnoj inteligenciji

Klasične multivarijantne metode poput PCA, ICA i NMF pokazale su se učinkovitim u preliminarnoj analizi hiperspektralnih podataka iluminiranih rukopisa, no sve se više koriste konvolucijske mreže (CNN), autoenkoderi i hibridni prostorno-spektralni modeli [15, 16], a pregled metoda dubokog učenja za hiperspektralne podatke pokazuje da nelinearni modeli nadmašuju linearne metode u klasifikaciji miješanih spektara, osobito pri velikoj varijabilnosti podataka [15]. One omogućuju redukciju dimenzionalnosti, vizualnu separaciju spektralno različitih zona te djelomičnu dekompoziciju miješanih signala. U kontekstu kulturne baštine to znači bolju diferencijaciju sličnih pigmenta, robusnije razdvajanje slojeva i potencijalno precizniji spektralni *unmixing* u složenim iluminacijama [8]. Međutim, rezultati dobiveni u ovom istraživanju ukazuju na određena ograničenja takvih pristupa.

Prvo, linearne metode pretpostavljaju da se izmjereni spektar može opisati linearnom kombinacijom nekoliko baznih komponenti koje u stvarnim iluminacijama često prepoznamo kao višeslojne nanose pigmenta, interakcije pigment-vezivo-podloga, degradacijske procese i polutransparentne slojeve i djelomičnu transmisiju svjetlosti. Takve situacije mogu dovesti do nelinearnog spektralnog ponašanja koje linearne metode ne modeliraju u potpunosti.

Drugo, PCA komponente nemaju izravno fizikalno značenje. Iako jasno diferenciraju zone varijance, njihova interpretacija u smislu stvarnih materijalnih sastojaka ostaje ograničena. ICA i NMF nude veću interpretabilnost, ali su osjetljive na šum, inicijalizaciju i varijabilnost spektralnih potpisa.

U tom kontekstu umjetna inteligencija, odnosno metode strojnog i dubokog učenja, predstavljaju potencijalni razvojni smjer. Za potrebe ovog rada umjetna inteligencija definira se kao skup algoritama koji iz podataka uče obrasce i odnose bez eksplicitnog definiranja matematičkog modela fizikalnog procesa.

U hiperspektralnoj analizi to može uključivati klasifikaciju pigmenata na temelju spektralnih potpisa, procjenu udjela komponenti u miješanim pikselima, segmentaciju iluminacija i tekstualnih zona, te detekciju degradacijskih obrazaca.

Pregled suvremenih metoda pokazuje da modeli temeljeni na dubokom učenju postižu visoku točnost u klasifikaciji hiperspektralnih podataka [15, 16]. Važno je naglasiti da implementacija takvih modela zahtijeva dovoljno velik i reprezentativan skup podataka, pažljivu radiometrijsku kalibraciju, validacijske protokole i, nadalje, interdisciplinarnu suradnju između stručnjaka za obradu slike, računalne znanosti i konzervatorske struke.

Laboratorijski sustav korišten u ovom istraživanju, s kontroliranim uvjetima snimanja i diskretnim spektralnim kanalima, predstavlja dobru osnovu za razvoj takvih modela u budućnosti.

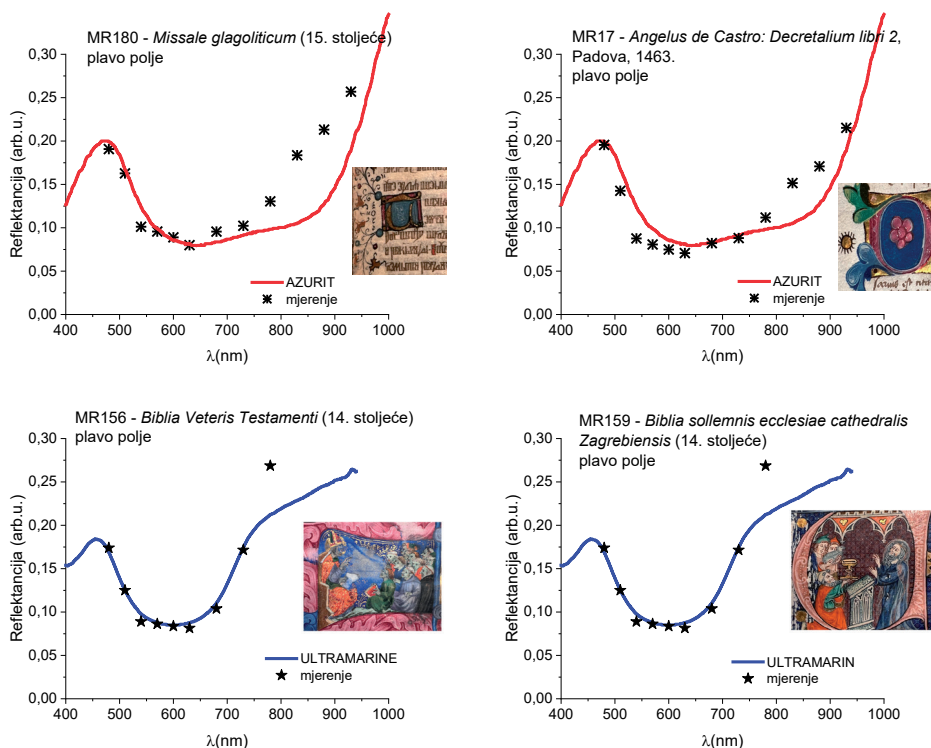
Stoga se umjetna inteligencija u ovom radu ne uvodi kao zamjena za klasične metode, već kao njihova nadogradnja i potencijalni alat za rješavanje problema spektralnog *unmixinga* i preciznije identifikacije materijala. Detaljna implementacija i evaluacija takvih modela zahtijevat će suradnju sa specijalistima iz područja umjetne inteligencije i računalne obrade podataka.

6. Metodološki izazovi spektralne analize pisane baštine

Jedan od temeljnih izazova u hiperspektralnoj analizi iluminiranih rukopisa jest činjenica da spektralni potpis pigmenta u stvarnom artefaktu često odstupa od laboratorijski izmjenjenog referentnog spektra. Razlozi za to uključuju promjene granulacije pigmenta, različite omjere pigment-vezivo, heterogenost podloge (pergament, papir), proces starenja i degradacije, te lokalna oštećenja i retuše.

spektralni potpis mora promatrati kao funkcija materijalnog sustava, a ne izoliranog kemijskog spoja. Ova varijabilnost otežava izravnu klasifikaciju i zahtijeva pažljivo definirane interpretacijske kriterije.

Kako bi ovo ilustrirali prikazat ćemo rezultate (Slika 3) u analizi pigmenata 15. stoljeća što smo proveli na knjigama iz fundusa Metropolitane (Bibliotheca Metropolitana, Metropolitanska knjižnica), knjižnice Zagrebačke nadbiskupije i Prvostolnoga kaptola zagrebačkoga. Metropolitana je najveća crkvena knjižnica i jedna od najstarijih sačuvanih knjižnica u Hrvatskoj.



Slika 3: Usporedba reflektancijskih spektara poznatih povijesnih pigmenata (azurit, ultramarin, indigo, crveni olovni prah, cinober) s izmjeranim spektrima iz četiri iluminirana rukopisa (14. i 15. stoljeće). Iako podudarnost nije savršena, eksperimentalni podaci potvrđuju identifikaciju pigmenata. Odstupanja se pripisuju starenju i kasnijim intervencijama

U iluminacijama s plavim i crvenim zonama ICA bi mogla izdvojiti komponentu vezanu uz bakrene pigmente i zasebnu komponentu podloge, što omogućuje prostornu mapu raspodjele materijala. U našim dosadašnjim analizama iluminacija (14.-15. st.) PCA je pokazala da prve dvije ili tri komponente često sadrže dominantnu informaciju o pigmentnim zonama, dok više komponente otkrivaju suptilne razlike unutar iste boje (npr. varijacije plavog područja) [8, 9].

Identifikacija pigmenata u pravilu se temelji na usporedbi izmjenenog spektra s referentnim spektrom. Međutim, dostupne baze podataka često ne uključuju varijacije u vezivu, ne obuhvaćaju degradirane uzorke, te skoro nikad nisu snimljene pod istim instrumentalnim uvjetima. Stoga je razumno pretpostaviti da, bez standardiziranih baza spektralnih potpisa prilagođenih povijesnim materijalima, postoji rizik pogrešne atribucije.

U kontekstu našeg rada, laboratorijski sustav s kontroliranim uvjetima snimanja pruža mogućnost postupne izgradnje vlastite referentne baze, što predstavlja važan razvojni smjer.

Slijedeće ključno pitanje u znanstvenoj analizi kulturne baštine je reproducibilnost. Različiti sustavi, različiti filtri i različite geometrije snimanja mogu, na istim uzorcima, generirati spektralne razlike koje nisu posljedica materijalnih promjena. U suprotnom, usporedba rezultata između različitih institucija postaje metodološki problematična.

Hiperspektralnom analizom iluminacija utvrđeno je da je dominantni plavi pigment azurit, što potvrđuju karakteristične apsorpcijske značajke u području oko 460 nm i 620 nm, tipične za bakrov karbonat-hidroksid [4, 9]. Uočena odstupanja u odnosu na laboratorijske referentne spektre mogu se objasniti utjecajem podloge, starenjem veziva, djelomičnim miješanjem s bijelim pigmentima te mogućim naknadnim restauratorskim intervencijama.

Primjena multivarijantnih metoda, posebice PCA i ICA, omogućila je razdvajanje tekstualnih i slikovnih elemenata te poboljšanje čitljivosti degradiranih dijelova rukopisa korištenjem tehnike lažnog prikaza boje [8, 12]. Dobiveni rezultati ukazuju da varijabilnost spektralnog odziva nije primarno posljedica promjene debljine sloja pigmenta, već složenih nelinearnih interakcija između materijala, što potvrđuje potrebu za primjenom naprednijih modela obrade spektralnih podataka.

7. Diskusija

Rezultati prikazani u ovom radu potvrđuju da hiperspektralna analiza pruža pouzdan uvid u materijalni sastav iluminiranih rukopisa, no istodobno razotkrivaju i temeljna metodološka ograničenja klasičnih multivarijantnih pristupa. PCA i ICA pokazale su se učinkovitima u redukciji dimenzionalnosti i izdvajanja dominantnih spektralnih obrazaca [12, 15], osobito u poboljšanju čitljivosti degradiranog teksta. Međutim, njihova interpretabilnost ovisi o pretpostavci linearne kombinacije izvora, što u slojevitim strukturama povijesnih tekstova nije uvijek fizikalno opravdano. Analiza iluminacija 14. i 15. stoljeća pokazala je da izmjereni spektri odstupaju od referentnih laboratorijskih vrijednosti azurita. Takva odstupanja mogu se objasniti interakcijom pigmenta i veziva, optičkim doprinosom podloge, mikroskopskim miješanjem s drugim pigmentima, te degradacijskim procesima tijekom stoljeća. Stoga, linearni spektralni *unmixing* u tim uvjetima može generirati matematički stabilna, ali fizikalno teško interpretabilna rješenja. To potvrđuje da problem nije isključivo statističke prirode, nego proizlazi iz kompleksne optike višeslojnih sustava. Upravo u tom kontekstu umjetna inteligencija predstavlja metodološki pomak [15, 16]. Duboke neuronske mreže mogu modelirati nelinearne odnose bez eksplicitne definicije funkcionalnog oblika miješanja čime se omogućuje aproksimacija složenih refleksijskih funkcija, robusnija klasifikacija pigmentata, integracija prostornih i spektralnih značajki, adaptivno učenje na heterogenim skupovima podataka, itd.

Međutim, da bi kvalitetno primijenili UI u analizi i zaštiti kulturne baštine potrebno je riješiti niz izazova kao što su nedostatak opsežnih, standardiziranih referentnih baza spektralnih potpisa povijesnih materijala, ograničena količina označenih (labeliranih) podataka za treniranje modela, potreba za objašnjivim modelima (engl. *Explainable AI*), osobito u konzervatorskoj praksi gdje je transparentnost odluka ključna, te reproduktivnost rezultata pri različitim sustavima snimanja i uvjetima osvjetljenja.

Posebno je važno naglasiti da UI ne može zamijeniti fizikalno razumijevanje optičkih procesa. Umjesto toga, optimalni pristup podrazumijeva hibridne modele koji kombiniraju fizikalno utemeljene modele refleksije, multivarijantnu statistiku i nelinearne neuronske arhitekture.

8. Zaključak

U radu je prikazana integracija hiperspektralne analize, multivarijantnih metoda i pristupa umjetne inteligencije u istraživanju pisane kulturne baštine. Teorijska razrada spektralne reflektancije i postupaka radiometrijske kalibracije potvrđuje da je precizna instrumentalna korekcija temelj pouzdane interpretacije spektralnih podataka. Primjena metoda poput PCA i ICA pokazala je njihovu učinkovitost u redukciji dimenzionalnosti i vizualizaciji skrivenih struktura, ali i ograničenja linearnih modela u analizi složenih, višeslojnih materijalnih sustava [2].

Na primjerima iluminiranih rukopisa iz 14. i 15. stoljeća potvrđena je prisutnost azurita kao dominantnog plavog pigmenta, uz izraženu varijabilnost spektralnog odziva koja ukazuje na nelinearne interakcije između pigmenta, veziva i podloge. Takvi rezultati potvrđuju da linearni modeli ne mogu u potpunosti opisati fizikalnu realnost povijesnih slojeva boje te upućuju na potrebu za naprednijim pristupima analizi.

Umjetna inteligencija, osobito metode temeljene na dubokom učenju, predstavlja perspektivan smjer razvoja jer omogućuje modeliranje nelinearnog spektralnog mijenjanja, automatiziranu klasifikaciju materijala i integraciju različitih izvora podataka. Međutim, njezina primjena zahtijeva sustavan razvoj referentnih baza spektralnih potpisa, standardizaciju postupaka snimanja, implementaciju objašnjivih modela te interdisciplinarnu validaciju rezultata.

Zaključno, umjetna inteligencija ne zamjenjuje postojeće analitičke metode, već ih nadopunjuje i proširuje. Sinergija fizikalno utemeljenih pristupa, multivarijantne analize i nelinearnih modela omogućuje dublje razumijevanje materijalne strukture povijesnih dokumenata te otvara nove mogućnosti u nerazornoj dijagnostici, interpretaciji i očuvanju pisane kulturne baštine.

9. Literatura

- [1] Fatma, Z. S. N.; Hardeberg, J. Y., Papachristos, E.: Pigment Identification of Ortelius' Historical Maps using Hyperspectral Imaging, *Journal of Imaging Science (IS&T)*, **22** (2025) 18-23, <https://doi.org/10.2352/issn.2168-3204.2025.22.1.4>
- [2] Liang, H.: Advances in multispectral and hyperspectral imaging for archaeology and art conservation, *Applied Physics A*, **106** (2012) 2, 309-323, <https://doi.org/10.1007/s00339-011-6689-1>
- [3] Zhang, J.; Su, R., Fu, Q., Ren, W., Heide, F., Nie, Y.: A survey on computational spectral reconstruction methods from RGB to hyperspectral imaging. *Scientific Reports*, **12** (2022) 11905, <https://doi.org/10.1038/s41598-022-16223-1>
- [4] Bioucas-Dias, J. M.; Plaza, A., Camps-Valls, G., Scheunders, P., Nasrabadi, N., Chanussot, J.: Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **5** (2012) 2, 354-379, <https://doi.org/10.1038/4456510.1109/JSTARS.2012.2194696>
- [5] Wang, Y.; Lyu, S., Ning, B., Yan, J., Hou, M., Sun, P., Li, L.: Spectral Unmixing of Pigments on Surface of Painted Artefacts Considering Spectral Variability, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **X-4** (2024) 403-409
- [6] Liu, J.; Li, T., Yu, Z., Lyu, S., Fu, Q., Yu, X.: Hyperspectral identification of mineral pigments in Thangka paintings for cultural heritage conservation. *npj Heritage Science* **13** (2025) 649, <https://doi.org/10.1038/s40494-025-02241-5>
- [7] Liu, Y.; Lyu, S., Hou, M., Yin, Q.: The Comparison between NMF and ICA in Pigment Mixture Identification of Ancient Chinese Paintings, *ISPRS Archives*, **XLII-3** (2018) 1169-1176
- [8] Modrić, D.: Hyperspectral camera as a spectrometer in the preservation of written and printed historical materials; International scientific conference, Colour in written heritage - multidisciplinary research, Book of abstracts, Zagreb, 25 – 27, September 2024, p 32, ISBN: 978-953-8461-27-9
- [9] Cviljušac, V.: Analysis of the spectrum of illuminations in books from the 14th and 15th centuries obtained with a hyperspectral camera; International scientific conference, Colour in written heritage - multidisciplinary research, Book of abstracts, Zagreb, 25 – 27, September 2024, p 33, ISBN: 978-953-8461-27-9
- [10] Pan, S. J.; Yang, Q.: A Survey on Transfer Learning, *IEEE Transactions on Knowledge and Data Engineering*, **22** (2010) 10, 1345-1359, <https://doi.org/10.1109/TKDE.2009.191>
- [11] Manolakis, D.; Shaw, G.: Detection Algorithms for Hyperspectral Imaging Applications, *IEEE Signal Processing Magazine*, **19** (2002) 1, 29-43, <https://doi.org/10.1109/79.974724>
- [12] Jolliffe, I. T.; Cadima, J.: Principal component analysis: a review and recent developments, *Philosophical Transactions of the Royal Society A*, **374** (2016) 20150202, <https://doi.org/10.1098/rsta.2015.0202>
- [13] Li, S.; Kang, X., Fang, L., Hu, J., Yin, H.: Deep learning for hyperspectral image classification: An overview, *IEEE Transactions on Geoscience and Remote Sensing*, **57** (2019) 9, 6690-6709, <https://doi.org/10.1109/TGRS.2019.2907932>

-
- [14] Chen, Y.; Lin, Z., Zhao, X., Wang, G., Gu, Y.: Deep Learning-Based Classification of Hyperspectral Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **7** (2014) 6, 2094-2107, <https://doi.org/10.1109/JSTARS.2014.2329330>
- [15] Hyvärinen, A.; Oja, E.: Independent component analysis: algorithms and applications, *Neural Networks*, **13** (2000) 4-5, 411-430, [https://doi.org/10.1016/S0893-6080\(00\)00026-5](https://doi.org/10.1016/S0893-6080(00)00026-5)
- [16] Lee, D. D.; Seung, H. S.: Learning the parts of objects by non-negative matrix factorization, *Nature*, **401** (1999) 788-791, <https://doi.org/10.1038/44565>

Integracija umjetne inteligencije u medicinske sustave i inteligentne sustave vožnje

Daniel Hofman¹, Martin Žagar²

¹Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva, Unska 3, 10000 Zagreb

²RIT Croatia, Damira Tomljanovića Gavrana 15, 10000 Zagreb

Sažetak: U posljednjem desetljeću umjetna inteligencija (UI) sve se intenzivnije primjenjuje u dvjema tehnološki komplementarnim domenama: medicinskoj robotici i automobilskoj industriji. U medicinskom kontekstu, razvijen je sustav koji omogućuje kirurškom osoblju interakciju s medicinskim slikovnim prikazima putem beskontaktnih metoda upravljanja, temeljenih na prepoznavanju gesta i praćenju pokreta ruku. Opisani pristup integrira obradu DICOM podataka, računalni vid i heurističke modele stanja geste, s ciljem smanjenja rizika kontaminacije u operacijskoj dvorani te unapređenja prostornog razumijevanja anatomskih struktura primjenom tehnologija proširene i virtualne stvarnosti.

U domeni automobilske sigurnosti, razvijena je metoda detekcije mrtvog kuta temeljena na fuziji podataka širokokutnih kamera i radarskih senzora. Kombinirani pristup nadilazi sigurnosna ograničenja jednostavnijih sustava te vozaču pruža pouzdaniju situacijsku svjesnost u kritičnim prometnim situacijama.

Cljučne riječi: umjetna inteligencija, medicinsko slikovno procesiranje, beskontaktna interakcija, detekcija mrtvog kuta, senzorska fuzija

1. Uvod

U posljednjem desetljeću umjetna inteligencija (UI) prodire u dvije naizgled različite, ali po mnogim načinima komplementarne domene: medicinu i automobilsku industriju. U medicini, UI omogućuje napredne metode za vizualizaciju, planiranje i izvođenje zahvata, od precizne dijagnostike bez dodira (engl. *contactless*) do kontrole tijekom operacija. U automobilima, UI i senzorne metode podupiru sustave pomoći vozaču (ADAS) kao što su detekcija mrtvog kuta, praćenje vozila i nadzor okolnog prostora. U ovom radu prikazan je razvoj koncepta i implementacije sustava koji omogućuju kirurzima interakciju s medicinskim slikama i operativnim prikazima bez fizičkog dodira -

koristeći gestikulaciju, praćenje ruku i 3D prikaze DICOM podataka. Glavne prednosti ovog pristupa su smanjenje rizika kontaminacije u operacijskoj dvorani, mogućnost intuitivnijeg i bržeg pregleda složenih 3D struktura (npr. kod planiranja zamjene kuka) te integracija proširene/virtualne stvarnosti za bolje prostorno razumijevanje anatomije pacijenta. Kreirani modul za praćenje ruke i interpretaciju gesta omogućuje osnovne naredbe (rotacija, zum, selekcija) nad medicinskim prikazima bez fizičkog kontakta kombinirajući računalni vid, filtarsku obradu signala i heurističke modele stanja geste. Ovaj rad ilustrira kako se postojeće standarde (npr. DICOM) može proširiti programskom podrškom koja UI čine dijelom kliničkog tijeka rada.

Slična se transformacija odvija i u automobilima, gdje se umjetna inteligencija postupno pretvara u ključni oslonac sigurnosti. Tijekom European Processor Initiative projekta razvijena je primjena UI na detekciju mrtvog kuta u vozilu. To je područje uz vozilo koje vozač ne može vidjeti, ali koje je redovito izvor najopasnijih prometnih situacija. Za razliku od tradicionalnih sustava koji se oslanjaju na jedan senzor, u ovom pristupu kombiniraju se širokokutne kamere i radarske jedinice, čime automobil dobiva dvostruku sigurnost pri odlučivanju. Kamere pružaju bogatstvo detalja, sposobnost prepoznavanja objekata i klasifikaciju, dok radari nude pouzdane podatke o udaljenosti i brzini drugih vozila. Kada automobil prepozna objekt u mrtvom kutu, ne radi to na temelju jedne slike ili jednog radarskog signala, već na temelju združene razumijevanja situacije. Zbog toga takav sustav nije samo tehnički dodatak vozilu, već inteligentni suradnik vozaču, upravo onakav kakvog kirurg ima u operacijskoj sali. I u jednom i u drugom slučaju UI postaje sigurnosna mreža odnosno dodatni osjet koji ljudskom oku ostaje skriven, ali koji može presudno utjecati na ishod.

Kada se pogleda u širem kontekstu, ovi primjeri otkrivaju fascinantnu srodnost među disciplinama. Kirurški zahvati i promet možda se odvijaju u različitim svjetovima, ali algoritmi koji pokreću obje domene dijele isto tehnološko srce: neuronske mreže koje prepoznaju obrasce, sustave fuzije podataka koji spajaju različite senzore, modele optimizirane za rad pod vremenskim ograničenjem i, iznad svega, potrebu za pouzdanjem u ambijentima u kojima pogreška nije dopuštena. Umjetna inteligencija u oba slučaja mora biti brza, robusna i iznimno predvidiva; mora djelovati neprimjetno, ali učinkovito; mora biti alat, a ne gospodar odluka. Zato sinergija između medicine i automobilske industrije nije slučajna.

2. Primjena umjetne inteligencije u medicinskim sustavima – analiza trenutnih metoda

2.1 Kontekst i motivacija: od 2D prema 3D kirurškom okruženju

Zamislite kirurga koji priprema složeni zahvat na paranazalnim sinusima. Pred njim se nalazi niz CT presjeka na ekranu. To su tanki, dvodimenzionalni slojevi anatomije

koje mora mentalno složiti u trodimenzionalnu cjelinu dok istovremeno planira svaki milimetar operacije. Upravo taj svakodnevni kognitivni napor koji se ponavlja od zahvata do zahvata predstavlja jedan od temeljnih i nedovoljno prepoznatih izvora kirurškog umora [1, 2]. Nije u pitanju nedostatak znanja ili iskustva; radi se o inherentnom nesrazmjeru između trodimenzionalne stvarnosti operativnog polja i dvodimenzionalnih alata kojima kirurg gradi svoju predodžbu o njemu. Taj jaz između percepcijskog ulaza i operativne stvarnosti izravno utječe na preciznost odlučivanja, posebice u dugotrajnim ili sekvencijalnim zahvatima.

Iz telemedicinske perspektive, ovaj problem dobiva dodatnu dimenziju. Telemedicina, u najširem smislu, podrazumijeva prijenos medicinske stručnosti bez fizičke prisutnosti liječnika. Kada se ta paradigma primijeni na kirurgiju, pojavljuje se fascinirajuća mogućnost: virtualni kirurški prostor u kojemu kirurg i rekonstruirana pacijentova anatomija koegzistiraju u istom digitalnom okruženju, neovisno o geografiji ili fizičkim ograničenjima operacijske dvorane. Integracija UI-a u ovaj prostor nije puki tehnološki dodatak, ona mijenja samu prirodu kirurškog čina, preoblikujući kirurga od operatera koji reagira na fizičke uvjete u navigatora koji aktivno upravlja digitalnim modelom anatomije.

Ovo poglavlje sustavno prolazi kroz trenutne metode koje taj prijelaz čine mogućim. Posebno se usredotočujemo na tri međusobno isprepletena područja: beskontaktno upravljanje medicinskim prikazima putem prepoznavanja gesta i praćenja pokreta ruku; obradu i vizualizaciju DICOM podataka u 3D, VR i AR okruženjima; te modele dubokog učenja koji u stvarnom vremenu interpretiraju namjere korisnika.

2.2 Metode praćenja pokreta ruku i prepoznavanja gesta u kirurškom okruženju

2.2.1 Evolucija pristupa: od markerskih do sustava bez markera

Ideja da kirurg može upravljati medicinskim prikazima pokretima ruku, bez dodirivanja tipkovnice, ekrana ili sterilnog instrumentarija, nije nova. Pionirski radovi s početka 2010-ih oslanjali su se na specijalizirani hardver: Leap Motion kontroler s infracrvenim senzorima koji prate 21 anatomska točka šake s latencijom ispod 10 milisekundi, te Intel RealSense kamere koje dubinskim senzorima rekonstruiraju trodimenzionalni položaj ruku u prostoru [3, 4]. Ti su sustavi bili tehnički impresivni, no klinička primjena otkrila je njihove granice: operacijska dvorana nije laboratorij. Reflektirajuće površine sterilnog instrumentarija, varijabilno kirurško osvjetljenje, a posebno kirurške rukavice koje mijenjaju optička svojstva kože, sve je to sustavno degradiralo performanse sustava koji su u kontroliranim uvjetima funkcionirali gotovo savršeno [4, 5].

Prijelomna točka nastupila je 2020. godine kada je Google objavio MediaPipe Hands, okvir koji iz jedne obične RGB kamere ekstrahira položaj 21 anatomske točke šake, bez ikakvog specijaliziranog hardvera, primjenom konvolucijskih neuronskih mreža u dva koraka: prvo detekcija dlana, zatim precizna estimacija položaja svih ključnih točaka [6]. Ono što je ranije zahtijevalo skupi senzor, sada je radio algoritam na standardnoj kameri. Sustavna medicinska validacija provedena na Politecnico di Torino (2023) pokazala je visoku konzistentnost MediaPipe okvira sa zlatnim standardima za hvatanje pokreta, uz prosječnu prostornu pogrešku od svega 3,1 mm [7]. No ista studija jasno je ukazala i na granice: fini pokreti prstiju ostaju metodološki izazov svuda gdje je potrebna submilimetarska preciznost [7, 8].

Opsežni sustavni pregled koji su Yangi i suradnici (2025) proveli pregledom 225 radova iz baza Medline, Scopus i Embase, uključivši 77 studija koje su prošle rigorozne kriterije odabira, zorno prikazuje kako se ovo polje razvijalo: do 2017. primjena AI u praćenju kirurških instrumenata i ruku bila je rubna pojava, a od 2018. bilježi eksponencijalni rast [9]. Algoritmi dubokog učenja (62 studije) daleko su nadmašili klasične pristupe strojnog učenja (15 studija), a primjena je najčešća u općoj kirurgiji, neurokirurgiji i oftalmologiji, pretežito u laparoskopskim i robotski asistiranim zahvatima [9].

2.2.2 Metode dubokog učenja za klasifikaciju gesta

Prepoznavanje gesta u kirurškom okruženju nije samo tehnički problem, već i semantički. Nije dovoljno znati gdje se ruka nalazi u prostoru; sustav mora razumjeti što kirurg namjerava učiniti. Taj skok od detekcije k interpretaciji namjere postignut je metodama dubokog učenja koje kombiniraju podatke iz više izvora: videozapise endoskopskih kamera, kinematske podatke robotskih sustava i, u nekim pristupima, čak i elektroencefalografske signale. DiPietro i suradnici demonstrirali su da rekurentne neuronske mreže (RNN) mogu prepoznati kirurške manevre s površinom ispod ROC krivulje od 0,88 za identifikaciju i 0,87 za klasifikaciju gesta šivanja što je postignuto na stvarnim snimkama robotski asistirane radikalne prostatektomije [10]. Kiyasseh i suradnici otišli su korak dalje, treniranjem vizualnog transformatora na kirurškim videozapisima iz više ustanova za disekcijske geste ovisno o specifičnoj proceduri [11].

Pri tome su obećavajući smjer hibridne arhitekture koje MediaPipe koriste samo kao prvi sloj obrade, a zatim te podatke prosljeđuju dubokim mrežama za vremensku analizu. Jedan takav trostruki model, koji integrira MediaPipe, Inception-v3 i LSTM mrežu za klasifikaciju sekvenci, postiže značajno poboljšanje točnosti nad jednomodalnim pristupima, i to uz redukciju dimenzija okvira s 1600×900 na samo 50×60 piksela, što je računalna ušteda koja u realnom kirurškom okruženju znači razliku između prihvatljive i neprihvatljive latencije [12]. Ovaj kompromis između preciznosti i brzine oduvijek je temelj kirurške informatike.

Primjer iz prakse dolazi od Wang i suradnika (2023), koji su razvili sustav ljudsko-robotske suradnje za kiruršku navigaciju temeljen isključivo na prepoznavanju gesta ruku. Njihov rad posebno se bavi problemom koji je u laboratorijskim uvjetima lako zanemariti, no u operacijskoj dvorani postaje kritičan: kako razlikovati namjernu gestu od slučajnog pokreta kirurga koji se, recimo, miče da bi uočio bolje osvjetljenje polja? Smanjenje lažnih aktivacija nije samo pitanje ergonomije, u kirurškom kontekstu neželjeni pokreti slike mogu direktno ugroziti sigurnost zahvata [13].

2.2.3 Ograničenja i izazovi postojećih pristupa

Detaljno razmatranje ove domene ne može zaobići njezine otvorene probleme. MediaPipe, unatoč svim prednostima, donosi nekoliko strukturnih ograničenja koja postaju vidljiva upravo u kliničkim uvjetima. Točnost sustava dokumentirano opada pri tamnijem tonu kože korisnika, što upućuje na pristranost u skupovima podataka za treniranje i zahtijeva aktivno ulaganje u reprezentativnije podatke [8]. Nadalje, MediaPipe generira tzv. “2.5D” estimaciju: z koordinata nije direktno izmjerena, nego izvedena iz 2D projekcije. Taj korak zahtijeva naknadne matematičke korekcije, rješavanje putem Perspective-n-Point problema, koje unose dodatno kašnjenje i potencijalnu pogrešku [9]. I naposljetku, svaki generički model treniran na laboratorijskim podacima mora proći specifično fino podešavanje za klinički kontekst operacijske dvorane, što je resursno intenzivan proces koji zahtijeva suradnju između inženjera i kliničara [5, 7].

Ove nalaze potvrđuju i radovi [4, 5] gdje su razvijeni modul za praćenje ruke i interpretaciju gesta u kontekstu beskontaktno kirurgije, ali se i navodi da DLIB i MediaPipe Hands u operacijskim uvjetima pokazuju ograničenja u brzini, točnosti i stabilnosti pri varijabilnom osvjetljenju. Upravo ta klinička iskustva motivirala su razvoj nadopunjenih rješenja koja kombiniraju računalni vid s filtriranjem signala i heurističkim modelima stanja geste, pristup koji je rezultat dijaloga između laboratorijskog istraživanja i operacijske prakse.

2.3 Obrada DICOM podataka i 3D vizualizacija u proširenoj i virtualnoj stvarnosti

2.3.1 DICOM kao temelj medicinskog digitalnog ekosustava

DICOM (engl. *Digital Imaging and Communications in Medicine*) je standard koji stoji iza gotovo svakog medicinskog skenera, svakog bolničkog sustava za pohranu slika, svakog radiologa koji pregledava CT na ekranu. Definiše format podataka, protokole prijenosa i pravila prikaza, čineći interoperabilnost između heterogenih uređaja i ustanova mogućom. No klasična DICOM vizualizacija ostaje fundamentalno pasivna i dvodimenzionalna: kirurg lista presjeke kao stranice knjige, a trodimenzi-

onalna anatomija postoji samo u njegovoj glavi. Taj jaz između bogatstva informacija skrivenih u DICOM datotekama i načina na koji se te informacije prezentiraju kirurgu, upravo je ono što moderni AI sustavi nastoje premostiti. Naši raniji radovi pokazali su da se efikasna obrada volumetrijskih podataka postiže kompresijom 4D medicinskih podataka (prostorno-vremenska redundancija) pomoću *motion estimation* i 3D *wavelet* transformacija, čime se omogućuje brža pohrana i prijenos dinamičkih medicinskih slika potrebnih za VR/AR navigaciju [14].

Suvremene platforme poput MedicalHolodeck i Medivis SurgicalAR idu korak dalje od običnog 3D renderiranja: one integriraju DICOM podatke s naglavnih AR uređaja, npr. HoloLens 2, Magic Leap, i holografski projiciraju pacijentovu anatomiju direktno u prostor operacijske dvorane, superponiranu na operativno polje [15]. Johns Hopkins University objavio je 2021. rezultate prvih kirurških zahvata vođenih takvom AR navigacijom, a Stanford Medicine je početkom 2024. demonstrirala primjenu AR-a za vizualizaciju podataka u stvarnom vremenu za vrijeme operacije [16]. Ove kliničke implementacije nisu dokazi koncepta, one su dokazi zrelosti tehnologije.

2.3.2 Proširena i virtualna stvarnost u preoperativnom planiranju i intraoperativnoj navigaciji

Virtualna i proširena stvarnost u kirurgiji prešle su dug put od svojih začetaka u kasnim 1990-ima, kada su bile rezervirane za specijalizirane istraživačke centre. Sustavni pregled *Extended Reality* (XR) u kirurgiji, objavljen 2025. godine, dokumentira kako se ta evolucija odvijala: od prvih eksperimentalnih VR simulatora prema sofisticiranim *mixed reality* sustavima koji danas pokrivaju cijeli kirurški put, od preoperativnog planiranja i intraoperativne navigacije do postoperativne rehabilitacije [17]. U ortopediji, volumetrijski modeli izvedeni iz CT podataka omogućuju planiranje točnih trajektorija implantata i rano otkrivanje anatomske varijante koje bi mogle komplicirati zahvat. Temelj za takve modele čine metode segmentacije i klasifikacije 3D objekata koje razdvajaju scenu na značajne podregije na temelju oblika, teksture i konteksta, što je ključno za preciznu rekonstrukciju u VR/AR okruženjima [18]. U neurokirurgiji, BrainLab platforma već godinama koristi MRI slike za precizno mapiranje mozga i definiranje sigurnih kirurških koridora prema dubokim lezijama [19].

Intraoperativna AR navigacija pokazala je konkretne kliničke dobiti. Molina i suradnici dokumentirali su prvu kliničku primjenu AR stereotaktičke navigacije u kirurgiji kralježnice uz visoku kliničku točnost, dok je tim sa Sveučilišta u Pennsylvaniji pokazao kako HoloLens 2 smanjuje potrebu za rendgenskim ozračivanjem pri CT-vođenom ciljanju lezija [16]. U otorinolaringologiji, disciplini koja je bila pionir čitavog ovog polja, Žagar i suradnici (2022) implementirali su beskontaktno upravljanje 3D virtualnom endoskopijom s validiranom kontrolom rotacije, zumiranja i selekcije regija interesa putem gesta, čime su spojili DICOM ekosustav s VR okruženjem na klinički upotrebljiv način [5].

Vrijedi primijetiti strukturnu srodnost koja se ovdje pojavljuje: princip koji Liu i suradnici (2024) opisuju za evoluciju kirurških robotskih sustava, AI kao posrednik između senzornih podataka i donošenja odluka, koji integrira informacije iz kamera, radarskih senzora i medicinskih slika u kohezivnu situacijsku svjesnost [21], identičan je principu koji stoji u temelju sustava za detekciju mrtvog kuta u automobilima. Ta konvergencija nije slučajna; ona odražava duboku zajedničku logiku senzorske fuzije koja prožima suvremenu primijenjenu AI.

2.4 Uloga umjetne inteligencije u smanjivanju kirurškog umora i kognitivnih predrasuda

Kada su Tversky i Kahneman još 1974. godine opisali kako ljudski mozak sustavno skraćuje putove pri donošenju odluka pod nesigurnošću [21], nisu imali na umu kirurge. No gotovo pola stoljeća istraživanja potvrdilo je da su kirurzi, unatoč visokom obrazovanju i strogoj selekciji, u toj neurofiziološkoj mjeri jednako ranjivi kao i svi ostali. Armstrong i suradnici (2023) proveli su sustavni pregled koji je obuhvatio 39 studija, više od 6.500 kirurga i 200.000 pacijenata, identificirajući čak 31 različitu vrstu kognitivne predrasude u kirurškim okruženjima; najčešće su pretjerano samopouzdanje i predrasuda potvrde [22]. Saposnik i suradnici (2016) u pregledu 20 studija s ukupno 6.810 liječnika pronašli su dijagnostičke greške u svim analiziranim studijama, a terapijske greške u pet od sedam [23]. Ove brojke nisu apstrakcija, problem je u tome što iza svake brojke stoji pacijent.

Kirurški umor ove tendencije ne uzrokuje, ali ih nedvojbeno pojačava. Janhofer i suradnici (2019) opisuju umor kao višedimenzionalan fenomen, fizički, kognitivni i emotivni, i ističu posebno prirodu mentalnog umora koji nastaje iz repetitivnog prevođenja 2D slika u 3D mentalne modele: kirurg ga ne doživljava kao problem, nego kao normalan dio radnog dana [24]. Park i suradnici (2017) pokazali su u svojoj studiji da kratke ciljane pauze s istezanjem statistički značajno poboljšavaju i fizičku funkciju i mentalnu fokusiranost kirurga [1]. No, koliko god korisne bile, te pauze ne adresiraju temeljni uzrok, kognitivni mehanizam koji umor generira.

Je li moguće taj mehanizam neutralizirati samim oblikovanjem radnog okruženja? Neurofiziološki dokazi sugeriraju da jest. fMRI studija Clemente i suradnika (2013) pokazala je da osjećaj prisutnosti u virtualnom okruženju negativno korelira s aktivacijom dorzolateralnog prefrontalnog korteksa, jednog od ključnih čvorišta kognitivnog napora [25]. Drugim riječima, u 3D prostoru mozak radi drugačije, i naizgled lakše. EEG studije koje uspoređuju 3D-VR i konvencionalna 2D iskustva konzistentno pokazuju višu globalnu mrežnu učinkovitost, jače emotivno uzbuđenje i veću beta-EEG snagu u VR uvjetima, što su sve zajedno indikatori povoljnijeg kognitivnog stanja [26, 27].

Istraživanje Gangemi i suradnika (2023), provedeno na pacijentima nakon moždanog udara koji su prolazili VR kognitivni trening, otkriva još intrigantnu mogućnost: da VR okruženje aktivno potiče neuroplastičnost pri čemu je povećanje alfa snage u okcipitalnim i beta snage u frontalnim područjima dokumentirano kao znak funkcionalne reorganizacije mozga [28]. Iz toga se otvara pitanje kojim se naš tim već bavi: može li beskontaktna kirurgija u VR okruženju ne samo smanjiti umor, nego i dugoročno poboljšati kognitivne kapacitete kirurga? To nije špekulacija nego hipoteza koja zahtijeva longitudinalna istraživanja, ali koja ima solidnu fiziološku osnovu.

2.5 Robotski asistirani kirurški sustavi s AI integracijom: trenutno stanje

Robotska kirurgija najzrelija je grana primjene AI-a u medicini, ona ima kliničku povijest, regulatorne okvire i mjerljive ishode. Liu i suradnici (2024) u opsežnom pregledu evolucije kirurških robotskih sustava identificiraju AI integraciju kao ključni razvojni vektor koji adresira ograničenja koja su godinama bila Ahilova peta ovog polja: ograničenu autonomiju, odsutnost haptičke povratne informacije i slabu adaptabilnost na neočekivane intraoperativne situacije [20]. Meta-analiza 25 studija iz 2024. i 2025. godine kvantificira učinak AI-asistiranih robotskih operacija, 25 % skraćanje trajanja zahvata i 30 % smanjenje intraoperativnih komplikacija u usporedbi s manualnim metodama [29]. Ove su brojke dovoljno robusne da u kliničkim krugovima mijenjaju pitanje s “treba li” na “kako i kada”.

Napredniji robotski sustavi danas integriraju nekoliko AI slojeva istovremeno: računalni vid za segmentaciju tkiva i prepoznavanje kritičnih anatomskih struktura, planiranje trajektorija instrumenta, prediktivnu analitiku komplikacija i poluautonomno izvođenje pojedinih faza zahvata. Stanford University razvio je sustav koji kombinira računalni vid s algoritmima pojačanog učenja za dinamičnu prilagodbu kirurških trajektorija u stvarnom vremenu; u istraživanju s 120 operacija kralježnice postignut je pad od 42 % u vremenu postavljanja pedikularnih vijaka uz stopu komplikacija ispod 0,8 % [30]. Morris i suradnici (2024) jasno formuliraju suštinu ovog razvoja: strojni vid robotskim sustavima ne daje samo preciznost, nego im daje i situacijsku svjesnost [31].

Za telemedicinski kontekst posebno je važna priča o latenciji. Suvremene telekirurške platforme ciljaju kašnjenja ispod 10 milisekundi što je fiziološki prag ispod kojeg kirurg ne percipira razliku u odgovoru sustava. Primjena 5G mreža i *edge computing* učinila je ovaj cilj ostvarivim u urbanim sredinama, a istraživanje ga aktivno gura prema ruralnim i resursno siromašnim okruženjima. Ovi sustavi ne demokratiziraju samo pristup visokokvalitetnoj kirurškoj skrbi, nego transformiraju i sam model obrazovanja kirurga, omogućavajući iskusnim kirurzima da u stvarnom vremenu asistiraju i mentoriraju kolege na geografski udaljenim lokacijama [29, 31].

2.6 Sinteza: konvergentne i divergentne karakteristike trenutnih metoda

Kad sagledamo cjelinu dosad analiziranih metoda, uočavamo nekoliko jasnih silnica koje oblikuju razvoj AI-podržanih kirurških sustava. Dominira pomak od jednododalnih prema multimodalnim sustavima koji podatke iz kamera, senzora dubine, kinematskih senzora i medicinskih slika stapaju u jedinstvenu reprezentaciju kirurškog polja. Arhitekture dubokog učenja, posebno konvolucijske mreže za prostornu analizu i rekurentne ili transformatorske mreže za vremensku sekvencijalnu analizu, postale su *de facto* standard, potiskujući klasične pristupe strojnog učenja. I sve je glasnjiji zahtjev za kliničkom validacijom i regulatornom prihvatljivošću, koji zahtijeva rigorozne studije i dugotrajna longitudinalna praćenja.

Divergencije pak odražavaju specifičnosti primjene. Sustavi za beskontaktnu navigaciju stavljaju u prioritet nisku latenciju i otpornost na nepredvidive uvjete okruženja gdje se ni jedan kirurški prikaz ne smije “zamrznuti” u kritičnom trenutku. Robotski kirurški sustavi pak mogu si priuštiti nešto više računalne složenosti u zamjenu za preciznost i predvidivost u kontroliranim uvjetima. No oba smjera suočavaju se s istim temeljnim izazovom: jaz između laboratorijskih performansi i kliničke svakodnevice ne smanjuje se sam od sebe. U operacijskoj dvorani nepredvidivost je pravilo, a ne iznimka.

Guni i suradnici (2024) u European Surgical Research artikuliraju konsenzus koji se sve jasnije ocrta u literaturi: AI za kirurgiju prešla je kritičnu točku, a napredak algoritama i operacionalizacija sustava otvaraju vrata transformaciji cijelog kirurškog puta pacijenta, od rane dijagnostike do postoperativnog praćenja [32]. No možda je najvažniji zaključak ovog pregleda upravo onaj manje tehnički: sustavi koji zaista mijenjaju kliničku praksu nisu oni koji se razvijaju u izolaciji laboratorija, nego oni koji nastaju iz stvarnog dijaloga između inženjera i kirurga koji stoji pred pacijentom. Taj dijalog, s kojim je naš tim počeo još 2017. godine, i dalje je najvažniji metodološki alat koji imamo.

3. Primjena umjetne inteligencije u inteligentnim sustavima vožnje: analiza trenutnih metoda

3.1 Od asistencije do autonomije: razvojni put inteligentnih vozila

Razvoj autonomnih vozila jedan je od najambicioznijih tehnoloških razvoja suvremenog doba. Ne odvija se linearno, nego kroz postupno osvajanje razina autonomije koje je Society of Automotive Engineers (SAE) definirao skalom od 0 do 5, od potpuno ručne vožnje do potpune autonomije bez ljudske intervencije [33]. Danas su komercijalno dostupni sustavi uglavnom na razinama 2 i 3, gdje vozilo može

preuzeti kontrolu u ograničenim uvjetima, no zahtijeva stalnu vozačevu pažnju kao sigurnosnu mrežu [34]. Taj prijelaz s razine 2 na razinu 3 i dalje nije samo inženjerski problem. On je i regulatorni, etički i epistemološki: kako projektirati sustav koji zna granice vlastite pouzdanosti i koji zna kada predati kontrolu čovjeku? Upravo tu umjetna inteligencija prestaje biti puki alat obrade podataka i postaje arhitekt odluka pod nesigurnošću.

Senzorska arhitektura suvremenih autonomnih vozila tipično kombinira LiDAR, radar i kamerom bazirane sustave računalnog vida, čija se komplementarna osjetljivost na različite uvjete vidljivosti, osvjetljenja i brzine stapaju algoritmima senzorske fuzije u jedinstvenu situacijsku sliku okoline vozila [35]. Kamere pružaju gustu semantičku informaciju i fine vizualne detalje, LiDAR generira precizne 3D oblake točaka za geometrijsku rekonstrukciju scene, dok radar nudi pouzdane podatke o udaljenosti i brzini objekata u svim vremenskim uvjetima, uključujući kišu, maglu i snijeg koji degradiraju performanse ostalih senzora [35, 36].

Duboke konvolucijske neuronske mreže i transformatorski modeli preuzeli su dominantnu ulogu u obradi vizualnih podataka od detekcije i klasifikacije objekata (pješači, biciklisti, semafori, privremene prepreke) do semantičke segmentacije prometne scene u stvarnom vremenu [37, 38].

Pritom je ključni izazov koji razdvaja laboratorijsku demonstraciju od prometne primjenljivosti isti kao i u kirurgiji: sustav mora biti robustan na uvjete koji nisu zastupljeni u skupovima podataka za treniranje, uključujući neobične konfiguracije raskrižja, rijetke, ali kritične prometne situacije, te degradiranu kvalitetu senzorskog signala uslijed nepovoljnih vremenskih uvjeta [35]. Taj jaz između kontroliranih uvjeta validacije i nepredvidivosti stvarnog prometa temeljni je razlog zašto je razvoj autonomnih vozila razine 4 i 5 sporiji od ranih prognoza i zašto se fokus industrije i regulatora sve više premješta prema hibridnim pristupima koji ne eliminiraju vozača, nego mu pružaju sve sofisticiranije alate za donošenje odluka [34, 36].

3.2 Detekcija mrtvog kuta kao primjer primjene umjetne inteligencije u sustavima potpore vozaču

Jedan od najilustrativnijih primjera primjene umjetne inteligencije u sustavima potpore vozaču jest detekcija mrtvog kuta koji predstavlja područja uz bočne strane vozila koje vozač ne može vidjeti ni izravno ni u retrovizorima, a koja su redovito izvor najopasnijih prometnih situacija (Slika 1).



Slika 1: Prikaz detekcije vozila u mrtvom kutu

U sklopu European Processor Initiative (EPI) projekta razvijen je i validiran sustav detekcije mrtvog kuta koji počiva na principu višemodalne senzorske fuzije: dvije širokokutne *fish-eye* kamere rezolucije 1280×960 piksela, postavljene lijevo i desno od vozila, pružaju vizualnu informaciju o prometnoj situaciji, dok radarski senzori smješteni na stražnjem dijelu vozila paralelno i neovisno prate objekte u kritičnoj zoni [39]. Ključna arhitekturna odluka pritom nije bila izbor pojedinog senzora, nego upravo njihova komplementarnost: kamera pruža bogatu semantičku informaciju i omogućuje klasifikaciju objekata, dok radar osigurava pouzdane podatke o udaljenosti i brzini čak i pri nepovoljnim uvjetima vidljivosti.

Obrada slike odvija se kroz Jaguar okvir za procesiranje i detekciju objekata, koji koristi kvantiziranu i optimiziranu inačicu MobileNet-V2 arhitekture prilagođenu *fish-eye* ulazu, treniranu na Woodscape skupu podataka pri čemu je sustav postigao propusnost od 29 sličica u sekundi na GPU platformi, a nakon integracije s radarskim podacima na R-Car-H3 platformi čitavi senzorski lanac radi na razini iznad 30 sličica u sekundi, što zadovoljava zahtjeve automobilske primjene u stvarnom vremenu [39].

Taj primjer zorno ilustrira širu logiku multimodalne percepcije u autonomnoj vožnji: ni jedna senzorska modalnost sama po sebi nije dovoljna za pouzdanu situacijsku svjesnost, ali njihovom fuzijom na razini visoke apstrakcije sustav dobiva robusnost koja nadilazi mogućnosti svakog pojedinog senzora. To je analogno načelu kojim kirurški sustavi opisani u prethodnom poglavlju spajaju podatke iz kamera, dubinskih senzora i medicinskih slika u jedinstvenu reprezentaciju operativnog polja.

3.3 Trenutni razvojni status autonomnih vozila i perspektive komercijalizacije

Komercijalna stvarnost autonomnih vozila krajem 2025. godine zrcali isti jaz koji smo u medicinskom kontekstu opisali između laboratorijskih performansi i kliničke primjene: tehnološka mogućnost i tržišna stvarnost odvajaju se širim jazom nego što su rane prognoze sugerirale. Kompanija Waymo koja je pionir komercijalne autonomne vožnje isporučila je više od 14 milijuna vožnji u 2025. godini, tri puta više nego godinu ranije, te je operativno prisutna u 10 američkih gradova sa flotom od oko 2.500 robotaksija koji rade bez sigurnosnog vozača [40].

Taj podatak, međutim, valja staviti u perspektivu: Waymo trenutno pokriva otprilike 3 % američke populacije, unatoč više od desetljeća intenzivnog razvoja i ulaganja koja premašuju 100 milijardi dolara u čitavom sektoru [40]. Tesla slijedi bitno drukčiju strategiju sa sustavom koji se oslanja isključivo na kamere i duboke neuronske mreže umjesto skupih LiDAR senzora, no njezin pilot program u Austinu, pokrenut sredinom 2025., i dalje radi uz nazočnost sigurnosnog operatera u vozilu, što ga svrstava na razinu 2 prema SAE klasifikaciji [40].

Ta razlika u pristupu između Waymovog senzorski bogatog sustava i Teslinog vizijskog modela nije samo tehnički detalj već ona odražava temeljno različite pretpostavke o tome koje su minimalne senzorske modalnosti dostatne za sigurnu autonomnu vožnju u nepredvidivim urbanim uvjetima. Prognoza S&P Global Mobility iz prosinca 2025. snažno relativizira ambiciozne industrijske narative: američko tržište autonomnih lakih vozila dosegnut će prema njihovim procjenama oko 85.000 jedinica godišnje do 2035. godine, što odgovara udjelu od oko 0,5 % ukupne prodaje [40].

Istovremeno, AAA istraživanje provedeno početkom 2025. bilježi da 61 % američkih vozača osjeća strah, a dodatnih 26 % nesigurnost prema autonomnim vozilima [41]. Taj podatak podsjeća da tehnička robusnost sustava i javno povjerenje u njega nisu ista varijabla, baš kao što ni prihvaćanje kirurške robotike u kliničkoj zajednici nije automatski slijedilo iz tehničke izvedivosti.

Kineski sektori razvijaju se brže zahvaljujući povoljnijem regulatornom okruženju: Baiduov Apollo Go sustav dostigao je 250.000 autonomnih vožnji tjedno samo u Kini do listopada 2025., što jasno pokazuje kako regulatorna politika, a ne isključivo tehnološka zrelost, određuje brzinu komercijalizacije [40]. Sve ove silnice zajedno upozoravaju na paradoks koji karakterizira suvremeni razvoj autonomne vožnje: algoritmi su dovoljno zreli da vožnju u određenim uvjetima obavljaju sigurnije od prosječnog ljudskog vozača, ali su istodobno nedovoljno robusni za rubne slučajeve koji se u stvarnom prometu pojavljuju nepredvidivo i nerijetko.

Upravo taj jaz između demonstracijske izvrsnosti i operativne pouzdanosti ostaje ključni neriješeni problem, jednak onome s kojim se suočavaju i kirurški AI sustavi.

4. Zaključak

Analiza obiju primjena ukazuje na zajedničko tehnološko ishodište koje nadilazi slučajnu srodnost dviju naizgled odvojenih disciplina. I kirurški sustavi za beskontaktnu navigaciju medicinskim prikazima i sustavi za detekciju mrtvog kuta u autonomnoj vožnji dijele isti temeljni arhitekturni obrazac: duboke neuronske mreže za prepoznavanje uzoraka u vizualnim podacima, višesenzorsku fuziju koja komplementarne modalnosti spaja u jedinstvenu situacijsku predodžbu, te optimizaciju modela za rad u uvjetima strogih vremenskih ograničenja.

U oba slučaja umjetna inteligencija djeluje kao pouzdani pomoćni sustav koji povećava sigurnost bez preuzimanja autonomije u donošenju odluka. Upravo je ta ograničena, ali visoko specijalizirana uloga ključ za razumijevanje trenutne i buduće vrijednosti ovih sustava.

Konvergencija koju ovaj rad prikazuje nije samo tehnička: ona je i epistemološka. I kirurgija i autonomna vožnja suočavaju se s istim temeljnim pitanjem, a to je kako izgraditi sustav koji u ambijentima gdje pogreška nije dopuštena djeluje dovoljno brzo da bude koristan, a dovoljno oprezno da ne postane opasan.

Odgovor koji oba područja nude konvergentan je: ne potpunom autonomijom, nego hibridnim modelima u kojima umjetna inteligencija preuzima kognitivno najzahtjevnije zadatke percepcije i obrade podataka, dok konačna odgovornost za odluku ostaje na čovjeku, kirurgu koji drži skalpel ili vozaču koji prati promet.

Taj princip komplementarnosti, a ne zamjene, nije privremeni kompromis na putu prema potpunoj autonomiji: on je, prema svemu što suvremena literatura sugerira, optimalni model za primjene u kojima su posljedice pogreške ireverzibilne.

Budući razvoj u oba područja slijedi nekoliko zajedničkih vektora. Modeli će postajati više multimodalni, integrirajući sve širi spektar senzorskih ulaza i kontekstualnih informacija u jedinstvenu reprezentaciju okoline. Zahtjevi za energetskom učinkovitosti koji su posebno izraženi u ugradbenim odnosno mobilnim sustavima, potaknut će daljnju optimizaciju i specijalizaciju hardverskih platformi.

Regulatorni okviri, koji u oba područja zaostaju za tempom tehnološkog razvoja, postupno će sazrijevati i time otvarati prostor za širu kliničku i prometnu primjenu validiranih sustava. Iznimno važan, a često nedovoljno naglašen vektor je pitanje objašnjivosti: kirurg i vozač trebaju razumjeti zašto je sustav donio određenu odluku, ne samo što je ta odluka bila.

XAI (engl. *Explainable Artificial Intelligence*) pristupi, koji opravdanje za ishode modela čine interpretabilnima za ljude koji su za te ishode odgovorni, postaju stoga ne opcijskim dodatkom već regulatornim i etičkim preduvjetom primjene u visokokritičnim domenama.

Konačno, iskustvo koje ovaj rad sintetizira sugerira metodološku pouku koja nadilazi oba konkretna slučaja: sustavi umjetne inteligencije koji zaista mijenjaju praksu nisu oni koji nastaju iz čiste tehničke izvrsnosti, nego oni koji nastaju iz dijaloškog procesa između inženjera koji razumiju mogućnosti i praktičara koji razumiju potrebe. Beskontaktna kirurgija razvijena je u dijalogu s otorinolaringolozima dok je detekcija mrtvog kuta validirana na stvarnom BMW X5 testnom vozilu u realnim prometnim uvjetima.

Oba puta vode do iste spoznaje: umjetna inteligencija nije cilj sam sebi, nego sredstvo kojim stručnjaci, primjerice kirurzi i vozači, liječnici i inženjeri, mogu djelovati preciznije, sigurnije i s većom sigurnošću da će njihove odluke biti podržane najboljim raspoloživim znanjem o situaciji u kojoj se nalaze.

5. Literatura

- [1] Park, A.E.; Zahiri, H.R., Hallbeck, M.S., Augenstein, V., Sutton, E., Yu, D., Lowndes, B. R., Bingener, J.: Intraoperative Micro Breaks With Targeted Stretching Enhance Surgeon Physical Function and Mental Focus: A Multicenter Cohort Study, *Annals of Surgery*, **265** (2017) 2, 340-346, <https://doi.org/10.1097/SLA.0000000000001665>
- [2] Žagar, M.; Klapan, I., Mutka, A., Majhen, Z.: Contactless Interface for Navigation in Medical Imaging Systems, *Intelligent Systems and Applications. IntelliSys 2021. Lecture Notes in Networks and Systems*, **295** (2022), https://doi.org/10.1007/978-3-030-82196-8_3
- [3] Marin, G.; Dominio F., Zanuttigh P.: Hand Gesture Recognition with Leap Motion and Kinect Devices, *Proc IEEE Int Conf Image Processing (ICIP)*, (2014) 1565-1569, <https://doi.org/10.1109/ICIP.2014.7025313>
- [4] Žagar, M.; Mutka, A., Klapan, I., Majhen, Z.: Hand and gesture module for enabling contactless surgery, *Trends in Telemed & e-Health*, **3** (2021) 1, 1-5, <https://doi.org/10.31031/TTEH.2021.03.000553>
- [5] Žagar, M.; Klapan, I., Mutka, A., Majhen, Z.: Implementation Details for Controlling Contactless 3D Virtual Endoscopy, *Applied Sciences (MDPI)*, **12** (2022) 11, 5757, <https://doi.org/10.3390/app12115757>
- [6] Zhang, F.; Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C., Grundmann, M.: MediaPipe Hands: On-device real-time hand tracking, (2020), arXiv:2006.10214 [cs.CV], <https://doi.org/10.48550/arXiv.2006.10214>
- [7] Amprimo, G.; Masi, G., Pettiti, G., Olmo, G., Priano, L., Ferraris, C.: Hand tracking for clinical applications: validation of the Google MediaPipe Hand (GMH) and the depth-enhanced GMH-D frameworks, *Biomed Signal Process Control*, **96** (2024) 106508, <https://doi.org/10.1016/j.bspc.2024.106508>
- [8] Budzinski, C.; Wu, H., Sarraf, E., Miller, S., Moore, J.: Accuracy of Mediapipe Visual Hand Tracking for use in Medical Training Procedures, *Proc ASME Design of Medical Devices Conf.*, (2024), V001T08A004, <https://doi.org/10.1115/DMD2024-1039>

- [9] Yangi K.; On, T.J., Xu, Y., Gholami, A.S., Hong, J., Reed, A.G., Puppalla, P., Chen, J., Tangsrivimol, J.A., Li, B., Santello, M., Lawton, M.T., Preul, M.C.: Artificial intelligence integration in surgery through hand and instrument tracking: a systematic literature review, *Front. Surg.*, **12** (2025) 1528362, <https://doi.org/10.3389/fsurg.2025.1528362>
- [10] DiPietro, R.; Ahmidi, N., Malpani, A., Waldram, M., Lee, G. I., Lee, M. R., Vedula, S. S., Hager, G. D.: Segmenting and classifying activities in robot-assisted surgery with recurrent neural networks, *International Journal of Computer Assisted Radiology and Surgery*, **14** (2019) 11, 2005-2020, <https://doi.org/10.1007/s11548-019-01953-x>
- [11] Kiyasseh, D.; Ma, R., Haque, T. F., Miles, B. J., Wagner, C., Donoho, D. A., Anandkumar, A., Hung, A. J.: A vision transformer for decoding surgeon activity from surgical videos, *Nature Biomedical Engineering*, **7** (2023) 6, 780-796, <https://doi.org/10.1038/s41551-023-01010-8>
- [12] Yaseen; Kwon, O.J., Kim, J., Jamil, S., Lee, J., Ullah, F.: Next-Gen Dynamic Hand Gesture Recognition: MediaPipe, Inception-v3 and LSTM-Based Enhanced Deep Learning Model, *Electronics*, **13** (2024) 16, 3233, <https://doi.org/10.3390/electronics13163233>
- [13] Wang, J.; Zhang, X., Chen, X., Song, Z.: A touch-free human-robot collaborative surgical navigation robotic system based on hand gesture recognition, *Frontiers in Neuroscience*, **17** (2023) 1171233, <https://doi.org/10.3389/fnins.2023.1200576>
- [14] Žagar, M.; Kovač, M., Hofman, D.: Framework for 4D medical data compression, *Tehnički vjesnik*, **19** (2012) 1, 99-105, <https://hrcak.srce.hr/79164>
- [15] MedicalHolodeck: Medical AI, auto segmentation, surgical planning, and medical education in AR/VR, *Dostupan na:* <https://www.medicalholodeck.com>, *Pristupljeno:* 2026-03-01
- [16] Molina, C.A.; Sciubba, D.M., Greenberg, J.K., Khan, M., Witham, T.: Clinical Accuracy, Technical Precision, and Workflow of the First in Human Use of an Augmented-Reality Head-Mounted Display Stereotactic Navigation System for Spine Surgery, *Operative Neurosurgery*, **20** (2021) 3, 300-309, <https://doi.org/10.1093/ons/opaa398>
- [17] Yujia, G.: Extended reality in surgery - past, present, and future, *Surgery (Oxford)*, **43** (2025) 3, 140-145, <https://doi.org/10.1016/j.mpsur.2024.12.003>
- [18] Žagar, M.; Kovač, M., Knezović, J., Mlinarić, H., Hofman, D.: 3D Object Classification and Segmentation Methods, *High-Quality Visual Experience*, Springer, Berlin, Heidelberg, (2010) 331-347, https://doi.org/10.1007/978-3-642-12802-8_14
- [19] Klapan, I.; Majhen, Z., Žagar, M., Trampuš, Z., Klapan, L., Berlengi, N., Zemba, M., Ljubičić, A., Ešler, M.: Utilization of 3-D medical imaging and touch-free navigation in endoscopic surgery, *Biomedical Journal of Scientific & Technical Research*, **22** (2019) 1, 16336-16344, <https://doi.org/10.26717/bjstr.2019.22.003691>
- [20] Liu, Y.; Wu, X., Sang, Y., Zhao, C., Wang, Y., Shi, B., Fan, Y.: Evolution of Surgical Robot Systems Enhanced by Artificial Intelligence: A Review, *Advanced Intelligent Systems*, **6** (2024) 5, 2300268, <https://doi.org/10.1002/aisy.202300268>
- [21] Tversky, A.; Kahneman, D.: Judgment under Uncertainty: Heuristics and Biases, *Science*, **185** (1974) 4157, 1124-1131
- [22] Armstrong, B.A.; Dutescu, I.A., Tung, A., Carter, D.N., Trbovich, P.L., Wong, S., Saposnik, G., Grantcharov, T.: Cognitive biases in surgery: systematic review, *British Journal of Surgery*, **110** (2023) 6, 645-654, <https://doi.org/10.1093/bjs/znad004>

- [23] Saposnik, G.; Redelmeier, D., Ruff, C.C., Tobler, P.N.: Cognitive biases associated with medical decisions: a systematic review, *BMC Medical Informatics and Decision Making*, **16** (2016) 1, 138, <https://doi.org/10.1186/s12911-016-0377-1>
- [24] Janhofer, D.E.; Lakhiani, C., Song, D.H.: Addressing surgeon fatigue: Current understanding and strategies for mitigation, *Plastic and Reconstructive Surgery*, **144** (2019) 693-699, <https://doi.org/10.1097/PRS.0000000000006075>
- [25] Clemente, M.; Rey, B., Rodriguez-Pujadas, A., Barros-Loscertales, A., Baños, R.M., Botella, C., Alcañiz, M., Ávila, C.: An fMRI Study to Analyze Neural Correlates of Presence during Virtual Reality Experiences, *Interacting with Computers*, **26** (2014) 3, 269-284, <https://doi.org/10.1093/iwc/iwt037>
- [26] Yu, M.; Li, Y., Tian, F.: Responses of functional brain networks while watching 2D and 3D videos: An EEG study, *Biomedical Signal Processing and Control*, **68** (2021) 102613, <https://doi.org/10.1016/j.bspc.2021.102613>
- [27] Tian, F.; Hua, M., Zhang, W., Li, Y., Yang, X.: Emotional arousal in 2D versus 3D virtual reality environments, *PLoS ONE*, **16** (2021) 9, e0256211, <https://doi.org/10.1371/journal.pone.0256211>
- [28] Gangemi, A.; De Luca, R., Fabio, R. A., Lauria, P., Rifichi, C., Pollicino, P., Marra, A., Olivo, A., Quartarone, A., Calabrò, R. S.: Effects of Virtual Reality Cognitive Training on Neuroplasticity: A Quasi-Randomized Clinical Trial in Patients with Stroke, *Biomedicines*, **11** (2023) 12, 3225, <https://doi.org/10.3390/biomedicines11123225>
- [29] Wah, J.N.K.: The rise of robotics and AI-assisted surgery in modern healthcare, *Journal of Robotic Surgery*, **19** (2025) 1, 311, <https://doi.org/10.1007/s11701-025-02485-0>
- [30] Han, F.; Huang, X., Wang, X., Chen, Y. F., Lu, C., Li, S., Lu, L., Zhang, D. W.: Artificial Intelligence in Orthopedic Surgery: Current Applications, Challenges, and Future Directions, *MedComm*, **6** (2025) 7, e70260, <https://doi.org/10.1002/mco2.70260>
- [31] Morris, M.X.; Fiocco, D., Caneva, T., Yiapanis, P., Orgill, D.P.: Current and future applications of artificial intelligence in surgery: implications for clinical practice and research, *Frontiers in Surgery*, **11** (2024) 1393898, <https://doi.org/10.3389/fsurg.2024.1393898>
- [32] Guni, A.; Varma, P., Zhang, J., Fehervari, M., Ashrafian, H.: Artificial Intelligence in Surgery: The Future is Now, *European Surgical Research*, **65** (2024) 1, 22-39, <https://doi.org/10.1159/000536393>
- [33] SAE International: Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles, SAE Standard J3016, (2021), *Dostupan na*: https://www.sae.org/standards/j3016_202104-taxonomy-definitions-terms-related-driving-automation-systems-road-motor-vehicles, *Pristupljeno*: 2026-03-01
- [34] Yeong, D.J.; Panduru, K., Walsh, J.: Exploring the Unseen: A Survey of Multi-Sensor Fusion and the Role of Explainable AI (XAI) in Autonomous Vehicles, *Sensors*, **25** (2025) 3, 856, <https://doi.org/10.3390/s25030856>
- [35] Qian H.; Wang M., Zhu M., Wang H.: A Review of Multi-Sensor Fusion in Autonomous Driving, *Sensors*, **25** (2025) 19, 6033, <https://doi.org/10.3390/s25196033>

- [36] Wu, D.; Yang, F., Xu, B., Liao, P., Liu, B.: A Survey of Deep Learning Based Radar and Vision Fusion for 3D Object Detection in Autonomous Driving, *arXiv Computer Vision and Pattern Recognition*, (2024), <https://doi.org/10.48550/arXiv.2406.00714>
- [37] Elhassan, M.A.M.; Zhou, C., Khan, A., Benabid, A., Adam, A.B.M., Mehmood, A., Wambugu, N.: Real-time semantic segmentation for autonomous driving: A review of CNNs, Transformers, and Beyond, *Journal of King Saud University - Computer and Information Sciences*, **36** (2024) 10, 10226, <https://doi.org/10.1016/j.jksuci.2024.102226>
- [38] Contreras, A.; Jain, A., Bhatt, P., Banerjee, N., Hashemi, E.: A survey on 3D object detection in real time for autonomous driving, *Frontiers in Robotics and AI*, **11** (2024) 1212070, <https://doi.org/10.3389/frobt.2024.1212070>
- [39] Hofman, D.; Brcic, M., Kovac, M., Hotfilter, T., Becker, J., Reinhardt, D., Grigorescu, S. M., Stevens, R., Vo, T. T.: European Processor Initiative Demonstration of Integrated Semi-Autonomous Driving System, 2023 IEEE 36th International System-on-Chip Conference (SOCC) proceedings, Andrew Marshall, 1.-6., Santa Clara, 2023, Institute of Electrical and Electronics Engineers (IEEE), <https://doi.org/10.1109/socc58585.2023.10257105>
- [40] S&P Global Mobility. Autonomous ride-hailing grows in key US markets. Automotive Insights Blog, *Dostupan na*: <https://www.spglobal.com/automotive-insights/en/blogs/2025/12/autonomous-ride-hailing-grows-key-us-markets>, *Pristupljeno*: 2026-03-01
- [41] Brittany Moye. 2025. AAA: Fear in Self-Driving Vehicles Persists. AAA, *Dostupan na*: <https://newsroom.aaa.com/2025/02/aaa-fear-in-self-drivingvehicles-persists/>, *Pristupljeno*: 2026-03-01

Sigurnost strojnog učenja

Stjepan Picek^{1,2,3}

¹Sveučilište u Zagrebu Fakultet elektrotehnike i računarstva, Unska 3, 10000 Zagreb

²Radboud University, Houtlaan 4, 6525 XZ Nijmegen, Nizozemska

³University of Bergen, Muséplassen 1, 5007 Bergen, Norveška

Sažetak: *Strojno učenje brzo prelazi iz istraživačke domene u temeljni element moderne digitalne infrastrukture. Pritom sustavi strojnog učenja postaju i meta sve sofisticiranijih napada, čime se otvara nova i rastuća površina rizika. Ovaj pregledni rad analizira sigurnost strojnog učenja s naglaskom na ranjivosti svojstvene sustavima temeljenima na podacima te na protivnike koji ih iskorištavaju. Nakon razgraničenja sigurnosti umjetne inteligencije i umjetne inteligencije za sigurnost, fokus stavljamo na prvi pristup te razlikujemo namjerne napade od nenamjernih pogrešaka i kvarova modela. Namjerne napade klasificiramo prema fazi životnog ciklusa strojnog učenja na koju su usmjereni, odnosno prema treniranju i inferenciji, te prema ciljevima napada u okviru CIA trijade. Nadalje, razmatramo sigurnost velikih jezičnih modela, osobito prompt injection i jailbreak napade. U završnom dijelu razmatramo regulatorni kontekst, posebno AI Act Europske unije i GDPR.*

Gljučne riječi: *sigurnost strojnog učenja, adversarijalno strojno učenje, prompt injection, jailbreak, AI Act*

1. Uvod

Strojno učenje (engl. *machine learning*, ML) danas je ugrađeno u velik broj kritičnih sustava. Modeli se koriste za medicinsku dijagnostiku, procjenu kreditnog rizika, filtriranje sadržaja, detekciju prijevara, autonomnu vožnju, biometriju, obradu prirodnog jezika i pomoć pri donošenju odluka u organizacijama. Takva rasprostranjenost znači da pogreška modela više nije samo tehnički problem kvalitete predikcije, nego može imati i operativne, financijske, pravne te sigurnosne posljedice. Zbog toga se sigurnost strojnog učenja više ne može promatrati kao usko tehničko pitanje robusnosti modela, nego kao širi problem pouzdanosti sustava koji nastaje na sjecištu podataka, algoritama, infrastrukture i načina uporabe [1, 2].

U literaturi se često razlikuju dva pristupa: sigurnost umjetne inteligencije (engl. *security of AI*) i umjetna inteligencija za sigurnost (engl. *AI for security*). Prvi pristup bavi se zaštitom modela, podataka i aplikacija koje koriste AI od napada, manipulacije, curenja informacija i degradacije performansi. Drugi pristup promatra AI kao alat za obranu, primjerice za otkrivanje anomalija, pomoć pri analizi zlonamjernog koda ili automatizaciju odgovora na incidente. Iako su ta dva područja povezana, važno ih je razlikovati jer se sigurnosni zahtjevi, model prijetnji i metode evaluacije bitno razlikuju [1]. Ovaj rad usmjeren je na sigurnost samih ML sustava, njihovih ulaza, izlaza, opskrbnog lanca i mehanizama uporabe.

Dodatnu složenost donosi širenje velikih jezičnih modela i generativne umjetne inteligencije u svakodnevne alate i poslovne procese. U tim sustavima prirodni jezik nije samo medij prijenosa sadržaja, nego i mehanizam upravljanja ponašanjem modela. Time se briše granica između podataka i uputa, što otvara prostor za *prompt injection*, *jailbreak* i druge oblike manipulacije koji nisu tipični za ranije, uže definirane ML aplikacije [3, 4].

Važno je naglasiti da sigurnost strojnog učenja ne prestaje trenutkom puštanja modela u rad. U produkcijskom okruženju model ostaje dio šireg socio-tehničkog sustava u kojem se mijenjaju ulazni podaci, korisnički obrasci, vanjske integracije i poslovna pravila. Zbog toga sigurnosna analiza mora obuhvatiti cijeli razvojno-operativni ciklus strojnog učenja (MLOps): prikupljanje i verzioniranje podataka, treniranje, validaciju, implementaciju, nadzor i upravljanje promjenama modela. Tek tada je moguće govoriti o stvarnoj otpornosti sustava, a ne samo o sigurnosti jedne verzije modela u laboratorijskim uvjetima.

Cilj ovog rada je ponuditi preglednu klasifikaciju sigurnosnih prijetnji nad sustavima strojnog učenja, analizirati najvažnije tehnike napada, raspraviti obrambene pristupe i smjestiti problem u širi tehnički i regulatorni kontekst. Valja pritom naglasiti da sigurnost strojnog učenja obuhvaća širi skup prijetnji, napada i obrambenih pristupa nego što ih je moguće detaljno obraditi u jednom preglednom radu ograničenog opsega. Stoga se u ovom radu ne nastoji dati iscrpan katalog svih poznatih metoda, nego se naglasak stavlja na najvažnije i najreprezentativnije klase napada i obrana koje pružaju dobar temelj za razumijevanje sigurnosti suvremenih sustava strojnog učenja.


Rad je strukturiran tako da najprije uvodi pojamovni okvir i taksonomiju prijetnji (Poglavlje 2), zatim zasebno razmatra napade u fazi treniranja (Poglavlje 3) i napade u fazi inferencije (Poglavlje 4). Potom analizira sigurnost velikih jezičnih modela (Poglavlje 5), predstavlja dvije studije slučaja iz novije literature (Poglavlje 6), razmatra obrambene pristupe (Poglavlje 7) i regulatorni okvir (Poglavlje 8). Naposljetku, sažima glavne otvorene izazove (Poglavlje 9).

2. Pojmovni okvir i taksonomija prijetnji

U raspravi o sigurnosti strojnog učenja važno je najprije razgraničiti sigurnosne incidente od općih problema pouzdanosti modela. Nije svaka pogrešna odluka modela posljedica napadača: mnoge poteškoće proizlaze iz loše kvalitete podataka, pomaka distribucije, pristranih oznaka, neodgovarajuće metrike ili neprikladne evaluacije. Takvi problemi mogu imati ozbiljne posljedice, ali ih metodološki treba razlikovati od situacija u kojima napadač svjesno i ciljano manipulira ulazima, podacima, okruženjem ili izlazima modela radi ostvarivanja vlastitog cilja [2].

Prva temeljna podjela odnosi se na fazu životnog ciklusa sustava. Napadi u fazi treniranja ciljaju podatke, oznake, hiperparametre, procese učenja ili opskrbeni lanac modela. Najpoznatiji primjeri su trovanje podataka i *backdoor* napadi, kod kojih napadač pokušava oblikovati buduće ponašanje modela prije njegove uporabe. Napadi u fazi inferencije izvode se nad već istreniranim modelom te iskorištavaju način na koji model reagira na ulazne upite. U tu skupinu ubrajaju se adversarijalni primjeri, krađa modela, *membership inference*, *prompt injection* i *jailbreak* [2-7].

Sigurnosne prijetnje u sustavima strojnog učenja mogu se pojaviti u različitim fazama njihova životnog ciklusa, od prikupljanja podataka do rada modela u produkciji. Slika 1 prikazuje pregled glavnih faza životnog ciklusa ML sustava te tipične sigurnosne prijetnje povezane s pojedinim fazama.



Slika 1: Životni ciklus sustava strojnog učenja i tipične sigurnosne prijetnje povezane s pojedinim fazama

Druga korisna klasifikacija polazi od sigurnosnih ciljeva, odnosno CIA trijade. Napadi na povjerljivost nastoje izvući informacije o modelu ili podacima na kojima je treniran. Napadi na integritet pokušavaju izazvati pogrešne odluke, zaobići detekciju ili promijeniti ponašanje sustava u korist napadača. Napadi na dostupnost ciljaju degradaciju performansi ili onemogućavanje uporabe modela. Ove se kategorije u praksi preklapaju: krađa modela, primjerice, ugrožava povjerljivost, ali istodobno može olakšati kasnije napade na integritet [2, 6].

Treća važna os klasifikacije odnosi se na znanje i sposobnosti napadača. *White-box* napadač poznaje arhitekturu, parametre i obrambene mehanizme. *Gray-box* napadač raspolaže parcijalnim znanjem o modelu ili skupu podataka. *Black-box* napadač vidi samo ulazno-izlazno ponašanje sustava, primjerice preko aplikacijskog sučelja (API-ja). Upravo je to razlikovanje važno jer brojni napadi, iako izvorno razvijeni za *white-box* okruženje, ostaju učinkoviti i u *black-box* scenarijima zbog transferabilnosti ili curenja informacija kroz izlaze modela [5, 6, 8].

Za potrebe ovog rada korisno je promatrati taksonomiju prijetnji kao višedimenzionalnu matricu, a ne kao jednostavnu listu napada. Isti napad može se opisati prema više osi: prema fazi životnog ciklusa, sigurnosnom cilju, znanju protivnika i operativnom učinku. Takav pristup pogodniji je za pregledni rad jer omogućuje povezivanje tehničkih detalja napada s obranom, upravljanjem rizikom i regulatornim zahtjevima.

3. Napadi u fazi treniranja

U suvremenim sustavima dodatni problem predstavlja opskrbeni lanac modela. Organizacije često koriste unaprijed naučene modele, vanjske skupove podataka, otvorene repozitorije i gotove biblioteke za fino podešavanje. Time se povećava produktivnost, ali i otvara mogućnost da kompromitacija nastane prije nego što organizacija uopće započne vlastito treniranje. Sigurnost treniranja zato uključuje provjeru podrijetla artefakata, reproducibilnost procesa učenja, praćenje promjena u skupovima podataka te postupke kojima se može dokazati kako je određena verzija modela nastala i na kojim je ulazima temeljena.

Napadi u fazi treniranja posebno su opasni zato što kompromitaciju ugrađuju u model prije njegove produkcijske uporabe. Takvi napadi mogu ostati neotkriveni dulje vrijeme jer se njihovi učinci ne moraju manifestirati odmah, a model može zadržati dobru opću točnost na standardnim testnim skupovima. Napadač time iskorištava osnovnu činjenicu da model svoju buduću logiku odluke gradi iz podataka i iz procesa optimizacije [2, 9].

3.1 Trovanje podataka

Trovanje podataka (engl. *data poisoning*) obuhvaća namjerno umetanje ili manipulaciju trening uzoraka s ciljem da model nakon treniranja donosi pogrešne odluke. Već su rani radovi pokazali da i relativno mali broj pažljivo konstruiranih uzoraka može znatno utjecati na performanse klasifikatora [9]. U praksi razlikujemo neselektivno trovanje, kojem je cilj opća degradacija modela, i ciljano trovanje, kojem je cilj promjena ponašanja za točno određene uzorke, klase ili scenarije uporabe. Ciljano trovanje posebno je opasno kada napadač želi zaobići detekciju prijave, biometrijsku provjeru ili sigurnosni klasifikator samo u uskom skupu situacija.

3.2 *Backdoor* napadi

Posebno važna podvrsta trovanja podataka su *backdoor* napadi. Kod njih model zadržava prividno dobro ponašanje na benignim ulazima, ali pokazuje zlonamjerno ili pogrešno ponašanje kada se pojavi određeni okidač. Okidač može biti vizualni uzorak, specifična riječ, sekvenca tokena ili neko drugo prepoznatljivo obilježje ulaza. Upravo zato *backdoor* napadi predstavljaju problem za standardnu evaluaciju: model može izgledati ispravno na testnom skupu, a ipak sadržavati skrivenu ranjivost. To otežava i tehničku provjeru i odgovornost organizacije koja model uvodi u uporabu [2, 10].

Rizik trovanja dodatno raste u okruženjima gdje podaci dolaze iz više izvora i gdje je provjera kvalitete ograničena. To vrijedi za *crowdsourcing*, automatizirano prikupljanje podataka s interneta, repozitorije gotovih skupova podataka, ali i za federirano učenje. U federiranom učenju pojedini klijenti treniraju lokalne modele nad vlastitim podacima, a zatim agregiraju promjene parametara. Takva arhitektura ima prednosti sa aspekta privatnosti, ali otvara i nove sigurnosne rizike: zlonamjerni klijent može pokušati otrovati zajednički model ili ubaciti *backdoor* uz ograničenu vidljivost centralnog koordinatora u njegove lokalne podatke [11].

3.3 Kompromitirani opskrbeni lanac modela

Osim trovanja podataka, napad se može provesti i kroz kompromitirani opskrbeni lanac modela. U praksi se često koriste unaprijed istrenirani modeli, *checkpoint* preuzeti s javnih repozitorija, biblioteke trećih strana i skripte za fino podešavanje. Svaki od tih elemenata može postati točka kompromitacije. Time sigurnost strojnog učenja postaje slična sigurnosti opskrbenog lanca u klasičnom softverskom inženjerstvu, ali s dodatnim problemom slabe transparentnosti modela: zlonamjerno ponašanje ne mora biti vidljivo u kodu, nego može biti utjelovljeno u parametrima modela i u njegovoj latentnoj reprezentaciji [12].

Iz perspektive obrane napadi u fazi treniranja posebno su zahtjevni jer njihovo otkrivanje često traži kombinaciju provjere podrijetla podataka, analize anomalija, robusnog agregiranja, posebnih metoda skeniranja modela i strožeg upravljanja opskrbnim lancem. Drugim riječima, problem nije samo u samom modelu, nego u cjelokupnom procesu kojim model nastaje.

4. Napadi u fazi inferencije

Napadi u fazi inferencije često su operativno privlačniji od napada na treniranje jer ne traže izravan pristup internim resursima organizacije. Dovoljan je pristup aplikaciji, aplikacijskom sučelju (API-ju) ili nekom drugom sučelju preko kojega model prima upite i vraća rezultate. To znači da su upravo javno izloženi servisi, *chatbotovi*, sustavi preporuke i sigurnosni klasifikatori pod najvećim pritiskom. U takvim scenarijima granica između zlouporabe aplikacije i napada na model postaje tanka, pa se obrana mora graditi istodobno na razini modela, servisa i upravljanja pristupom.

Napadi u fazi inferencije ne mijenjaju model izravno, nego iskorištavaju njegovo ponašanje tijekom uporabe. To ih čini osobito relevantnima za produkcijske sustave dostupne preko aplikacijskog sučelja, korisničkih sučelja ili ugrađenih inteligentnih funkcija u većim aplikacijama. U takvim scenarijima napadač često nema pristup parametrima modela, ali ipak može manipulativno oblikovati ulaze ili kroz upite prikupljati informacije o sustavu [5-7].

4.1 Adversarijalni primjeri

Adversarijalni primjeri predstavljaju jedan od najpoznatijih oblika inferencijskih napada. Riječ je o ulazima namjerno perturbiranim tako da model napravi pogrešku, iako je promjena često mala i ljudskom promatraču teško uočljiva. Već su prvi radovi pokazali da duboki modeli mogu biti iznenađujuće osjetljivi na takve perturbacije te su popularizirali jednostavne metode (npr. FGSM [5]) za njihovu konstrukciju. U računalnom vidu posljedice mogu biti pogrešno prepoznavanje objekata, zaobilaženje sigurnosnih klasifikatora ili narušavanje rada autonomnih sustava. U širem smislu, adversarijalni primjeri pokazuju da visoka točnost modela na standardnim testnim podacima nije isto što i robusnost u neprijateljskom okruženju.

Važno obilježje adversarijalnih primjera jest transferabilnost. Napad konstruiran na jednom modelu često djeluje i na drugi model iste ili srodne domene, čak i kada napadač nema uvid u unutarnje parametre cilja. Ta pojava značajno povećava praktičnu prijetnju *black-box* napada, jer napadač može trenirati ili koristiti *surrogate* modele te napad prenijeti na produkcijski sustav [2, 5]. Iz toga proizlazi važna obrambena implikacija: oslanjanje na tajnost arhitekture nije dovoljno jamstvo sigurnosti.

4.2 Krađa modela

Krađa modela (engl. *model extraction* ili *model stealing*) u pravilu se promatra kao napad u kojem protivnik, koristeći pristup predikcijskom sučelju ili drugim obilježjima izvođenja sustava, pokušava rekonstruirati vrijedna svojstva ciljnog modela. Posljedice takvog napada nisu samo gospodarske, u smislu gubitka intelektualnog vlasništva, nego i operativne: jednom kada raspolaže dovoljno vjernim zamjenskim modelom, napadač može detaljnije analizirati granice odluke, razvijati prilagođene adversarijalne primjere ili planirati napade na privatnost [6].


U tom je kontekstu korisno razlikovati krađu modela u širem smislu od krađe vjernosti ponašanja (engl. *fidelity stealing*) u užem smislu. U prvom slučaju protivnik nastoji rekonstruirati funkcionalna, strukturna ili parametarska svojstva modela, dok je u drugom primarni cilj izgraditi zamjenski model koji što vjernije oponaša ulazno-izlazno ponašanje izvornog sustava. Ta razlika nije samo terminološka. U mnogim praktičnim scenarijima napadaču nije nužno potreban isti model kao izvornik; dovoljno je da dobije model koji se ponaša dovoljno slično da omogući daljnje napade ili zaobiđe tržišnu prednost vlasnika izvornog modela. Štoviše, krađa modela ne odvija se isključivo kroz javno izloženi API. Model se može rekonstruirati i analizom elektromagnetskog zračenja i vremenskih obilježja izvođenja [13]. Nadalje, parametri ReLU mreža se mogu izvući u polinomnom vremenu upitima nad modelom, oslanjajući se na pristup inspiriran diferencijalnom kriptanalizom [14].

Takvi rezultati pokazuju da krađa modela nije ograničena samo na kopiranje funkcionalnosti putem aplikacijskog sučelja, nego obuhvaća i sofisticiranije metode rekonstrukcije arhitekture i parametara, što dodatno proširuje površinu napada nad sustavima strojnog učenja.

4.3 Membership inference

Napadi na privatnost predstavljaju dodatnu inferencijsku dimenziju. *Membership inference* pokušava zaključiti je li neki uzorak bio dio trening skupa. Takav napad može biti posebno osjetljiv kada model sadrži tragove o medicinskim zapisima, financijskim podacima ili drugim osobnim informacijama [7]. U nekim scenarijima mogući su i napadi koji pokušavaju rekonstruirati karakteristike trening skupa ili izvesti zaključke o osjetljivim atributima korisnika. Ovi napadi pokazuju da model može postati kanal curenja informacija, čak i kada izravni pristup originalnim podacima nije moguć.

Slika 2 vizualno sažima višedimenzionalnu taksonomiju napada na sustave strojnog učenja. Slika grupira prijetnje prema fazi životnog ciklusa, primarnom sigurnosnom cilju, te znanju napadača.



Slika 2: Taksonomija napada na sustave strojnog učenja

5. Sigurnost velikih jezičnih modela (LLM)

Sigurnost velikih jezičnih modela ne može se promatrati samo kao proširenje sigurnosti klasičnih ML sustava. Razlog nije samo njihova veličina ili generativna sposobnost, nego činjenica da djeluju u izrazito otvorenom semantičkom okruženju. Ulazi više nisu strogo strukturirani, izlazi nisu unaprijed ograničeni na nekoliko klasa, a model je sve češće povezan s dokumentima, vanjskim servisima i alatima koji mu omogućuju djelovanje izvan pukog generiranja teksta.

Veliki jezični modeli uvode novu klasu sigurnosnih izazova zato što prirodni jezik služi istodobno kao nositelj sadržaja i kao mehanizam upravljanja ponašanjem modela. U klasičnom softveru razdvajanje između podataka i uputa tipično je razmjerno jasno; kod LLM aplikacija ta je granica bitno slabije određena. Posljedica je da tekst koji bi aplikacija trebala tretirati kao običan podatak model može protumačiti kao uputu. Upravo na toj napetosti između sadržaja i instrukcije temelji se velik dio suvremenih sigurnosnih problema LLM sustava [3, 4].

Uz namjerne napade, kod velikih jezičnih modela valja razmotriti i halucinacije, odnosno situacije u kojima model generira netočne, izmišljene ili neosnovane tvrdnje

koje su predstavljene s visokim stupnjem uvjerljivosti. Za razliku od *prompt injection* i *jailbreak* napada, halucinacije u pravilu ne proizlaze iz aktivnog djelovanja napadača, nego iz ograničenja samog modela, nesigurnosti u generiranju, nedostatka pouzdanog uporišta u podacima ili neadekvatnog povezivanja s vanjskim izvorima znanja. Ipak, njihove posljedice mogu biti sigurnosno vrlo relevantne, osobito kada se izlaz modela koristi u odlučivanju, radu s alatima ili sigurnosno osjetljivim domenama.

5.1 *Prompt injection*

Prompt injection nastaje kada napadač u korisnički unos, dokument, web-stranicu, e-poštu ili drugi izvor umetne upute koje preusmjeravaju ponašanje modela izvan predviđene politike aplikacije. Temelj problema jest to što veliki jezični modeli obrađuju instrukcije i podatke unutar istog tekstualnog kanala, pa zlonamjerni sadržaj može biti pogrešno protumačen kao legitimna naredba. Napad može biti izravan, kada napadač komunicira neposredno s modelom, ili neizravan, kada se zlonamjerna uputa nalazi u sadržaju koji model naknadno obrađuje, primjerice tijekom pretraživanja weba, rada s dokumentima ili obrade elektroničke pošte [3, 4, 15].

5.2 *Jailbreak* napadi

Jailbreak napadi usmjereni su na zaobilazanje sigurnosnih ograda modela i navođenje modela da proizvede inače zabranjen ili neusklađen izlaz. U praksi *jailbreak* može koristiti različite strategije, uključujući semantičke obiliske, višekoračne zahtjeve, kodirane upute ili iskorištavanje vanjskog konteksta. Sigurnosna relevantnost takvih napada proizlazi iz činjenice da model može ostati fluentan i funkcionalan, a ipak izgubiti sposobnost sigurnosnog odbijanja štetnih zahtjeva [16, 17].

Iako se u literaturi i praksi pojmovi *prompt injection* i *jailbreaking* često koriste gotovo sinonimno, među njima postoji važna razlika. *Prompt injection* označava tehniku kojom napadač u kontekst koji model obrađuje umeće dodatne upute s ciljem promjene njegova ponašanja. *Jailbreaking*, naprotiv, označava sigurnosni cilj takve manipulacije, odnosno uspješno zaobilazanje ograničenja koja bi model trebala spriječiti u generiranju nedopuštenog ili neusklađenog izlaza. Drugim riječima, *prompt injection* prije svega opisuje mehanizam napada, a *jailbreak* njegov učinak.

LLM-ovi su dodatno rizični kada su integrirani s alatima i vanjskim akcijama. Model koji može čitati dokumente, slati upite drugim servisima, upravljati kalendarom, generirati kod ili pokretati automatizirane radnje širi površinu napada s razine samog modela na razinu cijele aplikacije. U takvim sustavima pogreška modela više nije samo problem kvalitete teksta, nego može imati neposredne sigurnosne posljedice.

Za razliku od ranijih ML sustava koji su često imali usko definirane ulaze i izlaze, LLM aplikacije djeluju u otvorenijem i semantički bogatijem okruženju. Zato sigurnost velikih jezičnih modela treba promatrati kao spoj robusnosti modela, sigurnosti aplikacijske arhitekture i kontrole nad vanjskim alatima i podacima.

6. Dvije studije slučaja iz novije literature

Cilj ovog poglavlja je prikazati dva konkretna slučaja iz novije literature. Te studije slučaja zajedno ilustriraju dvije važne stvari. Prvo, kod sigurnosti strojnog učenja problem često nije samo otkriti ranjivost, nego i vjerodostojno procijeniti koliko je neka obrana doista učinkovita. Drugo, kod velikih jezičnih modela sigurnosno ponašanje nije nužno ravnomjerno raspodijeljeno kroz sve parametre modela, nego se može koncentrirati u manjem broju unutarnjih mehanizama.

6.1 Studija slučaja: obrane od *backdoor* napada

Prva studija slučaja odnosi se na obrane od *backdoor* napada. Noviji sistematizacijski rad [10] pokazuje da je upravo način na koji se evaluiraju obrane jedna od najslabijih točaka literature. Analizom velikog broja radova autori pokazuju da se učinkovitost obrana snažno mijenja ovisno o odabranim eksperimentalnim postavkama, modelu prijetnje, arhitekturi i skupu podataka.

Važnost ovog nalaza nadilazi samu domenu *backdoor* napada. On pokazuje da pitanje nije samo koja je obrana najbolja, nego i kako uopće treba vrednovati tvrdnju da je model obranjen. Ako su metrike, pretpostavke i scenariji napada nekonzistentni, tada i usporedba obrana postaje metodološki nesigurna. Posljedica nije samo akademska neurednost, nego i praktičan rizik: obrana koja se u jednoj postavci čini vrlo učinkovitom može u realnijem scenariju pružiti znatno manju razinu zaštite [10].

Iz toga slijedi da obrane od *backdoor* napada treba promatrati kao dio šireg programa sigurnosnog osiguranja kvalitete modela. Potrebno je testirati više scenarija napada, više arhitektura, paziti na kompromis između sigurnosti i korisnosti te jasno navesti koje pretpostavke obrana doista pokriva. Evaluacija tako prestaje biti pomoćna istraživačka aktivnost i postaje sastavni dio same sigurnosne argumentacije.

6.2 Studija slučaja: *jailbreak* napadi koji ciljaju sigurnosno relevantne neurone

Druga studija slučaja odnosi se na *jailbreak* napade koji ciljaju sigurnosno relevantne neurone i eksperte u LLM-ovima. Osnovna premisa je da sigurnosno usklađeni

veliki jezični modeli dio sigurnosnog ponašanja temelje na razmjerno uskom skupu unutarnjih komponenti. Referenca [18] pokazuje da ciljana deaktivacija malog broja neurona može znatno povećati uspješnost *jailbreak* napada.

Ta se ideja dodatno pojačava kod *Mixture-of-Experts* modela. Reference [19] i [20] pokazuju da se sigurnosno relevantna ponašanja, poput odbijanja štetnih zahtjeva, u MoE modelima često koncentriraju u malom broju eksperata ili obrazaca usmjeravanja. Posljedično, napadač može narušiti sigurnosno ponašanje modela bez razmjerno velikog utjecaja na njegovu opću fluentnost i uporabljivost.

Zajednička poruka ovih radova jest da sigurnost LLM-ova nije nužno ravnomjerno raspodijeljena kroz parametre modela. Ako je sigurnosna funkcija koncentrirana u malom broju neurona, eksperata ili obrazaca usmjeravanja, tada obrana ne smije ostati ograničena na filtriranje *promptova* i izlaza. Potrebno je razumjeti i kako je sigurnosna funkcija raspoređena unutar same arhitekture te koliko je takva raspodjela robusna na ciljane intervencije [18-20].

7. Obrambeni pristupi

Praktično gledano, najzreliji pristup obrani jest uvođenje višeslojne strategije. Ona kombinira podatkovne kontrole prije treniranja, robusnije metode učenja, provjere ponašanja modela tijekom evaluacije i nadzor nad produkcijskim radom. Takav pristup odgovara logici obrane u dubini iz klasične kibernetičke sigurnosti, ali je u kontekstu strojnog učenja dodatno složen jer mora obuhvatiti i statističko ponašanje modela, a ne samo pristupne i mrežne kontrole.

Ne postoji univerzalna obrana protiv svih napada na sustave strojnog učenja. Razlog tome nije samo raznolikost napada, nego i činjenica da se površina napada proteže preko podataka, procesa treniranja, modela, aplikacijskog sloja, infrastrukture i organizacijskih postupaka. Zbog toga je korisnije govoriti o višeslojnoj obrani nego o pojedinačnim obrambenim metodama [1, 2].

7.1 Obrane od napada trovanjem

Za napade trovanja korisne su mjere poput provjere kvalitete i podrijetla podataka, detekcije anomalija tijekom treniranja, nadzora nad izvorima podataka i robusnih agregacijskih pravila u distribuiranim postavkama. U federiranom učenju to može uključivati procjenu vjerodostojnosti klijenata, detekciju odstupanja u lokalnim ažuriranjima i arhitekturne mehanizme koji otežavaju unošenje *backdoor* napada [11]. Međutim, važno je naglasiti da ni ove mjere same po sebi nisu dovoljne: često postoji kompromis između privatnosti, skalabilnosti i robusnosti.

7.2 Obrane od adversarijalnih primjera

Protiv adversarijalnih primjera najčešće se ističe adversarijalno treniranje, koje model izlaže napadački generiranim perturbacijama tijekom učenja kako bi povećalo robusnost [5]. Uz to se koriste i detekcija sumnjivih ulaza, preoblikovanje ulaza, certifikacijske metode i robusnije arhitekture. Ipak, iskustvo iz literature pokazuje da su mnoge obrane osjetljive na adaptivne napadače, odnosno da se učinkovitost obrane može značajno smanjiti kada napadač modelira obranu kao dio napadačkog procesa [2]. Stoga je u ovom području posebno važno provoditi evaluaciju protiv jakih i prilagodljivih protivnika.

7.3 Obrane od krađe modela i napada na privatnost

Za krađu modela i napade na privatnost važne su minimizacija izlaza, ograničavanje učestalosti i obrasca upita, praćenje anomalija u uporabi aplikacijskog sučelja, vođeni žigovi ili otisci modela te, u nekim scenarijima, diferencijalna privatnost [6, 7]. Važno je naglasiti da uklanjanje detaljnih vjerojatnosti iz izlaza može otežati određene napade, ali najčešće nije dostatno kao samostalna obrana.

7.4 Obrane za LLM-ove

Kod LLM-ova obrana dodatno mora obuhvatiti aplikacijsku arhitekturu. Dobre prakse uključuju strogo razdvajanje sustavskih uputa od neprovjerenog vanjskog sadržaja, označavanje izvora konteksta, izolirano izvođenje alata, validaciju izlaza prije izvršenja akcija, načelo najmanjih privilegija i protivničko testiranje *promptova* i radnih tokova [3, 4].

Noviji radovi o sigurnosno relevantnim neuronima i ekspertima dodatno sugeriraju da buduće obrane možda moraju postati i arhitekturno svjesne. Ako je sigurnost koncentrirana u uskom broju parametara ili eksperata, tada samo filtriranje ulaza i izlaza možda neće biti dovoljno. Obrana će morati uključiti i metode za analizu unutarnje raspodjele sigurnosnih funkcija te za sprečavanje njihove krhke koncentracije [18-20].

Tablica 1: Glavne skupine prijetnji, tipični ciljevi napadača i reprezentativni obrambeni pristupi

Prijetnja	Faza	Primarni cilj	Tipična posljedica	Reprezentativne obrane
Trovanje podataka	Treniranje	Integritet / dostupnost	Smanjenje točnosti modela ili namjerno oblikovanje granice odluke	Provjera podrijetla podataka, detekcija anomalija, robusno treniranje
<i>Backdoor</i> napadi	Treniranje	Integritet	Skriveno zlonamjerno ponašanje aktivirano okidačem	Skeniranje modela, filtriranje sumnjivih uzoraka, višescenarijska evaluacija obrana
Adversarijalni primjeri	Inferencija	Integritet	Pogrešna klasifikacija ili zaobilaženje detekcije	Adversarijalno treniranje, detekcija sumnjivih ulaza, robusna evaluacija
Krađa modela	Inferencija	Povjerljivost	Rekonstrukcija modela i priprema sekundarnih napada	Ograničenje izlaza, ograničavanje učestalosti upita, nadzor API-ja, vodeni žigovi modela
Napadi na privatnost	Inferencija	Povjerljivost	Otkrivanje članstva u trening-skupu ili curenje osjetljivih informacija	Minimizacija izlaza, diferencijalna privatnost, kontrola pristupa i revizija upita
<i>Prompt injection</i> i <i>jailbreak</i>	Inferencija / aplikacijski sloj	Integritet / povjerljivost	Zaobilaženje politike modela i manipulacija ponašanjem aplikacije	Razdvajanje uputa i podataka, izolirano izvođenje alata, validacija izlaza, protivničko testiranje

Tablica 1 sažima glavne skupine prijetnji, tipične ciljeve napadača i reprezentativne obrambene pristupe. Njezina je svrha ponuditi brzu referencu koja povezuje taksonomiju, praktične posljedice i obrambene prioritete.

8. Regulatorni okvir

Regulatorni zahtjevi postupno pretvaraju sigurnosne kontrole iz preporučene dobre prakse u element organizacijske dokazivosti i odgovornosti. U europskom kontekstu najvažniji regulatorni dokument je EU AI Act [21]. Riječ je o horizontalnom okviru koji uvodi pristup temeljen na riziku te povezuje tehničku pouzdanost, sigurnost, dokumentaciju i upravljanje tijekom cijelog životnog ciklusa AI sustava. Za sigurnost strojnog učenja važno je to što AI Act ne promatra problem samo kroz prizmu opće kibernetičke sigurnosti, nego šire kroz robusnost, kvalitetu podataka, transparentnost, ljudski nadzor i naknadno praćenje sustava.

Za visokorizične AI sustave posebno su važni zahtjevi koji se odnose na upravljanje rizicima, tehničku dokumentaciju, zapisivanje događaja, kvalitetu podataka i razinu točnosti, robusnosti i kibernetičke sigurnosti [21]. Iako AI Act ne koristi jezik adversarijalnog strojnog učenja kao glavni organizacijski princip, njegovi zahtjevi stvaraju regulatorni pritisak da organizacije ozbiljnije pristupe pitanjima trovanja podataka, validacije modela, upravljanja promjenama i post-market nadzora. To sigurnost ML-a postupno pretvara iz “dobre prakse” u element regulatorne usklađenosti.

Kada ML sustav obrađuje osobne podatke, ključan regulatorni okvir ostaje GDPR [22]. Napadi poput *membership inference* ili rekonstrukcije podataka relevantni su ne samo tehnički nego i pravno, jer pokazuju da model može postati kanal kroz koji se neizravno otkrivaju informacije o pojedincima iz trening skupa. GDPR traži zakoni-tu osnovu obrade, minimizaciju podataka, sigurnost obrade i odgovarajuće tehničke i organizacijske mjere. U tom smislu privatnost i sigurnost u ML-u nisu odvojene teme, nego se preklapaju na razini modela, izlaza i upravljanja pristupom.

Za organizacije koje razvijaju i uvode ML sustave u praksu regulatorni okvir znači da tehničke odluke trebaju biti dokumentirane i dokazive. Nije dovoljno tvrditi da je model robusan; potrebno je pokazati kako je procijenjen rizik, koje su kontrole provedene, kako se promjene prate nakon implementacije i kako se incidenti dokumentiraju. Takva dokazivost postaje osobito važna kada sustav djeluje u osjetljivim domenama ili kada utječe na prava i interese pojedinaca.

Uz obvezujuće propise važnu ulogu imaju i dobrovoljni okviri poput NIST AI RMF-a [1]. Oni nude strukturiran pristup identifikaciji, procjeni, upravljanju i praćenju AI rizika te pomažu povezati tehničke mjere s organizacijskim procesima. U praksi se regulatorna usklađenost i tehnička sigurnost ne bi smjele promatrati kao odvojeni

projekti. Upravo suprotno, učinkovit program sigurnosti strojnog učenja u pravilu mora kombinirati tehničku robusnost, upravljanje rizikom, dokumentiranje i kontinuirani nadzor.

9. Rasprava i zaključak

Sigurnost strojnog učenja razlikuje se od klasične informacijske sigurnosti po tome što je površina napada djelomično ugrađena u samu logiku učenja. Model uči iz podataka, generalizira statistički i donosi odluke u okruženjima koja se mogu mijenjati ili namjerno oblikovati. Zbog toga sigurnost ML-a nužno povezuje kibernetičku sigurnost, statistiku, softversko inženjerstvo, upravljanje rizikom i regulatorno razumijevanje.

Prijetnje su raznolike: od trovanja podataka i *backdoor* napada u fazi treniranja, preko adversarijalnih primjera, krađe modela i napada na privatnost u fazi inferencije, pa sve do *prompt injection*, *jailbreak* i halucinacija u velikim jezičnim modelima. Upravo ta raznolikost pokazuje da se sigurnost strojnog učenja ne može svesti na jedan model prijetnje ni na jednu obrambenu tehniku. Potrebno je istodobno promatrati model, podatke, aplikacijski sloj i organizacijski kontekst u kojem se sustav koristi.

Zaključno, robusniji i sigurniji sustavi strojnog učenja neće nastati jednom tehnikom, nego kombinacijom tehničkih, organizacijskih i regulatornih mjera kroz cijeli životni ciklus sustava. U budućem razvoju područja posebnu će važnost imati vjerodostojna evaluacija obrana, sigurnost LLM aplikacija povezanih s vanjskim alatima, otpornost na ciljane arhitekturne napade te sposobnost organizacija da sigurnosne tvrdnje učine dokazivima i provjerljivima.

10. Literatura

- [1] National Institute of Standards and Technology (NIST): Artificial Intelligence Risk Management Framework (AI RMF 1.0). NIST AI 100-1 (2023), *Dostupno na*: <https://nvlpubs.nist.gov/nistpubs/ai/nist.ai.100-1.pdf>, *Pristupljeno*: 2026-03-15
- [2] Vassilev, A.; Oprea, A., Fordyce, A., Anderson, H., Davies, X., Hamin, M.: Adversarial Machine Learning: A Taxonomy and Terminology of Attacks and Mitigations, NIST AI 100-2e2025 (2025), *Dostupno na*: <https://doi.org/10.6028/NIST.AI.100-2e2025>, *Pristupljeno*: 2026-03-15
- [3] OWASP Foundation: LLM Prompt Injection Prevention Cheat Sheet, *Dostupno na*: https://cheatsheetseries.owasp.org/cheatsheets/LLM_Prompt_Injection_Prevention_Cheat_Sheet.html, *Pristupljeno*: 2026-03-15
- [4] OWASP GenAI Security Project: LLM01:2025 Prompt Injection. *Dostupno na*: <https://genai.owasp.org/llmrisk/llm01-prompt-injection/>, *Pristupljeno*: 2026-03-15

- [5] Goodfellow, I. J.; Shlens, J., Szegedy, C.: Explaining and Harnessing Adversarial Examples. *Zbornik 3rd International Conference on Learning Representations, ICLR 2015*, svibanj 2015, (2015). *Dostupno na*: <https://arxiv.org/abs/1412.6572>, *Pristupljeno*: 2026-03-15
- [6] Tramèr, F.; Zhang, F., Juels, A., Reiter, M. K., Ristenpart, T.: Stealing Machine Learning Models via Prediction APIs. *Zbornik 25th USENIX Conference on Security Symposium (SEC'16)*, str. 601-618, USENIX Association, SAD (2016). *Dostupno na*: <https://arxiv.org/abs/1609.02943>, *Pristupljeno*: 2026-03-15
- [7] Shokri, R.; Stronati, M., Song, C., Shmatikov, V.: Membership Inference Attacks Against Machine Learning Models. *Zbornik 2017 IEEE Symposium on Security and Privacy (SP)*, str. 3-18, San Jose, SAD (2017). *Dostupno na*: <https://arxiv.org/abs/1610.05820>, *Pristupljeno*: 2026-03-15
- [8] Papernot, N.; McDaniel, P., Goodfellow, I., Jha, S., Celik, Z. B., Swami, A.: Practical Black-Box Attacks against Machine Learning. *Zbornik 2017 ACM on Asia Conference on Computer and Communications Security (ASIA CCS '17)*, str. 506-519, Association for Computing Machinery (2017). *Dostupno na*: <https://arxiv.org/abs/1602.02697>, *Pristupljeno*: 2026-03-15
- [9] Biggio, B.; Nelson, B., Laskov, P.: Poisoning Attacks against Support Vector Machines. *Zbornik 29th International Conference on International Conference on Machine Learning (ICML'12)*, str. 1467-1474, Omnipress, Madison, SAD (2012). *Dostupno na*: <https://arxiv.org/abs/1206.6389>, *Pristupljeno*: 2026-03-15
- [10] Abad, G.; Krček, M., Koffas, S., Tajalli, B., Arazzi, M., Riaño, R., Xu, X., Liu, Z., Nocera, A., Picek, S.: SoK: The Last Line of Defense: On Backdoor Defense Evaluation. arXiv preprint arXiv:2511.13143 (2025). *Dostupno na*: <https://arxiv.org/abs/2511.13143>, *Pristupljeno*: 2026-03-15
- [11] Abad, G.; Picek, S., Ramírez-Durán, V. J., Urbieta, A.: On the Security & Privacy in Federated Learning. arXiv:2112.05423 (2021). *Dostupno na*: <https://arxiv.org/abs/2112.05423>, *Pristupljeno*: 2026-03-15
- [12] MITRE: ATLAS – Adversarial Threat Landscape for Artificial-Intelligence Systems. *Dostupno na*: <https://atlas.mitre.org/>, *Pristupljeno*: 2026-03-15
- [13] Batina, L.; Bhasin, S., Jap, D., Picek, S.: CSI NN: Reverse Engineering of Neural Network Architectures Through Electromagnetic Side Channel. *Zbornik 28th USENIX Conference on Security Symposium (SEC'19)*, str. 515-532, USENIX Association, SAD (2019). *Dostupno na*: <https://www.usenix.org/conference/usenixsecurity19/presentation/batina>, *Pristupljeno*: 2026-03-15
- [14] Canales-Martínez, I. A.; Chávez-Saab, J., Hambitzer, A., Rodríguez-Henríquez, F., Satpute, N., Shamir, A.: Polynomial Time Cryptanalytic Extraction of Neural Network Models. *Zbornik Advances in Cryptology – EUROCRYPT 2024*, Joye, M., Leander, G., str. 3-33, svibanj, 2024, Springer, Cham (2024). *Dostupno na*: <https://eprint.iacr.org/2023/1526>, *Pristupljeno*: 2026-03-15
- [15] Greshake, K.; Abdelnabi, S., Mishra, S., Endres, C., Holz, T., Fritz, M.: Not what you've signed up for: Compromising Real-World LLM-Integrated Applications with Indirect Prompt Injection. *Zbornik 16th ACM Workshop on Artificial Intelligence and Security (AISec '23)*, str. 79-90, Association for Computing Machinery, New York, SAD (2023). *Dostupno na*: <https://arxiv.org/abs/2302.12173>, *Pristupljeno*: 2026-03-15

-
- [16] Andriushchenko, M.; Croce, F., Flammarion, N.: Jailbreaking Leading Safety-Aligned LLMs with Simple Adaptive Attacks. arXiv preprint arXiv:2404.02151 (2024). *Dostupno na:* <https://arxiv.org/abs/2404.02151>, *Pristupljeno:* 2026-03-15
- [17] Zou, A.; Wang, Z., Carlini, N., Nasr, M., Kolter, J. Z., Fredrikson, M.: Universal and Transferable Adversarial Attacks on Aligned Language Models. arXiv preprint arXiv:2307.15043 (2023). *Dostupno na:* <https://arxiv.org/abs/2307.15043>, *Pristupljeno:* 2026-03-15
- [18] Wu, L.; Behrouzi, S., Rostami, M., Thang, M., Picek, S., Sadeghi, A.-R.: NeuroStrike: Neuron-Level Attacks on Aligned LLMs. arXiv preprint arXiv:2509.11864 (2025). *Dostupno na:* <https://arxiv.org/abs/2509.11864>, *Pristupljeno:* 2026-03-15
- [19] te Lintelo, J.; Wu, L., Picek, S.: Large Language Lobotomy: Jailbreaking Mixture-of-Experts via Expert Silencing. arXiv preprint arXiv:2602.08741 (2026). *Dostupno na:* <https://arxiv.org/abs/2602.08741>, *Pristupljeno:* 2026-03-15
- [20] Wu, L.; Behrouzi, S., Rostami, M., Picek, S., Sadeghi, A.-R.: GateBreaker: Gate-Guided Attacks on Mixture-of-Expert LLMs. arXiv preprint arXiv:2512.21008 (2025). *Dostupno na:* <https://arxiv.org/abs/2512.21008>, *Pristupljeno:* 2026-03-15
- [21] European Parliament and Council of the European Union: Regulation (EU) 2024/1689 of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). *Dostupno na:* <https://eur-lex.europa.eu/eli/reg/2024/1689/oj/eng>, *Pristupljeno:* 2026-03-15
- [22] European Parliament and Council of the European Union: Regulation (EU) 2016/679 of 27 April 2016 (General Data Protection Regulation). *Dostupno na:* <https://eur-lex.europa.eu/eli/reg/2016/679/oj/eng>, *Pristupljeno:* 2026-03-15

Primjena strojnog učenja u kemijskom inženjerstvu

Nenad Bolj¹, Željka Ujević Andrijić¹

¹Sveučilište u Zagrebu Fakultet kemijskog inženjerstva i tehnologije, Trg Marka Marulića 19, 10 000 Zagreb

Sažetak: *Strojno učenje u kemijskom inženjerstvu nalazi primjenu u procjeni teško mjerljivih varijabli stanja i svojstava proizvoda u stvarnom vremenu, optimiranju procesnih uvjeta, analizi mjernih informacija, kao i u prediktivnoj dijagnostici i razvoju digitalnih blizanaca procesa. Primjenjuje se za donošenje brzih i pouzdanih odluka temeljenih na podacima. Digitalizacijom i automatizacijom postrojenja i laboratorija nastaju goleme količine podataka, a metode strojnog učenja izdvajaju ključne informacije i pružaju potporu pri donošenju odluka. U ovom je radu prikazano strojno učenje iz perspektive kemijskog inženjerstva kroz niz istraživačkih i praktičnih primjera koje su proveli suradnici Zavoda za mjerenja i automatsko vođenje procesa Sveučilišta u Zagrebu Fakulteta kemijskog inženjerstva i tehnologije. Prikazani su primjeri softverskih senzora za kontinuiranu procjenu svojstava proizvoda, modeli za praćenje učinkovitosti izmjenjivača topline, modeli za procjenu koncentracije u procesu kristalizacije farmaceutskih djelatnih tvari primjenom procesne analitičke tehnologije, kao i procjenu raspodjele veličine čestica. Dan je i osvrt na razvoj klasifikacijskog modela temeljenog na molekulskim deskriptorima za predviđanje nastanka kokristala. Također je prikazan primjer predviđanja koncentracije lebdećih čestica i dušikovih oksida u zraku.*

Prikazane studije pokazuju kako strojno učenje, u kombinaciji s domenskim znanjem, postaje vrijedan alat za optimiranje tehnoloških procesa, smanjenje troškova i ubrzanje razvojnog ciklusa u kemijskom inženjerstvu.

Ključne riječi: *strojno učenje, kemijsko inženjerstvo, softverski senzori, procesna analitička tehnologija*

1. Uvod

Digitalizacija industrijskih procesa i laboratorija, kao i razvoj metoda umjetne inteligencije posljednjih su godina značajno proširili mogućnosti analize, nadzora i vođenja složenih procesa u kemijskom inženjerstvu. Suvremena procesna postrojenja i laboratorijski sustavi stvaraju goleme količine podataka, no sama dostupnost podataka ne

znači automatski i korisne informacije. Upravo zato raste važnost modeliranja, statističke analize podataka i strojnog učenja, koje donose zaključke iz mjerenja, procjenjuju teško mjerljive, a bitne varijable, te donose pouzdanije odluke u realnom vremenu.

Postoji više razloga zbog kojih bi kemijski inženjeri i istraživači trebali u svom radu razumjeti i primjenjivati metode strojnog učenja. Tijekom posljednja dva desetljeća, a osobito u posljednjem, strojno učenje nalazi široku primjenu u kemijskom inženjerstvu, posebice u optimizaciji i naprednom vođenju procesa, analizi velikih skupova podataka iz procesnih postrojenja i laboratorija, preventivnoj i prediktivnoj dijagnostici procesa i procesne opreme, modeliranju kemijskih reakcija, predviđanju svojstava materijala, kao i upravljanju kvalitetom proizvoda. Metode strojnog učenja pružaju alate za učinkovitu analizu mjernih podataka, prepoznavanje složenih obrazaca i izdvajanje vrijednih informacija koje nije jednostavno uočiti klasičnim pristupom.

Kemijsko inženjerstvo po svojoj je prirodi multidisciplinarno područje stoga zahtijeva suradnju s drugim poljima znanosti, osobito s računalnim znanostima. Poznavanje metoda strojnog učenja doprinosi povezivanju domenskog znanja s naprednim računalnim alatima. Prednost kemijskog inženjera u odnosu na stručnjaka računalnog usmjerenja u ovom kontekstu jest sposobnost postavljanja i rješavanja zadataka, kritičke analize podataka i smislenog tumačenja dobivenih rezultata u skladu s fizikalno-kemijskim zakonitostima.

Posebna vrijednost kemijskog inženjerskog pristupa jest u tome što gotovo uvijek ima praktičnu primjenu. Zbog toga umjetna inteligencija pridonosi razvoju rješenja koja se izravno primjenjuju na konkretne zadatke, bilo u ranom razvoju u laboratoriju, pilot postrojenju, bilo u primjeni na postrojenju.

Industrijski kemijske procese najčešće karakterizira veliki broj međusobno povezanih varijabli, nelinearni odnosi među njima, vremenska promjenjivost i dinamičke promjene. Zbog toga je razvoj pouzdanih modela koji se temelje isključivo na fundamentalnim zakonima veoma zahtjevan, a u pojedinim slučajevima i nedostatan za dobar opis stvarnog vladanja postrojenja, ponajprije zbog složenosti procesa i ograničene dostupnosti procesnih parametara. S druge strane, pristupi modeliranju temeljeni na podacima omogućuju razvoj empirijskih modela koji opisuju vladanje procesa na temelju reprezentativnih i kvalitetno obrađenih skupova podataka.

U mnogim slučajevima ključne procesne varijable ili svojstva proizvoda nije moguće kontinuirano mjeriti u realnom vremenu. Laboratorijske analize često su spore i diskontinuirane, dok su *on-line* procesni analizatori skupi, zahtjevni za održavanje i podložni kvarovima. Zbog toga se razvijaju softverski senzori za procjenu varijabli stanja. Softverski senzori mogu se temeljiti na fundamentalnim modelima ili, češće, empirijskim, na podacima na kojima se primjenjuju metode identifikacije procesa [1, 2]. Paralelno s time, metode strojnog učenja nalaze sve širu primjenu i u drugim

područjima kemijskog inženjerstva, primjerice u nadzoru procesa, procjeni kvalitete proizvoda, dijagnostici procesne opreme [3, 4], optimiranju radnih uvjeta, analizi spektroskopskih podataka, praćenju procesa [5, 6] i razvoju novih farmaceutskih formulacija i spojeva [7, 8], kao i zaštiti okoliša [9, 10]. Dodatni zamah dao je razvoj procesne analitičke tehnologije (PAT-a), naprednih senzorskih sustava, dostupnost komercijalnih i otvorenih sofisticiranih programskih alata za obradu podataka, kao i računalnih metoda za razvoj i vrednovanje modela.

Područje kemijskog inženjerstva kao i ostala tehnička područja već neko vrijeme prolazi kroz značajnu transformaciju potaknutu integracijom umjetne inteligencije (UI). Noviji pregledni radovi ističu promjenu paradigme od tradicionalnih pristupa temeljenih na pravilima i modelima zasnovanima na teorijskim načelima prema pristupima usmjerenima na podatke i modelima koji uče iz podataka [11, 12]. Ta je promjena osobito vidljiva u području razvoja novih materijala i molekula, pri čemu modeli umjetne inteligencije povezuju strukture i svojstava te ubrzavaju postupke probira, čime se značajno skraćuje vrijeme razvoja [13, 14]. Nadalje, primjena UI olakšava optimiranje procesa u stvarnom vremenu, prediktivno održavanje procesne opreme i razvoj digitalnih blizanaca dijelova ili cjelokupnih postrojenja [14, 15].

Osim povećanja učinkovitosti procesa, metode strojnog učenja sve se više primjenjuju i na složene proizvodne sustave, uključujući zelene procese poput valorizacije biomase i optimiranja sustava kemijskog kruženja (engl. *chemical looping*) [16, 17]. Također njihova se primjena sve više usmjerava prema načelima zelene kemije, s ciljem razvoja održivijih proizvodnih procesa optimiranjem iskorištenja resursa i racionalizacijom potrošnje energije [17].

Unatoč napretku i dalje postoje brojni izazovi. Stručnjaci iz industrije posebno ističu potrebu za reprezentativnim podacima iz različitih radnih uvjeta, većom interpretabilnošću modela i učinkovitim upravljanjem životnog ciklusa (razvoj, validacija, primjena i održavanje). To uključuje kontinuirano praćenje točnosti i pouzdanosti modela, njegovo ažuriranje s novim podacima i prilagodbu promjenama radnih uvjeta, kako bi se osigurala pouzdanost i sigurnost u industrijskom okruženju [14, 16]. Dodatna ograničenja su poteškoće u generalizaciji modela na različite radne uvjete, izazovi integracije modela u postojeće sustave za vođenje procesa, kao i regulatorni zahtjevi i sigurnost podataka. Osobito je to izraženo u farmaceutskoj proizvodnji u kojoj je primjena softverskih alata dodatno ograničena zahtjevima validacije sustava. U daljnjem razvoju ovog područja očekuje se da će razvoj hibridnih modela koji povezuju pristupe temeljene na fizikalnim zakonitostima i dubokom učenju, pomoći premostiti jaz između algoritama “crne kutije” i strogih zahtjeva kemijskog procesnog inženjerstva [15, 17]. Kako bi se povećalo povjerenje stručnjaka u primjenu modela, očekuje se i veća “objašnjivost” modela strojnog učenja primjenom metoda objašnjive umjetne inteligencije poput SHAP (engl. *SHapley Additive exPlanations*), LIME (engl. *Local Interpretable Model-agnostic Explanations*), analize važnosti značajki modela [18, 19].

U nastavku ovog rada dan je pregled metoda strojnog učenja koje su autori primijenili na vlastitim istraživačkim i suradničkim projektima na više područja istraživanja:

- razvoj softverskih senzora za procjenu teško mjerljivih procesnih varijabli,
- prediktivna dijagnostika industrijskih izmjenjivača topline,
- primjena procesne analitičke tehnologije u procesu kristalizacije,
- predviđanje raspodjele veličine čestica i koncentracije u suspenzijama,
- primjena klasifikacijskih modela u predviđanju nastanka kokristala i
- modeliranje koncentracije onečišćujućih tvari u zraku.

Svrha je prikazati primjenu tih metoda kroz primjere iz istraživačke i industrijske prakse kako bi se pokazalo da integracija procesnog znanja, eksperimentalnih podataka i metoda strojnog učenja doprinosi boljem razumijevanju, vođenju i optimiranju kemijskih procesa.

2. (Pred)obrada podataka, modeli strojnog učenja i softverski alati

2.1 Predobrada podataka

Razvoj modela strojnog učenja u kemijskom inženjerstvu uvelike ovisi o kvaliteti i reprezentativnosti dostupnih podataka. Budući da se modeli temelje na mjernim podacima dobivenim laboratorijskim eksperimentima ili iz industrijskih postrojenja, prvi korak u razvoju empirijskih modela predstavlja kritička analiza i predobrada podataka. Cilj predobrade jest uklanjanje pogrešaka i neželjenih utjecaja iz mjernih signala te priprema podataka u obliku prikladnom za razvoj modela.

Jedan od prvih koraka u analizi podataka jest primjena deskriptivne statistike radi osnovnog uvida u distribuciju i karakteristike mjerenih veličina. Grafički prikazi poput histograma, *box-plot* dijagrama i dijagrama raspršenja prikladne su za vizualni pregled distribucije podataka, identifikaciju odstupanja i analizu korelacija između varijabli.

U bazama procesnih podataka česte nedostaju neke vrijednosti (engl. *missing values*) zbog kvara senzora, problema u prijenosu signala ili održavanja mjerne opreme. Takve vrijednosti potrebno je za daljnju obradu podataka nadomjestiti, primjerice interpoliranim vrijednostima. Dodatni koraci obuhvaćaju uklanjanje šuma, trendova i klizanja karakteristike senzora primjenom metoda filtriranja i izgladivanja, primjerice filtara pomičnog prosjeka, Savitzky-Golay ili LOESS filtra [2].

Posebnu pozornost potrebno je posvetiti otkrivanju (uočavanju) ekstremnih vrijednosti (engl. *outliers*) koje nastaju zbog pogrešaka u mjerenju, kvara mjernog pretvornika, poremećaja u radu procesa ili odstupanja od uobičajenih radnih uvjeta. Za identifikaciju često se primjenjuje pravilo 3σ , analiza reziduala i metode temeljene na multivarijatnim udaljenostima.

Prije razvoja modela provodi se i skaliranje podataka jer procesne varijable mogu imati različite redove veličina i fizikalne jedinice. U tu svrhu primjenjuju se postupci normalizacije ili standardizacije. Važno je naglasiti da se predobrada podataka, odabir značajki i razvoj modela treba provoditi isključivo na skupu podataka za treniranje kako bi se izbjegao problem “curenja” podataka (engl. *data leakage*).

Predobrada spektralnih podataka

Kod procesne analitičke tehnologije (engl. *process analytical technology*, PAT) za praćenje kemijskog sastava i svojstava u stvarnom vremenu u primjeni su metode poput Ramanove i infracrvene spektroskopije. Spektralni podaci dobiveni tim metodama često sadrže različite neželjene doprinose signalu koji mogu otežati interpretaciju i smanjiti pouzdanost modela. Cilj predobrade spektralnih podataka jest uklanjanje ili smanjenje utjecaja pojava poput fluorescencije, raspršenja svjetlosti, šuma detektora, pogrešaka umjeravanja, kozmičkih zraka i fluktuacija snage izvora zračenja. Budući da i male razlike u spektrima mogu sadržavati važne informacije, potrebno je izbjeći pretjeranu obradu podataka kako ne bi došlo do izobličenja spektra ili gubitka relevantnih informacija.

Uobičajene metode predobrade obuhvaćaju korekciju raspršenosti i derivacijske metode [20]. U korekciju raspršenosti ubrajaju se multiplikativna korekcija signala, standardna normalna varijacija, normalizacija spektra i korekcija bazne linije. Derivacijske metode primjenjuju se za razdvajanje preklapljenih vrpca i smanjenje utjecaja promjena bazne linije, a uobičajeno se kombiniraju s postupcima izgladivanja, poput Savitzky-Golay filtriranja. Postupke predobrade potrebno je prilagoditi spektroskopskoj metodi i karakteristikama analiziranog sustava.

2.2 Modeli strojnog učenja

Razvoj metoda strojnog učenja donio je primjenu naprednih računalnih modela u analizi i optimiranju kemijskih procesa. U kemijskom inženjerstvu metode strojnog učenja najčešće se koriste za razvoj softverskih senzora, analizu spektroskopskih podataka, optimiranje procesa, predviđanje svojstava materijala te modeliranju u području zaštite okoliša. Ovisno o prirodi zadatka, metode strojnog učenja dijele se na metode regresije, klasifikacije i modele za analizu vremenskih nizova. Pregled standardnih metoda dan je u tablici 1.

Tablica 1: Pregled standardnih metoda strojnog učenja u kemijskom inženjerstvu

Skupina metoda	Algoritmi	Tip problema	Tipične primjene u kemijskom inženjerstvu
Linearni i multivarijantni modeli	MLR, PCA, PLS	regresija	kemometrija, analiza spektara, kalibracijski modeli u PAT sustavima, softverski senzori
Metode stabala odlučivanja	stabla odlučivanja (engl. <i>decision tree</i>), slučajna (nasumična) šuma (engl. <i>random forest</i>), XGBoost	regresija, klasifikacija	predviđanje kvalitete proizvoda, procesni podaci, analiza okolišnih podataka (npr. koncentracije onečišćujućih tvari), optimiranje procesa
Metode potpornih vektora	SVM, SVR	klasifikacija, regresija	klasifikacija kemijskih spojeva i materijala, analiza spektroskopskih podataka, predviđanje fizikalno-kemijskih svojstava tvari
Umjetne neuronske mreže	MLP, konvolucijske mreže (CNN)	regresija, klasifikacija	modeliranje nelinearnih kemijskih procesa, analiza spektroskopskih i slikovnih podataka, predviđanje svojstava materijala
Rekurentne mreže	RNN, LSTM, GRU	vremenski nizovi	dinamika procesa, predviđanje vladanja procesa, analiza vremenskih nizova iz postrojenja, praćenja onečišćivala u okolišu
Ansambel metode	slučajna šuma, <i>gradient boosting</i>	regresija, klasifikacija	prediktivno modeliranje složenih procesa, analiza velikih skupova podataka, razvoj robusnih modela za optimiranje i nadzor procesa

Metode linearne i multivarijantne regresije

Jedan od standardnih pristupa u kemijskom inženjerstvu je multivarijantna regresijska analiza koja (funkcijski) opisuje odnose između više ulaznih varijabli i jednog ili više izlaza sustava. Ove metode posebno su važne u analizi spektroskopskih podataka i u razvoju jednostavnijih struktura softverskih senzora.

Između ostalih metoda ističu se:

- višestruka linearna regresija (engl. *multilinear regression*, MLR)
- regresija parcijalnih najmanjih kvadrata (engl. *partial least squares*, PLS)
- analiza glavnih komponenti (engl. *principal component analysis*, PCA)

PCA metoda primjenjuje se za smanjenje dimenzionalnosti podataka i otkrivanje skrivenih obrazaca u velikim skupovima podataka, dok se PLS-om modelira odnos između ulaznih i izlaznih varijabli, čak i kada su ulazne varijable međusobno značajno korelirane. Zbog toga se ove metode široko primjenjuju u kemometriji i analizi spektroskopskih podataka.

Metode temeljene na stablima odlučivanja

Metode temeljene na stablima odlučivanja predstavljaju skup algoritama za regresijske i klasifikacijske zadatke. Stabla odlučivanja temelje se na hijerarhijskoj strukturi čvorova u kojoj se skup podataka postupno dijeli prema vrijednostima ulaznih varijabli kako bi se dobile što homogenije skupine podataka s obzirom na ciljnu varijablu. Prednost im je relativno jednostavna interpretacija rezultata i rad s nelinearnim odnosima između varijabli.

U ovoj skupini ističu se: stabla odlučivanja, slučajna (nasumična) šuma, *gradient boosting* i *extreme gradient boosting* (tzv. XGBoost).

Metoda slučajne šume i XGBoost posebno su popularne u kemijskom inženjerstvu zbog visoke pouzdanosti pri predviđanju i otpornosti na smetnje u podacima [21]. Te metode primjenjuju se u predviđanju kvalitete proizvoda, modeliranju podataka koncentracija onečišćujućih tvari u okolišu (npr. plinova i lebdećih čestica) i optimiranju industrijskih procesa.

Metode potpornih vektora

Metoda potpornih vektora (engl. *support vector machines*, SVM) razvijena je za rješavanje klasifikacijskih i regresijskih problema u složenim i nelinearnim sustavima. Ova metoda traži optimalnu granicu razdvajanja između različitih klasa podataka ili funkciju koja najbolje opisuje odnos između ulaznih i izlaznih varijabli. Pri tome se nelinearni odnosi modeliraju primjenom različitih *kernel* funkcija. U kemijskom inženjerstvu SVM se često primjenjuje za klasifikaciju kemijskih spojeva, predviđanje svojstava materijala, analizu spektroskopskih podataka i razvoj softverskih senzora.

Umjetne neuronske mreže

Umjetne neuronske mreže najučestalija je metoda strojnog učenja u kemijskom inženjerstvu. Temelje se na međusobno povezanim umjetnim neuronima organiziranim u slojeve koji tijekom procesa učenja prilagođavaju težinske koeficijente veza kako bi aproksimirali odnos između ulaznih i izlaznih podataka. Služe za modeliranje složenih nelinearnih odnosa između procesnih varijabli. Primjenjuje se za modeliranje kemijskih reakcija, predviđanje svojstava i kvalitete proizvoda, optimiranje procesa i analizu spektroskopskih podataka.

Uobičajene mrežne arhitekture su:

- višeslojne perceptronske (MLP) mreže
- konvolucijske neuronske mreže (CNN)
- rekurentne neuronske mreže (RNN)
- *Long Short-Term Memory* (LSTM) i *Gated Recurrent Unit* (GRU) mreže
- transformerske neuronske mreže (engl. *Transformers*).

Rekurentne neuronske mreže kao i LSTM mreže [22] posebno su pogodne za analizu vremenskih nizova i modeliranje dinamičkog vladanja procesa jer uzimaju u obzir vremensku ovisnost podataka. Transformerske arhitekture temelje se na mehanizmu pažnje

(engl. *attention*), a primjenjuju se u analizi sekvencijskih podataka, modeliranju molekularnih struktura i predviđanju fizikalno-kemijskih svojstava molekula i materijala.

Ansambl metode i duboko učenje

U novijim istraživanjima sve se češće primjenjuju ansambl metode koje kombiniraju rezultate više pojedinačnih modela kako bi se postigla veća točnost i robusnost predviđanja. Takvi pristupi uključuju metode poput slučajne šume i *gradient boostinga* ([23]).

Paralelno s time, razvoj dubokog učenja (neuronskih mreža s većim brojem skrivenih slojeva) omogućuje primjenu kompleksnih modela koji automatski uče značajke iz velikih skupova podataka. Za razliku od tradicionalnih metoda strojnog učenja, duboke neuronske mreže automatski izdvajaju relevantne značajke iz sirovih podataka bez potrebe za opsežnim ručnim odabirom ulaznih varijabli. Duboke neuronske mreže danas se primjenjuju u: analizi spektroskopskih i slikovnih podataka, modeliranju molekularnih struktura, predviđanju svojstava materijala i razvoju digitalnih blizanaca kemijskih procesa.

2.3 Softverski alati za primjenu strojnog učenja u kemijskom inženjerstvu

Primjena strojnog učenja uvelike je potaknuta razvojem računalnih alata za obradu velikih skupova podataka, modeliranje, kao i integraciju modela u sustave za nadzor i vođenje procesa. U praksi je na raspolaganju velik broj softverskih alata.

U području analize podataka i strojnog učenja ističe se Python kojim se, zahvaljujući brojnim bibliotekama, razvijaju različiti modeli strojnog i dubokog učenja. Ističu se biblioteke NumPy i Pandas za obradu podataka, Scikit-learn za strojno učenje, kao i TensorFlow i PyTorch za razvoj dubokih neuronskih mreža.

U kemijskom i procesnom inženjerstvu široko se primjenjuje i MATLAB, koji nudi brojne alate za numeričku analizu, identifikaciju procesa i razvoj modela strojnog učenja. Posebno su važni *Statistics and Machine Learning Toolbox* i *Deep Learning Toolbox*.

Za statističku analizu i obradu podataka postoji programski jezik R koji sadrži velik broj paketa za statističko modeliranje, vizualizaciju podataka i primjenu metoda strojnog učenja.

Osim programskih jezika, postoje i platforme za analizu podataka s grafičkim sučeljem, poput KNIME, RapidMiner, Quasar i Orange, u kojima se programira vizualno. U kemijskoj industriji i procesnoj analitici važnu ulogu imaju i specijalizirani kemometrijski softveri poput SIMCA, Unscrambler i Pirouette, koji se primjenjuju za multivarijantnu analizu.

Razvoj i dostupnost ovih alata značajno su doprinijeli širenju primjene strojnog učenja u kemijskom inženjerstvu te omogućili integraciju naprednih analitičkih metoda u istraživačke i industrijske procese.

3. Primjeri primjene modela strojnog učenja


3.1 Softverski senzori u kemijskoj procesnoj industriji

Softverski senzori predstavljaju matematičke modele s kojima se procjenjuju procesne varijable ili svojstva proizvoda koja se ne mogu izravno mjeriti ili čije je mjerenje otežano. Temelje se na dostupnim procesnim mjerenjima poput temperature, tlaka ili protoka. U industrijskoj praksi softverski senzori služe kao zamjena za skupe ili nepouzdanе analitičke instrumente ili kao pomoćni sustavi za procjenu kvalitete proizvoda u realnom vremenu.

Softverski senzori se razvijaju linearnim i nelinearnim modelima (engl. *system identification*), kao i metodama strojnog učenja. U procesnoj industriji primjenjuju se dinamičke linearne i nelinearne strukture parametarskih modela poput FIR, ARX, OE i Hammerstein-Wiener modela za opisivanje dinamičkog vladanja procesa.

3.1.1 Primjer: Procjena sadržaja benzena u lakom reformatu

Jedan od primjera softverskih senzora razvijenih na Zavodu za mjerenja i automatsko vođenje procesa odnosi se na procjenu sadržaja benzena u katalitičkom reformatu u rafinerijskoj proizvodnji[24]. Proces katalitičkog reformiranja obuhvaća frakcioniranje reformata u sustavu kolona (slika 1), pri čemu se benzen koncentrira u lakom reformatu koji se dalje obrađuje kako bi se zadovoljili zahtjevi za kvalitetom goriva. Kontinuirano praćenje sadržaja benzena u reformatu važno je zbog ekoloških regulativa i zahtjeva za kvalitetom goriva. Međutim, *on-line* analizatori za mjerenje sastava benzena često nisu dostupni ili zahtijevaju složeno i učestalo održavanje, a laboratorijske analize su prerijetke s obzirom na moguće promjene u procesu. U tom slučaju razvijen je softverski senzor temeljen na procesnim podacima dobivenim iz distribuiranog sustava za vođenje procesa (DCS).



Slika 1: Pojednostavljena shema frakcioniranja reformata i procesne varijable korištene za razvoj softverskog senzora [24]

Modeli su razvijeni primjenom linearnih i nelinearnih metoda identifikacije procesa, uključujući FIR, *Output Error* (OE) i Hammerstein-Wiener (HW) modele u programskom jeziku Matlab. FIR i OE modeli pripadaju skupini linearnih dinamičkih modela koji opisuju odnos između ulaznih i izlaznih varijabli procesa, dok HW model predstavlja nelinearnu strukturu koja kombinira linearni dinamički blok s nelinearnim transformacijama ulaza i izlaza. Ulazne varijable su kontinuirano mjerene procesne veličine poput temperature, ulaznog protoka u kolonu, temperature dna kolone, temperature u koloni, tlaka u koloni i protoka refluksa u frakcionacijsku kolonu. Podaci su prikupljeni tijekom nekoliko tjedana neprekidnog rada postrojenja, uz odgovarajuću predobradu podataka, filtriranje i uklanjanje ekstremnih vrijednosti. Modeli su optimirani primjenom genetičkih algoritama kako bi se odredili optimalni redovi i parametri modela. Usporedba razvijenih modela pokazala je da je OE model ostvario najveću točnost predviđanja ($FIT \approx 90\%$) na validacijskom skupu podataka, dok je HW model pokazao nešto slabije, ali zadovoljavajuće rezultate ($FIT \approx 88\%$), a FIR model, kao strukturno najjednostavniji model, postigao je najnižu točnost ($FIT \approx 79\%$).

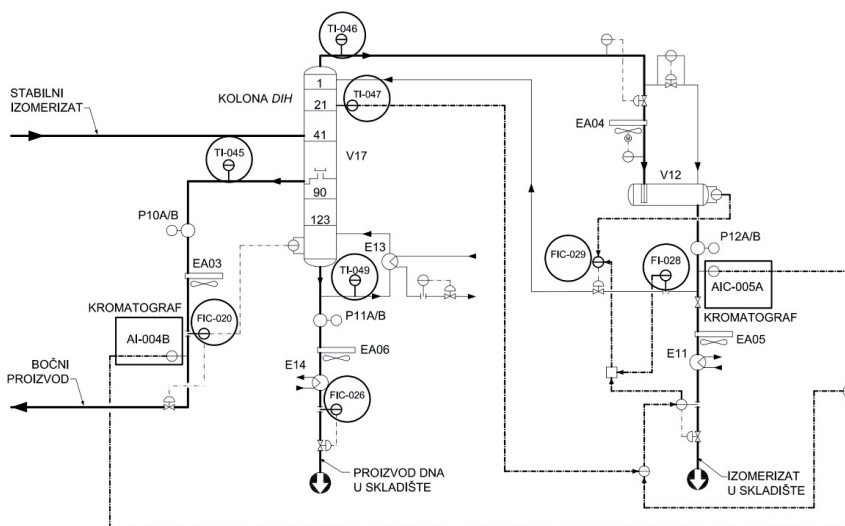
3.1.2 Primjer procjene sadržaja sumpora u procesu hidrodosulfurizacije

Sličan pristup modeliranju može se primijeniti i u procesu hidrodosulfurizacije. U ovom procesu se kontinuirano prati sadržaj sumpora u proizvodu, što je iznimno važno zbog zahtjeva za kvalitetom goriva i zaštitom okoliša. Budući da su laboratorijske analize rijetke, a procesni analizatori mogu biti u kvaru ili vremenski zahtjevni, razvi-

jaju se softverski senzori za procjenu sadržaja sumpora na temelju kontinuirano mje-
renih procesnih varijabli kao što su temperatura i tlak reaktora, ulazni protok, omjer
 H_2 / nafta, temperatura nakon izmjenjivača i tlak separatora [25]. U istraživanju [25]
razvijeni su modeli temeljeni na metodama identifikacije procesa (FIR, ARX, OE,
NARX i HW) i modeli strojnog učenja poput umjetnih neuronskih mreža, LSTM i
GRU mreža. Usporedba modela pokazala je da su modeli temeljeni na neuronskim
mrežama postigli najveću točnost predviđanja sadržaja sumpora, dok su OE i HW
modeli pokazali vrlo dobre rezultate uz jednostavniju i interpretabilniju strukturu.

3.1.3 Primjer procjene kvalitete proizvoda u procesu izomerizacije

U radu Hercega i sur. [26] razvijeni su modeli za procjenu sastava proizvoda u procesu
izomerizacije primjenom metoda strojnog učenja. Na slici 2 prikazana je sekcija deizo-
heksanizacijske kolone u kojoj se odvaja izomerat čiji sastav značajno utječe na oktanski
broj benzina. U razvijenim modelima izlazna varijabla bila je procesni parametar
povezan s oktanskim brojem benzina izražen udjelom spojeva 2,3-dimetilbutana (2,3-
DMB) i 3-metilpentana (3-MP). Poseban naglasak stavljen je na primjenu dinamičkih
neuronskih mreža LSTM arhitekture za modeliranje vremenski ovisnih procesa.



Slika 2: Sekcija deizoheksanizacijske kolone u procesu izomerizacije [26]

Rezultati su uspoređeni s drugim pristupima modeliranju temeljenim na podacima,
uključujući višeslojni perceptron, metode potpornih vektora i dinamičke polinomske
modele. Dobiveni rezultati pokazali su da LSTM mreže mogu uspješno opisati dina-
mičko vladanje industrijskih procesa za procjenu teško mjerljivih svojstava proizvo-
da u realnom vremenu.

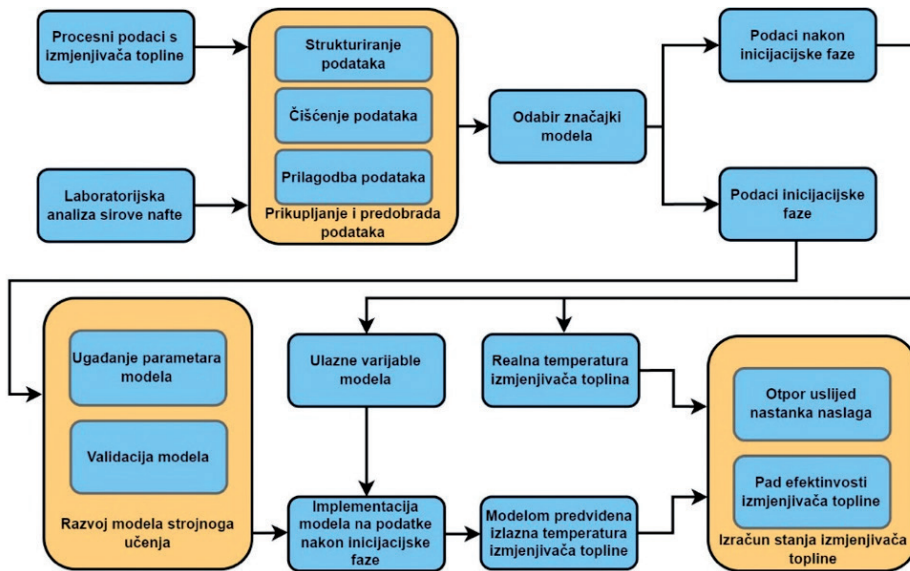
3.2 Praćenje učinkovitosti izmjenjivača topline

Učinkovitost industrijskih izmjenjivača topline s vremenom pada zbog taloženja naslaga na površinama za prijenos topline (engl. *fouling*), promjena radnih uvjeta ili degradacije opreme. Smanjenje učinkovitosti izmjenjivača topline izravno utječe na potrošnju energije, ekonomičnost procesa i emisije štetnih plinova u okoliš. Praćenje učinkovitosti izmjenjivača topline temelji se na analizi toplinskih parametara kao što su koeficijent prijenosa topline, temperaturne razlike i protoci radnih fluida. Razvojem modela temeljenih na procesnim podacima kontinuirano se procjenjuje stanje izmjenjivača topline u realnom vremenu i pravovremeno detektiraju promjene.

Jedan od primjera je razvoj modela za detekciju nastajanja naslaga u izmjenjivačima topline u rafinerijskom sustavu za predgrijavanje nafte u sklopu postrojenja za preradu sirove nafte [27]. U radu su uzeti podaci iz industrijskog postrojenja procesnih varijabli poput ulaznih i izlaznih temperatura toplog i hladnog toka, protoka fluida i drugih parametara vezanih za izmjenu topline.

Modeli su razvijeni primjenom LSTM neuronske mreže i XGBoost algoritma. Uspoređeni su s poluempirijskim pristupom temeljenim na ϵ -NTU metodi. Modeli su uvježbani na podacima iz početne faze rada izmjenjivača kada se sustav smatra čistim. Cilj je bio predvidjeti izlazne temperature izmjenjivača topline u tom stanju (slika 3).

Kako se tijekom rada na površini za prijenos topline postupno razvijaju naslage, pojavljuje se odstupanje između predviđenih i stvarno izmjerenih izlaznih temperatura. Ta odstupanja temelj su za procjenu koeficijenta prolaza topline i izračun otpora naslaga (engl. *fouling resistance*). Na taj način kontinuirano se prati učinkovitost izmjenjivača topline i pravovremeno detektira *fouling*. U radu je također analiziran utjecaj sastava i fizikalno-kemijskih svojstava sirove nafte na nastajanje *foulinga*. Provedena je detaljna analiza značajki (engl. *feature analysis*) i interpretacija modela za bolje razumijevanje doprinosa pojedinih procesnih varijabli i fizikalno-kemijskih parametara pojavi naslaga u izmjenjivačima topline.



Slika 3: Postupak procjene otpora uslijed nastanka naslaga i učinkovitosti izmjenjivača topline primjenom LSTM i XGBoost modela [27]

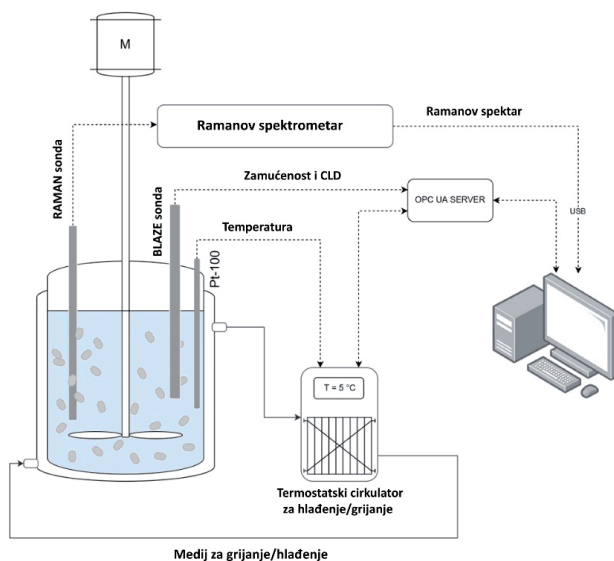
U radu Ujević Andrijić i sur. [28] razvijen je sličan sustav za detekciju nastajanja naslaga u industrijskom izmjenjivaču topline u rafinerijskom postrojenju hidrokrekiranja primjenom modela temeljenih na podacima i poluempirijskih pristupa. Stanje izmjenjivača procjenjuje se modelom temeljenom na metodi broja prijenosnih jedinica (ϵ -NTU), umjetnom neuronskom mrežom i nelinearnim dinamičkim modelima tipa NFIR. Modeli su razvijeni na temelju kontinuirano mjenjenih temperatura i protoka radnih fluida. Predviđaju izlazne temperature izmjenjivača topline. Odstupanje između predviđenih i stvarnih izlaznih temperatura indikator je smanjenja učinkovitosti prijenosa topline i razvoja naslaga na površinama za prijenos topline. Rezultati su pokazali da neuronske mreže kao i NFIR modeli mogu pouzdano detektirati nastanak naslaga i kvantificirati promjene u učinkovitosti izmjenjivača topline.

3.3 Procesna analitička tehnologija u kristalizacijskim procesima

Kristalizacija je jedan od ključnih procesa u farmaceutskoj industriji jer određuje fizikalna svojstva proizvoda poput veličine čestica, polimorfnog oblika i topljivosti. Kontinuirano praćenje kristalizacijskog procesa ostvaruje se primjenom alata procesne analitičke tehnologije (PAT). PAT obuhvaća primjenu naprednih analitičkih metoda za mjerenje kritičnih procesnih varijabli u realnom vremenu, čime se postiže bolje vođenje procesa i kvaliteta proizvoda. U kristalizacijskim procesima često se rabe tehnike poput Raman spektroskopije, FTIR spektroskopije, *in-line* mikroskopije i mjerenja zamućenosti. Ramanova spektroskopija primjenjuje se za procjenu kon-

centracije otopljene tvari i praćenje promjena u kristalnoj strukturi tijekom procesa kristalizacije. Zbog složenosti signala često je potrebno razviti multivarijatne kalibracijske modele koji uzimaju u obzir promjene u veličini i koncentraciji kristala.

Primjer takvog pristupa prikazan je u razvoju kalibracijskog modela za procjenu koncentracije otopljene djelatne farmaceutske tvari tijekom kristalizacije ceritiniba [29]. Pokazano je da uključivanje varijabli povezanih s veličinom kristala i koncentracijom čvrste faze značajno poboljšava procjenu koncentracije u dvofaznom sustavu. U istraživanju su primijenjene Ramanova spektroskopija, *in-line* procesna mikroskopija i mjerenje zamućenosti suspenzije, kako je prikazano na Slici 4.



Slika 4: Eksperimentalni postav procesa kristalizacije [29]

Ramanovom spektroskopijom prati se koncentracija otopljene tvari i identificira kristalne strukture tijekom provedbe kristalizacije. *In-line* procesnom mikroskopijom procjenjuje se veličina kristala putem distribucije duljine tetiva (engl. *chord length distribution*), pri čemu su kriteriji percentili D10, D50 i D90. Zamućenost suspenzije indikator je koncentracije čvrste faze.

Prije razvoja kalibracijskog modela provedena je analiza i obrada prikupljenih Ramanovih spektara. Primijenjene su različite metode predobrade spektralnih podataka. Za procjenu robusnosti modela primijenjena je metoda unakrsne validacije, pri čemu su pojedini skupovi podataka s različitim koncentracijama otopljene tvari uzimani naizmjenično za treniranje i validaciju modela. Za procjenu koncentracije otopljene djelatne tvari razvijeni su multivarijatni kalibracijski modeli temeljeni na parcijalnoj regresiji najmanjih kvadrata i umjetnim neuronskim mrežama. Ulazne varijable modela uključivale su Ramanove spektre, temperaturu procesa, zamućenost suspenzije


i parametre raspodjele veličine kristala. Rezultati su pokazali da modeli neuronskih mreža dobro procjenjuju koncentraciju otopljene tvari tijekom kristalizacije, pri čemu pogreška predviđanja nije prelazila približno 1 % nominalne koncentracije.

3.4 Predviđanje raspodjele veličine čestica tijekom kristalizacije

Raspodjela veličine čestica (engl. *particle size distribution*, PSD) predstavlja jedno od ključnih svojstava kristalnih proizvoda u farmaceutskoj i kemijskoj industriji. Ona izravno utječe na svojstva poput topljivosti, brzine otapanja, filtrabilnosti i daljnje obradivosti proizvoda. Za procjenu raspodjele veličine čestica primjenjuju se *in-line* mikroskopija, FBRM metode i optičke metode analize slike. Razvojem matematičkih modela i metoda strojnog učenja povezuju se procesne varijable s promjenama u raspodjeli veličine čestica.

U radu Vrbana i sur. [30] razvijen je model temeljen na strojnom učenju za predviđanje parametara veličine kristala tijekom procesa kristalizacije hlađenjem. Za analizu vremenskih nizova procesnih podataka primijenjena je LSTM neuronska mreža. Podaci su prikupljeni *in-situ* mikroskopijom, mjerenjem temperature, brzine hlađenja i količine cjepiva kristala. Cilj je bio predvidjeti metrike veličine kristala - D10, D50 i D90 koji karakteriziraju raspodjelu veličina čestica. Kako bi poboljšali predikciju modela proveden je postupak inženjerstva značajki (engl. *feature engineering*) pri čemu su uvedeni dodatni procesni deskriptori, poput derivacija i integrala temperature. Rezultati pokazuju da se LSTM modelom dobro predviđa raspodjela veličina kristala bez izravnog mjerenja prezasićenosti (Slika 5).

Takav pristup omogućuje bolje razumijevanje utjecaja procesnih uvjeta na razvoj kristala, a istovremeno pomaže pri optimiranju kristalizacijskih procesa i prijenosu procesa s laboratorijske na poluindustrijsku i industrijsku razinu.



Slika 5: Usporedba Avg Val Loss za LSTM mreže: (a) uz inženjerstvo značajki i (b) bez inženjerstva značajki [30]

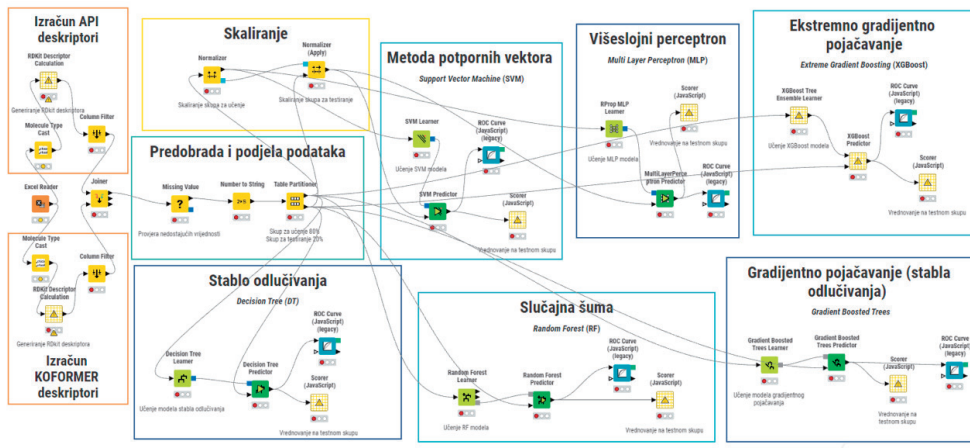
3.5 Strojno učenje u predviđanju nastanka kokristala

Kokristali predstavljaju kristalne sustave sastavljene od djelatne farmaceutske tvari (engl. *active pharmaceutical ingredient* - API) i koformera u određenom molarnom omjeru. Primjenjuju se za poboljšanje fizikalno-kemijskih svojstava lijekova poput topljivosti, stabilnosti i brzine otapanja. Tradicionalni postupci ispitivanja nastanka kokristala temelje se na eksperimentalnom probiru (engl. *screening*) velikog broja kombinacija API-ja i koformera, što je vremenski i financijski zahtjevno. Stoga se sve češće primjenjuju metode strojnog učenja za predviđanje mogućnosti formiranja kokristala na temelju molekulskih deskriptora. Modeli strojnog učenja koriste različite molekulske deskriptore poput broja donora i akceptora vodikovih veza, $\log P$ vrijednosti, topološke polarne površine i molekulske mase, broja rotacijskih veza i drugih strukturnih značajki molekula. Takvim deskriptorima kvantitativno se opisuju molekulska svojstva te povezuju strukture molekula s potencijalnim formiranjem kokristala.

3.5.1 Primjer klasifikacijskog modela za predviđanje kokristala

Primjer klasifikacijskog modela za predviđanje nastanka kokristala temelji se na uređenim parovima API-ja i koformera te skupu molekulskih deskriptora izračunatih iz strukturnih zapisa molekula. Podaci o poznatim kokristalima prikupljaju se iz baza kristalnih struktura ili iz relevantnih znanstvenih radova, nakon čega se iz molekulskih struktura izračunavaju odgovarajući deskriptori. Na temelju tih podataka razvijen je klasifikacijski model neuronske mreže koji predviđa vjerojatnost nastanka kokristala za određeni par molekula. Kako bi se procijenila sposobnost generalizacije model je uvježban i validiran primjenom postupaka unakrsne validacije na novim kombinacijama API-ja i koformera. Među brojnim strukturama modela (Slika 6) najbolje rezultate postigao je XGBoost model s prosječnim slaganjem od 80 % na validacijskom skupu.

Takvi modeli služe kao alat u preliminarnom odabiru perspektivnih kombinacija za eksperimentalna ispitivanja, čime se značajno smanjuje broj laboratorijskih eksperimenata i, time, ubrzava razvoj novih farmaceutskih formulacija.




Slika 6: Dijagram toka razvoja modela u KNIME platformi [31]

3.6 Modeliranje koncentracije onečišćujućih tvari u zraku

3.6.1 Primjer razvoja modela za predviđanje koncentracije dušičnih oksida


U radu od Zaninović [32] razvijeni su modeli strojnog učenja za predviđanje koncentracije dušikovih oksida (NO_x) u zraku na području Zagreba. Modeli su razvijeni na temelju podataka s mjernih postaja za praćenje kvalitete zraka i meteoroloških podataka: temperature zraka, brzine i smjera vjetera, relativne vlažnosti i atmosferskog tlaka. Za razvoj modela primijenjene su metode slučajne šume, XGBoost i umjetne neuronske mreže, a razvoj i evaluacija modela provedeni su u programskom jeziku Python. Dobiveni rezultati (slika 7) pokazuju da modeli uspješno opisuju promjene koncentracije NO_x ($R^2 \approx 0,70$; $\text{RMSE} \approx 28,7 \mu\text{g}/\text{m}^3$) i prepoznaju trendove onečišćenja zraka, što potvrđuje prikladnost za primjenu u sustavima za praćenje kvalitete zraka i potporu pri donošenju preventivnih mjera.



Slika 7: Usporedba vrijednosti koncentracije dušikovih oksida modelom XGBoost za mjernu postaju ZG3 sa stvarnim vrijednostima koncentracije dušikovih oksida na skupu za validaciju [32]

3.6.2 Primjer razvoja modela za predviđanje indeksa kvalitete zraka

U diplomskom radu Klonkay [33] razvijeni su modeli strojnog učenja za procjenu indeksa kvalitete zraka (AQI) povezanog s koncentracijama lebdećih čestica PM10 i PM2,5 na području Zagreba. Modeli su razvijeni na temelju podataka prikupljenih na mjernim postajama državne mreže za praćenje kvalitete zraka te meteoroloških podataka. Za razvoj klasifikacijskih modela primijenjene su metoda slučajne šume i metoda potpornih vektora (SVM) u programskom jeziku Python. Rezultati su pokazali da model slučajne šume ostvaruje veću točnost (97 %) u odnosu na SVM model (87 %) na sve tri lokacije što se može pripisati boljoj sposobnosti modela slučajne šume da opiše složene nelinearne odnose između varijabli i većoj otpornosti na šum u podacima. Na Slici 8 prikazana je dobra podudarnost između stvarnih i modelom slučajne šume predviđenih vrijednosti AQI za testni skup podataka za svih šest razina AQI.



Slika 8: Prikaz stvarnih i RF modelom predviđenih vrijednosti AQI za testni skup podataka [33]

4. Zaključak

Ovim pregledom nastojalo se prikazati kako se metode modeliranja i strojnog učenja primjenjuju u različitim granama kemijskog procesnog inženjerstva.

Integracija matematičkih modela, naprednih analitičkih metoda i strojnog učenja dala je značajan impuls za razvoj digitalnih alata za praćenje, dijagnostiku i optimiranje industrijskih procesa. Očekuje se da će se daljnji razvoj zbivati kroz integraciju velikih skupova podataka, naprednih metoda optimizacije, hibridnih modela i digitalnih blizanaca procesa.

Razvoj metoda strojnog učenja i primjena softverskih senzora imaju značajnu perspektivu u kemijskom inženjerstvu, osobito u području prediktivnog vođenja procesa i optimiranja rada u stvarnom vremenu, kao i u praćenju stanja sustava i okoliša. Posebno se ističe primjena u prediktivnom održavanju za pravovremeno predviđanje kvarova i problema u radu postrojenja čime se smanjuje vrijeme zastoja i planira održavanja opreme i postrojenja.

U skoroj budućnosti očekuje se sve veća primjena u razvoju digitalnih blizanaca postrojenja koji kombiniraju modele temeljene na fizikalnim zakonitostima i one razvijene metodama strojnog učenja. Takvi sustavi služe za simulaciju različitih scenarija rada bez rizika za stvarno postrojenje. Također, pružaju podršku pri optimiranju procesa i donošenju operativnih odluka.

Unatoč navedenim prednostima, primjena ovih metoda i dalje je ograničena izazovima poput nedostatka relevantnih podataka, nedovoljne interpretabilnosti modela i složene integracije u postojeće sustave.

U kontekstu primjene strojnog učenja u industrijskim procesima sve se više naglašava koncept “*human-in-the-loop*” sustava, u kojima modeli strojnog učenja pružaju potporu odlučivanju, dok nezamjenjivu ulogu i dalje ima inženjer koji detaljno poznaje proces, podatke i ograničenja sustava pa, na temelju toga, smisleno tumači i primjenjuje rezultate analize.

Kemijsko inženjerstvo nalazi se u fazi intenzivne digitalne transformacije, pri čemu integracija procesnog znanja s metodama podatkovne znanosti i strojnog učenja predstavlja ključan smjer budućeg razvoja koji otvara nove mogućnosti za unapređenje industrijskih procesa.

5. Literatura

- [1] Kadlec, P.; Gabrys, B., Strandt, S.: Data-driven soft sensors in the process industry, *Computers and Chemical Engineering*, **33** (2009) 795-814, <https://doi.org/10.1016/j.compchemeng.2008.12.012>
- [2] Fortuna, L.; Graziani, S., Rizzo, A., Xibilia, M.G.: *Soft Sensors for Monitoring and Control of Industrial Processes (Advances in Industrial Control)*; Springer: London, UK (2007)
- [3] Wang, J.; Sun, L., Li, H., Ding, R., Chen, N.: Prediction Model of Fouling Thickness of Heat Exchanger Based on TA-LSTM Structure, *Processes*, **11** (2023) 845, <https://doi.org/10.3390/pr11092594>.
- [4] Al Shabaan, M. A.; Nemer, Z. N.: Oil and Gas Production Forecasting Using Decision Trees, Random Forest, and XGBoost, *Journal of Al-Qadisiyah Computer Science and Mathematics*, **16** (2024) 864, <https://doi.org/10.29304/jqcs.2024.16.11431>.

- [5] Lin, M.; Wu, Y., Rohani, S.: Simultaneous Measurement of Solution Concentration and Slurry Density by Raman Spectroscopy with Artificial Neural Network, *Crystal Growth & Design*, **20** (2020) 1752-1759
- [6] Wu, Y.; Gao, Z., Rohani, S.: Deep Learning-Based Oriented Object Detection for in Situ Image Monitoring and Analysis: A Process Analytical Technology (PAT) Application for Taurine Crystallization, *Chemical Engineering Research and Design*, **170** (2021) 444-455
- [7] Birolo, R.; Bravetti, F., Alladio, E., Priola, E., Bianchini, G., Novelli, R., Aramini, A., Gobetto, R., Chierotti, M. R.: Speeding Up the Cocrystallization Process: Machine Learning-Combined Methods for the Prediction of Multicomponent Systems, Supporting Materials, *Crystal Growth & Design*, **23** (2023) 2-12
- [8] Deng, J.; Ye, Z., Zheng, W., Chen, J., Gao, H., Wu, Z., Chan, G., Wang, Y., Cao, D., Wang, Y.; Lee, S. M.: Machine learning in accelerating microsphere formulation development, *Drug Delivery and Translational Research*, **13** (2022) 966–982 <https://doi.org/10.1007/s13346-022-01253-z>.
- [9] Méndez, M.; Merayo, M. G., Núñez, M.: Machine learning algorithms to forecast air quality: A survey, *Artificial Intelligence Review*, **56** (2023) 10031–10066
- [10] Altamirano-Astorga, J.; Gutierrez-Garcia, J.O., Roman-Rangel, E.: Forecasting Indoor Air Quality in Mexico City Using Deep Learning Architectures, *Atmosphere (Basel)*, **15** (2024) 1529, <https://doi.org/10.3390/atmos15121529>.
- [11] Namdeti, R.: Artificial Intelligence in Chemical Engineering: Past, Present, and Future Perspectives, *Journal of Chemical Health Risks*, **13** (2023) 2051-2061, <https://doi.org/10.52783/jchr.v13.i6.2058>
- [12] Al Sharah, A.; Owida, H. A., Alnaimat, F., Hassan, M., Abuowaida, S., Alhaj, M., Sharadqeh, A.: Application of machine learning in chemical engineering: outlook and perspectives, *IAES International Journal of Artificial Intelligence*, **13** (2024) 619-630, <https://doi.org/10.11591/ijai.v13.i1>.
- [13] Ding, C.; Gui, X., Jiang, J.: Advancing chemical engineering technology with artificial intelligence, *Clean Energy*, **9** (2025) 55–74, <https://doi.org/10.1093/ce/zkaf036>
- [14] Chiang, L. H. T.; Braun, B., Wang, Z., Castillo, I.: Towards AI at Scale in the Chemical Industry, *AIChE Journal*, **68** (2022) <https://doi.org/10.1002/aic.17644>
- [15] He, C.; Zhang, C., Bian, T., Jiao, K., Su, W., Wu, K.-J., Su, A.: A Review on Artificial Intelligence Enabled Design, Synthesis, and Process Optimization of Chemical Products for Industry 4.0, *Processes*, **11** (2023) 330, <https://doi.org/10.3390/pr11020330>
- [16] Mafat, I. H.; Surya, D.V., Sharma, S.K., Rao, C.S.: Exploring Machine Learning Applications in Chemical Production through Valorization of Biomass, Plastics, and Petroleum Resources: A Comprehensive Review, *Journal of Analytical and Applied Pyrolysis*, **180** (2024), 106512, <https://doi.org/10.1016/j.jaap.2024.106512>
- [17] Selvakumar, P.; Preethi, C., Nehru, P., Saravanan, A., Das, A.: *AI in Green Chemistry Sustainable Manufacturing Processes*, IGI Global Scientific Publishing, ISBN 979-8-3693-7483-2, Hershey, PA, USA, (2025)

- [18] Carter, A.; Imtiaz, S.; Naterer, G.F.: Review of interpretable machine learning for process industries, *Process Safety and Environmental Protection*, **170** (2023) 647-659, <https://doi.org/10.1016/j.psep.2022.12.018>
- [19] Di Bonito, L.P.; Campanile, L., Di Natale, F., Mastroianni, M., Iacono, M., eXplainable Artificial Intelligence in Process Engineering: Promises, Facts, and Current Limitations, *Applied System Innovation*, **7** (2024), 121, <https://doi.org/10.3390/asi7060121>
- [20] Brereton, R.: *Chemometrics: Data Driven Extraction for Science*, John Wiley & Sons, Hoboken, NJ, USA, (2018), 121-181
- [21] Liang, H.; Jiang, K., Yan, T.-A., Chen, G.-H.: XGBoost: An Optimal Machine Learning Model with Just Structural Features to Discover MOF Adsorbents of Xe/Kr, *ACS Omega*, **6** (2021) 13, 9066-9074, <https://doi.org/10.1021/acsomega.1c00471>
- [22] Hochreiter, S.; Schmidhuber, J.: Long Short-Term Memory, *Neural Computation*, **9** (1997) 8, 1735-1780, <https://doi.org/10.1162/neco.1997.9.8.1735>
- [23] Ahn, J. M.; Kim, J., Kim, K.: Ensemble Machine Learning of Gradient Boosting (XGBoost, LightGBM, CatBoost) and Attention-Based CNN-LSTM for Harmful Algal Blooms Forecasting, *Toxins (Basel)*, **15** (2023) 10, 608, <https://doi.org/10.3390/toxins15100608>
- [24] Ujević Andrijić, Ž.; Rolich, T., Bolf, N.: Soft sensor development for the estimation of benzene content in catalytic reformat, *Industrial & engineering chemistry research*, **51** (2012) 3007-3014, <https://doi.org/10.1021/ie202362d>
- [25] Ujević Andrijić, Ž.; Herceg, S., Šimić, M., Bolf, N.: Intelligent Soft Sensors for Inferential Monitoring of Hydrodesulfurization Process Analyzers, *Actuators*, **14** (2025) 1-26, <https://doi.org/10.3390/act14080410>
- [26] Herceg, S.; Ujević Andrijić, Ž., Rimac, N., Bolf, N.: Development of mathematical models for industrial processes using dynamic neural networks, *Mathematics*, **11** (2023) 4518, <https://doi.org/10.3390/math11214518>
- [27] Ujević Andrijić, Ž.; Rimac, N.: Data-driven fouling detection in refinery preheat train heat exchangers using neural networks and gradient boosting, *Sensors*, **25** (2025) 4936, <https://doi.org/10.3390/s25164936>
- [28] Ujević Andrijić, Ž.; Bolf, N., Rimac, N., Brzović, A.: Fouling Detection in Industrial Heat Exchanger Using Number of Transfer Units Method, Neural Network, and Nonlinear Finite Impulse Response Models, *Heat Transfer Engineering*, **43** (2022) 1852-1866, <https://doi.org/10.1080/01457632.2021.2016149>
- [29] Gavran, M.; Andrijić, Ž.U., Bolf, N., Rimac, N., Sacher, J., Šahnić, D.: Development of a Calibration Model for Real-Time Solute Concentration Monitoring during Crystallization of Ceritinib Using Raman Spectroscopy and In-Line Process Microscopy, *Processes*, **11** (2023) 3439, <https://doi.org/10.3390/pr1133439>
- [30] Vrbanić, I.; Bolf, N., Budimir Sacher, J.: Data-Driven Prediction of Crystal Size Metrics Using LSTM Networks and In Situ Microscopy in Seeded Cooling Crystallization, *Processes*, **13** (2025) 1860, <https://doi.org/10.3390/pr13061860>

- [31] Vretenar, F.; Hartmann, H., Ujević Andrijić, Ž.: *In silico* ispitivanje nastajanja kokristala u farmaceutskom razvoju, Knjiga sažetaka - XVI. susret mladih kemijskih inženjera, Zagreb (2026).
- [32] Zanimović, V., Diplomski rad: Predviđanje koncentracija dušikovih oksida (NO_x) u zraku u gradu Zagrebu primjenom metoda strojnog učenja, Sveučilište u Zagrebu Fakultet kemijskog inženjerstva i tehnologije, 2025
- [33] Klonekay, P., Diplomski rad: Procjena indeksa kvalitete zraka za lebdeće čestice PM₁₀ i PM_{2,5} grada Zagreba primjenom metoda strojnog učenja, Sveučilište u Zagrebu Fakultet kemijskog inženjerstva i tehnologije, 2024.

Zahvala

Ova istraživanja i analiza provedeni su u okviru projekta *Digi-ChemEng-Lab* (112113), financiranog sredstvima NextGenerationEU fonda Europske unije iz izvora 581 – Mehanizam za oporavak i otpornost, u sklopu Programa financiranja javnih visokih učilišta i javnih znanstvenih instituta. Dio istraživanja rezultat je projekta *CrystAPC - Napredno vođenje procesa kristalizacije* sufinanciranog iz Europskog fonda za regionalni razvoj.

Primjena umjetne inteligencije u predviđanju i optimiranju sastava vodenih dvofaznih sustava za ekstrakciju enzima

Ana Jurinjak Tušek¹, Renata Vičević², Nera Bebek², Anita Šalić²,
Bruno Zelić^{2,3}

¹Sveučilište u Zagrebu Prehrambeno-biotehnološki fakultet, Pierottijeva ulica 6, 10000 Zagreb

²Sveučilište u Zagrebu Fakultet kemijskog inženjerstva i tehnologije, Trg Marka Marulića 19, 10000 Zagreb

³Sveučilište Sjever, Trg Žarka Dolinara 1, 48000 Koprivnica

Sažetak: Napredak u razvoju niskotemperaturnih eutektičkih otapala (engl. Deep Eutectic Solvent, DES) i njihovoj primjeni u vodenim dvofaznim sustavima (engl. Aqueous Two-Phase System, ATPS) otvorio je nova područja istraživanja u selektivnoj ekstrakciji biomolekula, osobito enzima. Zbog velikog broja mogućih kombinacija sastava, fizikalno-kemijskih svojstava i procesnih uvjeta, eksperimentalna optimizacija ATPS temeljenih na DES često je dugotrajna i zahtjevna za provedbu. U posljednje vrijeme se umjetna inteligencija (engl. Artificial Intelligence, AI) i napredni matematički modeli sve više koriste kao podrška razumijevanju i predviđanju ponašanja kompleksnih ekstrakcijskih sustava, uključujući ATPS. U ovom radu prikazani su razvoj i primjena suvremenih AI modela, uključujući strojno učenje, nelinearne regresijske modele i metode dubokog učenja, za predviđanje učinkovitosti ekstrakcije i očuvanja enzimske aktivnosti u DES nakon ekstrakcije. Pri tome je naglasak dan na potencijal AI-podržanog modeliranja u dizajnu selektivnih, održivih i ekonomičnih ekstrakcijskih sustava.

Ključne riječi: umjetna inteligencija, ATPS temeljen na DES, ekstrakcija enzima, strojno učenje

1. Uvod

Ekstrakcija je jedan od ključnih separacijskih procesa koji se temelji na potpunom ili djelomičnom odjeljivanju tvari iz smjese pomoću otapala. Provodi se na temelju različite topljivosti tvari u otapalima koja se međusobno ne miješaju. Prema agregatnom stanju faza, procesi ekstrakcije dijele se na ekstrakciju kapljevina-krutina, plin-kapljevina i kapljevina-kapljevina. Konvencionalne metode separacije ekstrakcijom kaplje-

vina-kapljevina imaju niz nedostataka kao što su velika potrošnja energije te upotreba organskih otapala koja mogu biti toksična, štetna za okoliš i nisu biorazgradiva [1].

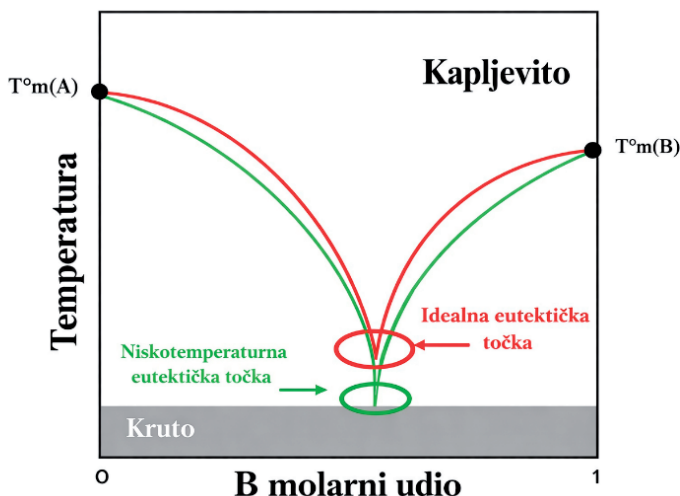
Kao potencijalno rješenje tih problema sve više se primjenjuju vodeni dvofazni sustavi (engl. *Aqueous Two-Phase System*, ATPS) koji nastaju miješanjem dviju kapljevine sličnih fizikalno-kemijskih svojstava koje zajedno ne tvore jednu homogenu fazu, već formiraju dvije kapljevite faze. Zbog tog svojstva, ATPS su jedan od primjera ekstrakcije kapljevina-kapljevina [2]. Za njihovo formiranje mogu se koristiti i zelena otapala poput niskotemperaturnih eutektičkih otapala (engl. *Deep Eutectic Solvent*, DES). Primjena ATPS-a u separacijskim procesima pokazala se opravdanom alternativom konvencionalnim metodama ekstrakcije zbog niže potrošnje energije tijekom provedbe procesa, manjih troškova, veće selektivnosti i njihove biorazgradivosti. Također, prilikom ekstrakcije prirodnih spojeva, kakvi su primjerice enzimi, potrebni su blagi separacijski uvjeti kako bi se spriječio gubitak njihove aktivnosti. ATPS se većinom sastoje od vode, polimera i soli te oponašaju prirodno stanično okruženje za enzime, što produljuje njihovu aktivnost [3].

1.1 Niskotemperaturna eutektička otapala

DES-ovi se definiraju kao eutektičke smjese Lewisovih i/ili Brønstedovih kiselina i baza koje mogu sadržavati različite anionske i/ili kationske vrste. Takve smjese karakterizira znatno niže talište u odnosu na pojedinačne komponente, a snižavanje tališta posljedica je snažnih međumolekulskih interakcija između početnih komponenti. U pravilu jedna komponenta djeluje kao donor protona (engl. *Hydrogen Bond Donor*, HBD), dok druga preuzima ulogu akceptora (engl. *Hydrogen Bond Acceptor*, HBA) [4, 5]. DES-ovi se najčešće dobivaju kompleksiranjem kvaterne amonijeve soli s metalnom soli ili donatorom vodikove veze [6]. U kontekstu zelenih otapala, ionske kapljevine i DES-ovi ubrajaju se među najperspektivnija zelena otapala. Iako dijele slična fizikalno-kemijska svojstva, poput niske hlapljivosti, povišene viskoznosti, dobre kemijske i toplinske stabilnosti te nezapaljivosti, DES-ovi se od ionskih kapljevine razlikuju po tome što nisu nužno u potpunosti ionske prirode te se mogu pripremiti i iz neionskih spojeva. Osim toga, u odnosu na ionske kapljevine, DES-ovi su često sigurniji za rukovanje, pokazuju bolju biorazgradivost te su ekonomski povoljniji za pripremu. Zbog navedenih svojstava, DES-ovi se danas koriste u širokom rasponu područja, uključujući elektrodepoziciju, sintezu nanomaterijala, biotransformaciju, sintezu lijekova i sustava za dostavu lijekova te ekstrakciju bioaktivnih spojeva [7].

Na faznom dijagramu (Slika 1) prikazana je ovisnost temperature tališta eutektičke smjese komponenata A i B o njihovu međusobnom omjeru, uz istodobni prikaz tališta pojedinačnih čistih komponenti. Dijagram jasno ilustrira karakteristično sniženje tališta u eutektičkoj točki u odnosu na tališta polaznih tvari, što je temeljno obilježje DES sustava. Ovo sniženje temperature tališta posljedica je snažnih međumole-

kulskih interakcija, ponajprije vodikovih veza između HBA i HBD, koje rezultiraju formiranjem guste, stabilizirane supramolekulske mreže. Takva mreža narušava kristalnu rešetku pojedinačnih komponenti i time značajno smanjuje temperaturu tališta smjese [8].



Slika 1: Fazni dijagram eutektičkog otapala koje se sastoji od dvije komponente

1.2 Enzim glukoza-dehidrogenaza

Enzim glukoza-dehidrogenaza (GDH) pripada skupini enzima oksidoreduktaza. Oksidoreduktaze su enzimi koji kataliziraju reakcije oksidacije i redukcije u metaboličkim procesima. Enzim GDH katalizira oksidaciju β -D-glukoze u D-glukono- δ -lakton (glukonolakton) uz istodobnu redukciju koenzima nikotinamid-adenin dinukleotida (fosfat) NAD(P)^+ u NAD(P)H pri čemu glukonolakton spontano hidrolizira u glukonsku kiselinu [9]. Enzim GDH je prisutan u raznim mikroorganizmima poput *Bacillus magaterium*, *Bacillus subtilis*, *Gluconobacter suboxydans*, *Halobacterium mediterraneus*, *Thermoplasma acidophilum*, *Sulfobus solfataricus* i *Haloferax mediterranei*. Ovisno o izvoru, enzim GDH se značajno razlikuje po svojim biokemijskim karakteristikama, odnosno prema specifičnoj aktivnosti i stabilnosti, ali i po afinitetu prema koenzimima NAD^+ i NADP^+ [10]. NAD^+ je ključni koenzim u enzimskim oksidoredukcijskim procesima, no njegova stabilnost u vodenim otopinama često predstavlja ograničenje u dugoročnim enzimskim primjenama. Istraživanjima je pokazano da DES-ovi značajno produžuju stabilnost NAD^+/NADH sustava, zadržavajući koenzim nepromijenjen tijekom više od 50 dana. Ova sposobnost DES-a da istovremeno posluži kao otapalo i stabilizacijski medij ukazuje na njegov potencijal u primjenama koje zahtijevaju trajnost enzimskih sustava, uključujući ekstrakciju bioaktivnih spojeva te regeneraciju koenzima [11].

1.3 Matematičko modeliranje u dizajnu DES-ova

Korištenjem statističkih i kemometrijskih metoda moguće je unaprijed predvidjeti fizikalno-kemijska svojstva DES-ova te njihovu kompatibilnost s ciljnim biomolekulama. U ranijim istraživanjima korištena je Spearmanova korelacijska matrica koja je omogućila identifikaciju odnosa između pH, viskoznosti, gustoće, molekularnih deskriptora DES-ova (σ -profili) i biokatalitičkih svojstava (aktivnost i stabilnost enzima formijat-dehidrogenaze (FDH), stabilnost NADH, topljivost CO₂) [12]. Rezultati dobiveni korištenjem korelacija omogućuju određivanje strukturnih obilježja DES-ova koja su povoljna za određenu reakciju, što smanjuje potrebu za eksperimentalnim istraživanjem i time štedi vrijeme i resurse. Modeli koji opisuju kvantitativni odnos strukture i aktivnosti (engl. *Quantitative Structure-Activity Relationship*, QSAR) i modeli koji opisuju kvantitativni odnos strukture i svojstava (engl. *Quantitative Structure-Property Relationship*, QSPR) temelje se na pretpostavci da se svojstva molekula (ili smjesa poput DES-ova) mogu predvidjeti na temelju njihovih strukturnih značajki izraženih pomoću različitih deskriptora [9]. Kao molekularni deskriptori najčešće se koriste σ -profilni deskriptori, snažni molekularni deskriptori koji potječu iz COSMO-RS (engl. *Conductor-like Screening Model for Real Solvents*). Oni opisuju raspodjelu naboja po molekularnoj površini, mapirajući koliko su polarna ili nepolarna različita područja molekule te kako mogu sudjelovati u elektrostatskim ili vodikovim vezama [13]. Ovi deskriptori mogu se ugraditi u prediktivne modele, a do sada je nekoliko metoda strojnog učenja uspješno primijenjeno na σ -profile:

- 1) **Linearna regresija** i njene ostale varijante poput operatora najmanjeg apsolutnog smanjenja i selekcije (engl. *Least Absolute Shrinkage and Selection Operator*, LASSO) i Ridge regresije. Kada se ti modeli primjenjuju na σ -profile, mogu se identificirati područja molekularne polarosti koja najsnažnije doprinose svojstvu od interesa [14].
- 2) **Metode temeljene na stablima odlučivanja tj. slučajnoj šumi** (engl. *Random Forest*, RF) imaju sposobnost modeliranja nelinearnih odnosa bez potrebe za opsežnim predprocesiranjima podataka zbog čega se često koriste u računalnoj kemiji. Kada se treniraju na σ -profilima, modeli mogu opisati složene obrasce interakcije između distribucija površinske polarosti i molekularnih svojstava [15].
- 3) **Neuronske mreže i duboko učenje**. Umjetne neuronske mreže (engl. *Artificial Neural Networks*, ANN) i arhitekture dubokog učenja pokazale su veliki potencijal u zadacima molekularnog modeliranja. Budući da su σ -profili kontinuirani i višedimenzionalni, služe kao izvrstan ulaz za neuronske modele [15, 16]. Konvolucijske neuronske mreže (engl. *Convolution Neural Networks*, CNN) mogu se prilagoditi za tretiranje σ -profila kao 1D "signala" raspodjele površinskog naboja [13, 17]. Rekurentne neuronske mreže (engl. *Recurrent Neural Networks*, RNN) i transformatori također se mogu koristiti kada su vremenski ili sekvencijalni odnosi između odjeljaka profila značajni [18].

- 4) **Metode jezgre** (engl. *Kernel methods*, KM) i **potpornih vektora** (engl. *Support Vector Machines*, SVM). Regresija potpornih vektora (engl. *Support Vector Regression*, SVR) s funkcijama jezgre može modelirati nelinearne ovisnosti između σ -profila i molekularnih svojstava [19]. Budući da σ -profili često kodiraju suptilne razlike u molekularnom polaritetu, metode jezgre su posebno učinkovite u razlikovanju malih varijacija u kemijskim skupovima podataka [20].
- 5) **Nenadzirano učenje** (engl. *Unsupervised Learning*, UL) i **smanjenje dimenzionalnosti** (engl. *Dimensionality Reduction*, DR). Metode smanjenja dimenzionalnosti poput analize glavnih komponenti (engl. *Principal Component Analysis*, PCA) ili autoenkodera često se primjenjuju za komprimiranje σ -profila u manji skup latentnih varijabli uz očuvanje većine varijance. Ove smanjene značajke zatim se mogu grupirati pomoću metoda poput k -srednjih vrijednosti (engl. *k-means*) ili hijerarhijskog grupiranja (engl. *Hierarchical Clustering*, HC) kako bi se grupirale molekule sa sličnim raspodjelama polariteta [21].

2. Materijali i metode

Radi razvoja integriranog eksperimentalno-računalnog sustava za optimiranje ekstrakcije enzima GDH u ATPS temeljenih na DES, najprije je provedena sveobuhvatna fizikalno-kemijska karakterizacija odabranih DES-ova. Na temelju dobivenih podataka izrađeni su kvantitativni modeli koji povezuju strukturne i empirijske deskriptore DES-ova s njihovim relevantnim svojstvima. Tako razvijeni modeli potom su korišteni za prediktivno određivanje optimalnih uvjeta ekstrakcije, uz istodobno očuvanje enzimске aktivnosti i stabilnosti u odabranom sustavu. Konačni cilj bio je uspostaviti integrirani okvir koji omogućuje razvoj korisnički orijentirane aplikacije za racionalan odabir DES-a i optimiranje uvjeta ekstrakcije.

2.1 Fizikalno-kemijska karakterizacija DES-ova

Provedena je fizikalno-kemijska karakterizacija svih pripremljenih DES-ova na način da je određena njihova gustoća (ρ), pH-vrijednost, polarnost (E_{NR}), dinamička viskoznost (η), aktivitet vode u DES-u (a_w) te boja (L^* , a^* , b^* , c , h). Sva mjerenja provedena su u tri ponavljanja.

2.2 Određivanje koncentracije proteina i praćenje aktivnosti enzima GDH

Za određivanje koncentracije proteina u uzorcima korištena je linearizirana Bradfordova metoda, koja se temelji na vezivanju kiseloplavog kopolimera Coomassie

Brilliant Blue G-250 (CBB G-250) s proteinskim amino skupinama u kiselom mediju, u kojem je boja prisutna u svom anionskom obliku. Boja selektivno reagira s aminokiselinskim ostacima, pri čemu najveći afinitet pokazuje prema argininu, ali može ostvariti interakcije i s tirozinom, histidinom, lizinom, triptofanom i fenilalaninom. Praćenje aktivnosti enzima GDH provedeno je spektrofotometrijski ($\lambda = 340$) na temelju reakcije oksidacije glukoze katalizirane enzimom GDH, pri čemu nastaju glukonolakton i NADH.

2.3. Provedba šaržne ekstrakcije enzima GDH primjenom ATPS temeljenih na DES

Za formiranje ATPS temeljenog na DES koristio se dikalijev hidrogenfosfat (K_2HPO_4) zbog svoje dobre topljivosti u vodi u visokim koncentracijama. Nakon provedene šaržne ekstrakcije u formiranom dvofaznom sustavu gornji sloj (ekstraktna faza, E) sadržavao je eutektičko otapalo s ekstrahiranim enzimom GDH, dok je donji sloj (rafinatna faza, R) sadržavao otopinu K_2HPO_4 sa zaostalim enzimom. Učinkovitost ekstrakcije enzima GDH (E_{GDH} , jednadžba 1) i koeficijent raspodjele (K_p , jednadžba 2) izračunati su na temelju volumena faza i koncentracije enzima u pojedinoj fazi.

$$E_{GDH} = \frac{\gamma_{P,E} V_E}{\gamma_{P,E} V_E + \gamma_{P,R} V_R} \cdot 100 \% \quad (1)$$

$$K_p = \frac{\gamma_{P,E}}{\gamma_{P,R}} \quad (2)$$

Pri tome su $\gamma_{P,E}$ masena koncentracija proteina u ekstraktnoj fazi (mg cm^{-3}), $\gamma_{P,R}$ masena koncentracija proteina u rafinatnoj fazi (mg cm^{-3}), V_E volumen ekstraktnje faze (cm^3) i V_R volumen rafinatne faze (cm^3).

Relativna aktivnost (R.A.) enzima u ekstraktnoj i rafinatnoj fazi izražena je kao omjer izmjerene aktivnosti u svakoj fazi i aktivnosti referentnog (kontrolnog) uzorka tj. aktivnosti izmjerene u $0,02 \text{ mol dm}^{-3}$ Tris-HCl puferu pH = 7,5.

2.4. Statistička analiza i matematičko modeliranje

Statistička analiza provedena je u programskom paketu Statistica 14.0, a korelacije između eksperimentalnih podataka analizirane su uz Spearmanove korelacijske matrice unutar navedenog programa. Svi spojevi korišteni za pripremu DES sustava geometrijski i energetski su optimirani pomoću programskog paketa BIOVIA TmoleX19 2021. Kvantno-kemijski proračuni provedeni su metodom teorije funkcionala gustoće (engl. *Density Functional Theory*, DFT). COSMO datoteka sadrži σ -profil krivulju koja kvan-

titativno prikazuje površinski naboj polarne molekule duž skale polariteta, a softver ju generira za svaku optimiranu molekulu. Pri tome su HBA karakterizirani vrhovima u području negativnog potencijala, HBD vrhovima u području pozitivnog potencijala, dok su nepolarne molekule karakterizirane vrhovima oko nultog potencijala.

Odnos između fizikalno-kemijskih svojstava DES sustava (kao što su pH, gustoća, viskoznost, polarnost, aktivitet i boja) te DES deskriptora, učinkovitosti ekstrakcije (E_{GDH}) i relativne aktivnosti enzima GDH (R.A.) modeliran je uz pretpostavku da se učinkovitost ekstrakcije i relativna aktivnost enzima GDH mogu izraziti kao funkcije fizikalno-kemijskih svojstava DES sustava i S_{mix}^i deskriptora [22]. Odnos fizikalno-kemijskih svojstava DES sustava prikazan je jednadžbom 3:

$$f(\text{pH}, \rho, \eta, E_{\text{NR}}, a_w, L^*, a^*, b^*, c, h, S_{\text{mix}}^1, S_{\text{mix}}^2, S_{\text{mix}}^3, S_{\text{mix}}^4, S_{\text{mix}}^5, S_{\text{mix}}^6, S_{\text{mix}}^7, S_{\text{mix}}^8, S_{\text{mix}}^9, S_{\text{mix}}^{10}) \quad (3)$$

Na temelju korelacijske matrice, odabrane su ulazne varijable koje pokazuju značajnu korelaciju s obje zavisne varijable, učinkovitošću ekstrakcije i relativnom aktivnošću enzima GDH. Odnosi između zavisnih i nezavisnih varijabli analizirani su primjenom ANN.

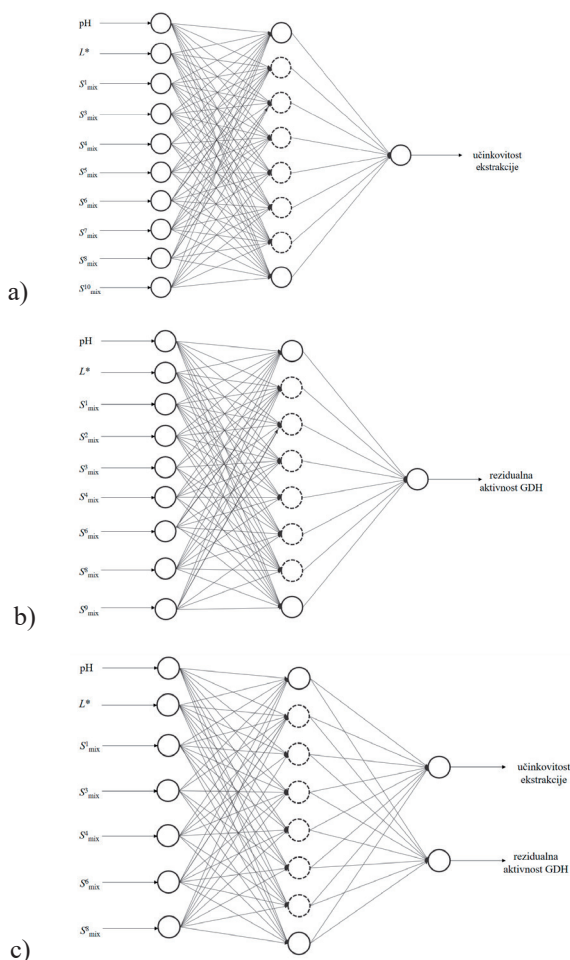
Pomoću programskog paketa Statistica 14.0 razvijene su višeslojne perceptronske (engl. *Multiple Layer Perceptron*, MLP) neuronske mreže. Arhitektura ANN uključivala je ulazni sloj s 10, 13 ili 14 neurona (odabrane su ulazne varijable značajne za odabranu izlaznu varijablu te za kombinaciju obiju izlaznih varijabli), skriveni sloj i izlazni sloj s dva neurona (za učinkovitost ekstrakcije i relativnu aktivnost enzima GDH). Shema MLP mreža koje su primijenjene prikazane su na Slici 2.

Za ANN modele odabrane su varijable koje su pokazale statistički značajnu korelaciju ($p < 0,05$) s učinkovitošću ekstrakcije i relativnom aktivnošću enzima GDH te su korištene kao ulazni neuroni u MLP mreži. Kako bi se osigurala robusnost modela, korištena je unakrsna validacija (engl. *cross-validation*) putem nasumičnog poduzorkovanja. Algoritam propagacije pogreške unatrag korišten je za treniranje ANN modela, osiguravajući pouzdano predviđanje i točnost predikcije. Primjenjivost razvijenih kalibracijskih modela ocijenjena je pomoću koeficijenta determinacije za kalibraciju (R_{kal}^2), prilagođenog koeficijenta determinacije za kalibraciju ($R_{\text{kal,adj}}^2$) i korijena srednje kvadratne pogreške za kalibraciju (engl. *Root Mean Square Error for Calibration*, RMSEC). Prediktivna sposobnost modela ocijenjena je pomoću koeficijenta determinacije za predikciju (R_{pred}^2), prilagođenog koeficijenta determinacije za predikciju ($R_{\text{pred,adj}}^2$), korijena srednje kvadratne pogreške za predikciju (engl. *Root Mean Square Error for Prediction*, RMSEP), standardne pogreške predviđanja (engl. *Standard Error of Prediction*, SEP), omjera predviđanja i odstupanja (engl. *Ratio of Prediction to Deviation*, RPD) te omjera raspona pogreške (engl. *Ratio of the Error Range*, RER) [23].

Utjecaj S_{mix}^i deskriptora na učinkovitost ekstrakcije i relativnu aktivnost enzima GDH modeliran je korištenjem polinomnog modela odzivne površine drugog reda prema jednadžbi 4:

$$E_{\text{GDH}} \text{ ili R. A.} = \beta_0 + \sum_{i=1}^{10} \beta_i \cdot (S_{\text{mix}}^i)_i + \sum_{i=1}^{10} \beta_{ii} \cdot (S_{\text{mix}}^i)_i^2 + \sum_{i=1}^9 \sum_{j=i+1}^{10} \beta_{ij} \cdot (S_{\text{mix}}^i)_i \cdot (S_{\text{mix}}^j)_j \quad (4)$$

gdje su odabrana izlazna varijabla, odnosno učinkovitost ekstrakcije ili relativna aktivnost enzima GDH, β_0 je slobodni član, a β_i , β_{ii} i β_{ij} su regresijski koeficijenti za linearne, kvadratne i interakcijske članove. Optimiranje je provedeno primjenom funkcije poželjnosti (engl. *desirability function*).



Slika 2: Shema MLP mreža primijenjenih za predviđanje učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH u ATPS temeljenih na DES, a) ANN model za predviđanje učinkovitosti ekstrakcije, b) ANN model za predviđanje relativne aktivnosti enzima GDH, c) ANN model za simultano predviđanje učinkovitosti ekstrakcije i relativne aktivnost enzima GDH

3. Rezultati i rasprava

Provedena je analiza korelacija između fizikalno-kemijskih svojstava DES sustava, DES deskriptora, učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH s ciljem razvoja prediktivnog modela za učinkovito predviđanje učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH. Rezultati su podijeljeni na analizu raspodjele podataka, razvoj modela umjetnih neuronskih mreža za predviđanje učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH te optimiranje i odabir DES-a na temelju funkcije poželjnosti.

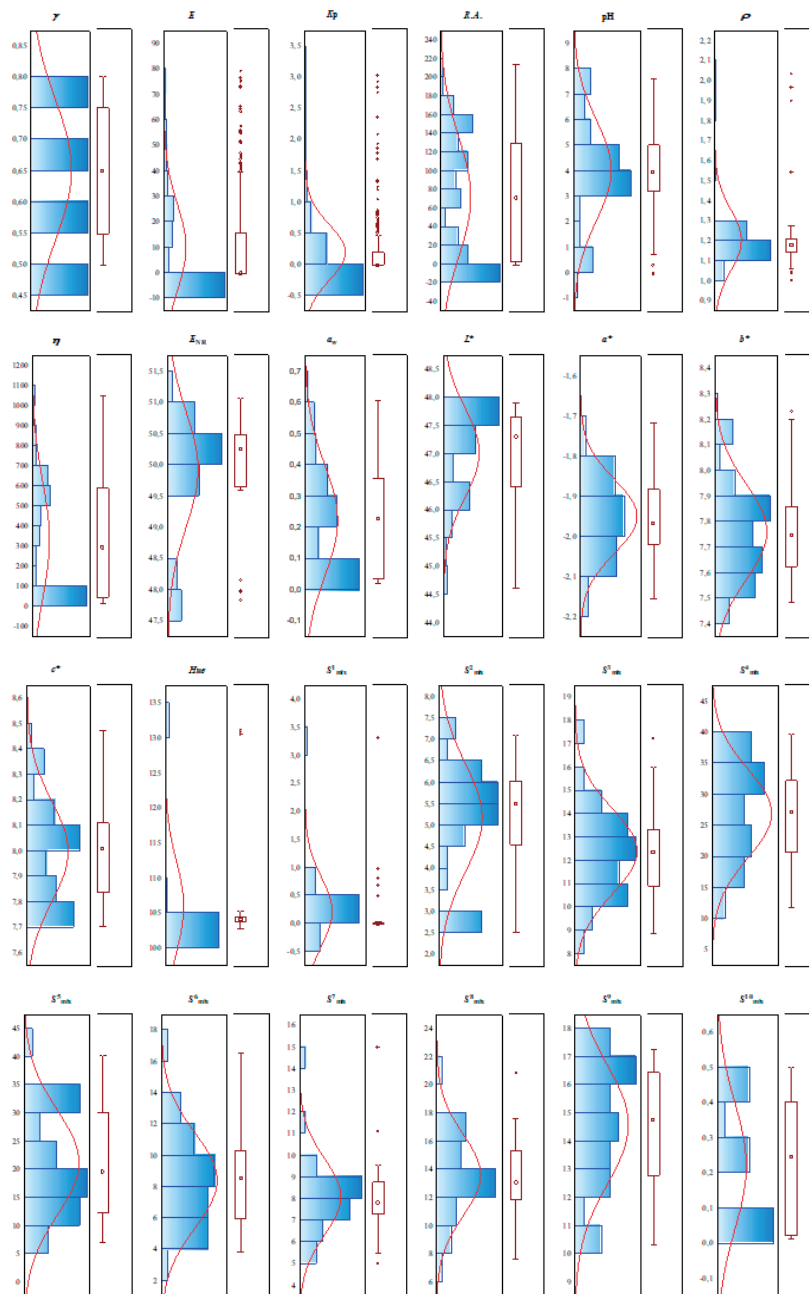
3.1. Analiza raspodjele podataka i korelacijska matrica

U prvom koraku analize podataka provedena je analiza raspodjele svih analiziranih varijabli, no u prikazanim rezultatima (Slika 3) vidljivo je da varijable ne prate normalnu raspodjelu pa je veza između σ -profila i fizikalno-kemijskih svojstva DES-ova analizirana primjenom Spearmanove korelacijske matrice. Ona se temelji na rangiranim vrijednostima i stoga obuhvaća monotone, nelinearne ovisnosti koje su uobičajene u složenim kemijskim sustavima, što je čini prikladnom za DES-ove, gdje jake mreže vodikovih veza, molekularni polaritet i strukturna heterogenost često rezultiraju nelinearnim trendovima između molekularnih deskriptora i svojstava mase.

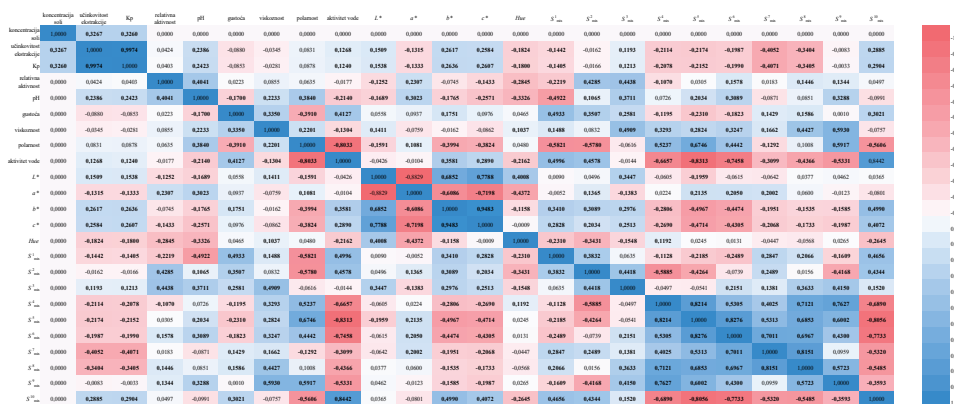
Prema rezultatima prikazanim na Slici 4, na učinkovitost ekstrakcije značajno utječu koncentracija soli u vodenom dvofaznom sustavu ($r = 0,3267$), pH ($r = 0,2386$), aktivitet vode ($r = -0,1268$), L^* koordinata boje ($r = 0,1509$), a^* koordinata boje ($r = -0,1315$), b^* koordinata boje ($r = 0,2617$), c^* koordinata boje ($r = 0,2584$), Hue koordinata boje ($r = -0,1824$), S^1_{mix} ($r = -0,1442$), S^3_{mix} ($r = 0,1193$), S^4_{mix} ($r = -0,2114$), S^5_{mix} ($r = -0,2174$), S^6_{mix} ($r = -0,1987$), S^7_{mix} ($r = -0,4052$), S^8_{mix} ($r = -0,3404$) i S^{10}_{mix} ($r = 0,2885$).

Prema rezultatima korelacijske analize na aktivnost enzima u vodenom dvofaznom sustavu s odabranim DES-ovima signifikantno utječe pH ($r = 0,4041$), L^* koordinata boje ($r = 0,1252$), a^* koordinata boje ($r = 0,2307$), c^* koordinata boje ($r = -0,1433$), Hue koordinata boje ($r = -0,2845$), S^1_{mix} ($r = -0,2219$), S^2_{mix} ($r = 4285$), S^3_{mix} ($r = 0,4438$), S^4_{mix} ($r = -0,1070$), S^6_{mix} ($r = 0,1578$), S^8_{mix} ($r = 0,1446$) i S^9_{mix} ($r = 0,1344$).

Vidljivo je da određeni σ -profili značajno utječu i na učinkovitost ekstrakcije enzima GDH i na njegovu aktivnosti u DES-u. Stoga su kao signifikantne varijable za razvoj modela u kojem su zavisne varijable učinkovitost ekstrakcije i aktivnost odabrani pH, L^* koordinata boje, S^1_{mix} , S^3_{mix} , S^4_{mix} , S^6_{mix} i S^8_{mix} s obzirom na to da pokazuju značajnu korelaciju i s relativnom aktivnošću i s učinkovitošću ekstrakcije enzima GDH.



Slika 3: Raspodjela podataka fizikalno-kemijskih svojstava DES sustava, DES deskriptora, učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH



Slika 4: Spearmanova korelacijska matrica odnosa između učinkovitosti ekstrakcije, relativne aktivnosti enzima GDH, fizikalno-kemijskih svojstava i molekulskih deskriptora DES-ova u vodenim dvofaznim sustavima. Korelacije označene podebljano statistički su značajne na razini $p < 0,05$

3.2. Modeli umjetnih neuronskih mreža za predviđanje učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH

U svrhu predviđanja učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH u ATPS temeljenih na DES razvijeni su ANN modeli. Arhitektura ANN koja je izabrana za predikciju učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH na temelju fizikalno-kemijskih svojstava DES-ova i DES molekularnih deskriptora prikazana je u Tablici 1, a prediktivna svojstva odabranih optimalnih ANN modela prikazana su u Tablici 2.

Razvijene su tri vrste ANN modela u kojima su za odabir optimalne mreže uzeti u obzir koeficijenti determinacije, pogreške učenja, testiranja i validacije te broj neurona u skrivenom sloju. Manji broj neurona u skrivenom sloju znači jednostavniju mrežu i stoga pouzdaniji model. Na temelju tih kriterija, odabrane su optimalne mreže, koje su označene podebljano u Tablici 1.

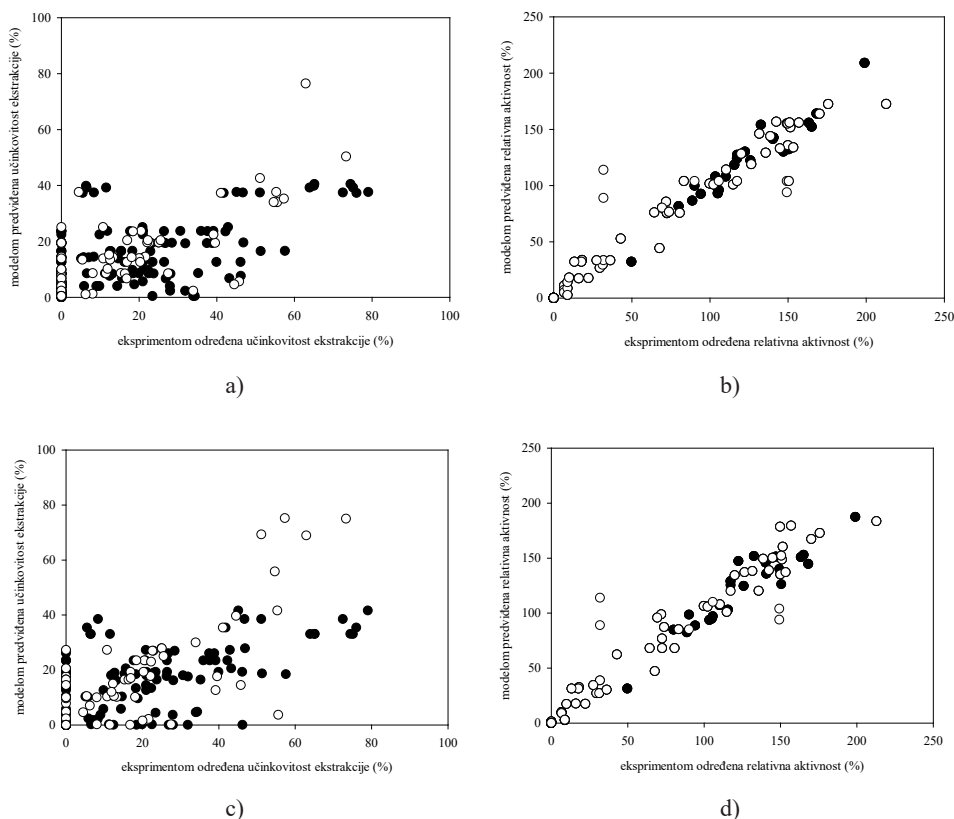
Usporedba eksperimentalnih i ANN modelima predviđenih učinkovitosti ekstrakcije i relativne aktivnosti enzima prikazana je grafički (Slika 5). Odnos između eksperimentalnih i matematičkim modelom predviđenih podataka analiziran je primjenom ključnih statističkih parametara: koeficijenta determinacije (R^2), omjera predviđanja i odstupanja (RPD) i omjera raspona pogreške (RER) (Tablica 2).

Tablica 1: Arhitektura umjetnih neuronskih mreža izabranih za predikciju učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH na temelju fizikalno-kemijskih svojstava DES-ova i DES molekularnih deskriptora

Izlazna varijabla	ANN model	$R^2_{\text{treniranje}}/$ RMSE _{treniranje}	$R^2_{\text{testiranje}}/$ RMSE _{testiranje}	$R^2_{\text{validacija}}/$ RMSE _{validacija}	Skrivena aktivacijska funkcija	Izlazna aktivacijska funkcija
Učinkovitost ekstrakcije	MLP 10-4-1	0,8126 72,3029	0,7392 77,6535	0,6009 117,7158	Tangens hiperbolni	Eksponecijalna funkcija
	MLP 10-12-1	0,7972 73,9895	0,7579 75,6252	0,6157 108,4585	Tangens hiperbolni	Eksponecijalna funkcija
	MLP 10-13-1	0,8121 76,8171	0,7870 84,9618	0,5505 119,3271	Funkcija identiteta	Eksponecijalna funkcija
	MLP 10-8-1	0,8446 67,4848	0,7473 74,2853	0,6233 112,7156	Logistička funkcija	Eksponecijalna funkcija
	MLP 10-8-1	0,7935 64,4851	0,7397 71,5705	0,6606 114,5802	Logistička funkcija	Eksponecijalna funkcija
Relativna aktivnost	MLP 9-13-1	0,9914 40,0279	0,9887 41,0307	0,9871 47,5497	Tangens hiperbolni	Eksponecijalna funkcija
	MLP 9-13-1	0,9906 37,3611	0,9894 44,0087	0,9860 51,2402	Eksponecijalna funkcija	Funkcija identiteta
	MLP 9-12-1	0,9927 31,2702	0,9912 34,3306	0,9889 40,7519	Tangens hiperbolni	Tangens hiperbolni
	MLP 9-6-1	0,9905 39,7888	0,9889 44,3481	0,9860 51,4748	Tangens hiperbolni	Logistička funkcija
	MLP 9-5-1	0,9930 24,9667	0,9929 33,1221	0,9893 39,2425	Tangens hiperbolni	Eksponecijalna funkcija
Učinkovitost ekstrakcije i relativna aktivnost	MLP 7-10-2	0,8797 125,9281	0,8402 142,1075	0,8294 176,4003	Tangens hiperbolni	Funkcija identiteta
	MLP 7-5-2	0,8892 126,2442	0,8541 150,6011	0,8288 188,7286	Logistička funkcija	Tangens hiperbolni
	MLP 7-11-2	0,8860 122,2001	0,8414 129,4710	0,8304 172,8911	Eksponecijalna funkcija	Logistička funkcija

S $R^2_{\text{pred}} > 0,75$ za predviđanje relativne aktivnosti modeli MLP 9-5-1 i MLP 7-11-2 pokazuju snažnu prediktivnu sposobnost, što ih čini pouzdanim alatom za predviđanje relativne aktivnosti enzima GDH u ATPS-ima temeljenim na DES-u. Osim toga, utvrđeno je da su spomenuti modeli izvrstan prediktivni alat na temelju RPD vrijednosti za relativnu aktivnost enzima GDH ($RPD > 2$). RPD vrijednost veća od 2

ukazuje na to da je model ne samo točan, već i vrlo prikladan za točna predviđanja u različitim eksperimentalnim uvjetima. To naglašava potencijal modela za optimiranje procesa ekstrakcije enzima bez potrebe za opsežnim eksperimentima pokušaja i pogreške. Na temelju RER vrijednosti, razvijeni ANN modeli (MLP 9-5-1 i MLP 7-11-2) mogu se koristiti za kontrolu kvalitete ($10 < \text{RER} < 15$) podataka relativne aktivnosti enzima GDH. S druge strane, razvijeni modeli nisu se pokazali dovoljno pouzdanima za predviđanje učinkovitosti ekstrakcije te zahtijevaju daljnja unapređenja. Dobiveni rezultati upućuju na potrebu odabira optimalnih DES-ova za svaki enzim zasebno.




Slika 5: Usporedba eksperimentalnih i ANN modelima predviđenih učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH, a) učinkovitost ekstrakcije prema modelu MLP 10-12-1, b) relativna aktivnost prema modelu MLP 9-5-1, c) učinkovitost ekstrakcije prema modelu MLP 7-11-2, d) relativna aktivnost prema modelu MLP 7-11-2 (• - kalibracija, o - predikcija)

Tablica 2: Prediktivna svojstva odabranih modela umjetnih neuronskih mreža za previđanje učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH

ANN model	Izlazna varijabla	R^2_{pred}	$R^2_{pred,adj}$	RMSEP	SEP	RPD	RER
MLP 10-12-1	Učinkovitost ekstrakcije	0,5394	0,4669	11,0444	0,8223	1,4719	5,6952
MLP 9-5-1	Relativna aktivnost	0,9327	0,9276	16,9099	1,3181	3,8207	12,5842
MLP 7-11-2	Učinkovitost ekstrakcije	0,6511	0,6245	10,2843	0,8550	1,6365	6,1161
	Učinkovitost ekstrakcije	0,9419	0,9375	15,6667	1,3626	4,1239	13,5228

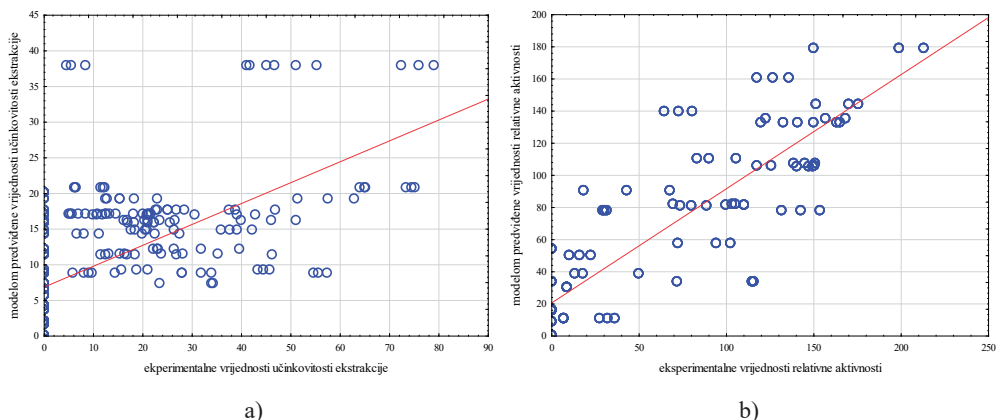
3.2. Optimiranje i odabir DES-a na temelju funkcije poželjnosti

Funkcija poželjnosti primijenjena je na model odzivne površine u svrhu odabira otapala koje će osigurati maksimume učinkovitosti ekstrakcije i relativne aktivnosti enzima GDH. Analiza je provedena primjenom Pareto dijagrama koji je prikazan na Slici 6. Usporedba eksperimentalnih i modelom odzivnih površina predviđenih vrijednosti učinkovitosti ekstrakcije i relativne aktivnosti prikazana je na Slici 7, analiza odstupanja modela odzivnih površina za predviđene vrijednosti učinkovitosti ekstrakcije i relativne aktivnosti prikazana je na Slici 8, dok su profili predviđenih vrijednosti i funkcije poželjnosti za učinkovitost ekstrakcije i relativnu aktivnost prikazani na Slici 9.

**Slika 6:** Pareto dijagram utjecaja izabranih nezavisnih varijabli na a) učinkovitost ekstrakcije i b) relativnu aktivnost. (L) predstavlja linearnu, a (Q) kvadratnu interakciju varijabli

Na Slici 6a vidljivo je da na učinkovitost ekstrakcije najveći utjecaj imaju S^1_{mix} , S^6_{mix} i S^8_{mix} u kvadratnom članu te S^1_{mix} u linearnom članu. Važno je napomenuti da je uočeno da S^1_{mix} i S^6_{mix} u kvadratnom članu imaju pozitivan utjecaj na učinkovitost

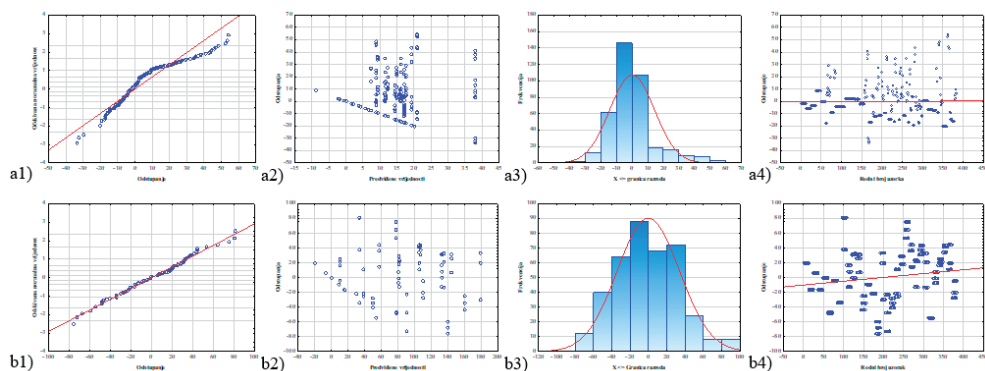
ekstrakcije, dok S_{mix}^8 u kvadratnom članu ima negativan utjecaj na učinkovitost ekstrakcije. Nadalje, na Slici 6b vidljivo je da S_{mix}^1 , S_{mix}^4 i S_{mix}^8 u linearnom članu te S_{mix}^8 u kvadratnom članu imaju najveći utjecaj na relativnu aktivnost enzima GHD.



Slika 7: Usporedba eksperimentalnih i modelom odzivnih površina predviđenih vrijednosti za a) učinkovitost ekstrakcije ($R^2 = 0,5929$) i b) relativnu aktivnost ($R^2 = 0,7103$)

Usporedba eksperimentalnih i modelom odzivnih površina predviđenih vrijednosti, učinkovitosti ekstrakcije (Slika 7a, $R^2 = 0,5929$) i relativne aktivnosti (Slika 7b, $R^2 = 0,7103$) ukazuje na značajno raspršenje podataka posebno u slučaju učinkovitosti ekstrakcije. Prema literaturi, model se može smatrati primjenjivim ako koeficijent determinacije koji opisuje razliku između eksperimentalnih vrijednosti i predviđenih vrijednosti modela prelazi 0,75 [24]. Na temelju toga razvijeni modeli odzivnih površina zahtijevaju poboljšanje, no osim visoke vrijednosti R^2 potrebno je analizirati i odstupanja kako bi znali da je model primjenjiv [25].

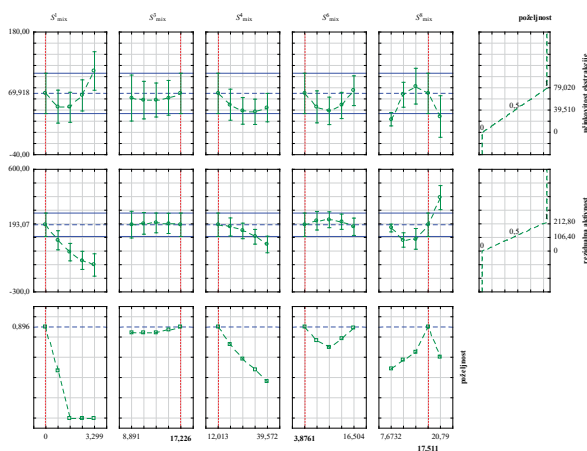
Odstupanja iz prilagođenog modela su razlike između opaženih odgovora i odgovarajućeg predviđanja odgovora izračunatog pomoću regresijske funkcije. Može se primijetiti da su za oba razvijena RSM modela odstupanja normalno distribuirana (Slike 8a1 i 8b1). Odstupanja su grupirana približno duž ravne linije i stoga je pretpostavka normalnosti zadovoljena. Histogrami koji prikazuju raspodjelu podataka također su potvrdili normalnu raspodjelu odstupanja (Slike 8a3 i 8b3). Prema navedenim slikama, dobiveni su tipični histogrami u obliku zvona s niskim nedostatkom simetrije. Slike 8a2 i 8b2 prikazuju odstupanja u odnosu na predviđene vrijednosti, a može se vidjeti da grafikonu ne pokazuju nikakav praktični obrazac, tj. odstupanja se ponašaju nasumično, što sugerira da modeli dobro odgovaraju eksperimentalnim podacima. Nadalje, Slike 8a4 i 8b4 prikazuju odstupanja u odnosu na redoslijed eksperimentalnih podataka kako bi se provjerilo može li redoslijed eksperimentalnih izvođenja utjecati na podatke. Primijećeno je da odstupanja variraju oko središnje vrijednosti bez očitih odstupanja.



Slika 8: Analiza odstupanja modela odzivnih površina za predviđene vrijednosti a) učinkovitosti ekstrakcije i b) relativne aktivnosti. 1) prikaz normalne raspodjele odstupanja, 2) odstupanja u odnosu na predviđene vrijednosti, 3) histogram odstupanja, 4) odstupanja u odnosu na redoslijed podataka

Optimiranje vrijednosti DES deskriptora za istovremeno postizanje maksimalne učinkovitosti ekstrakcije i relativne aktivnosti na temelju profila poželjnosti dobivenih iz modela odzivne površine provedeno je korištenjem funkcije poželjnosti (Slika 9). Skala poželjnosti je u rasponu od 0 (nepoželjno) do 1 (vrlo poželjno). Značajni σ -profili odabrani su na temelju funkcija poželjnosti, a njihove optimalne vrijednosti za postizanje maksimalne relativne aktivnosti i učinkovitosti ekstrakcije su sljedeće: $S^1_{\text{mix}} = 0$, $S^3_{\text{mix}} = 17,226$, $S^4_{\text{mix}} = 12,013$, $S^6_{\text{mix}} = 3,876$ i $S^8_{\text{mix}} = 17,511$.

Pretragom interne baze σ -profila odabrana su eutektička otapala s najbližim vrijednostima te su prikazana u Tablici 3. Također, prikazani su i dobiveni rezultati nakon provedene šaržne ekstrakcije i mjerenja aktivnosti enzima u navedenim sustavima. Na temelju dobivenih rezultata kao optimalni DES odabran je ChCl:U (1:2, 20% H₂O (w/w).



Slika 9: Profili predviđenih vrijednosti i funkcije poželjnosti za učinkovitost ekstrakcije i relativnu aktivnost

Tablica 3: Rezultati šaržne ekstrakcije enzima GDH i relativne aktivnosti primjenom ATPS temeljenih na optimalnim DES-ovima

DES	$\gamma_{K_2HPO_4}$ (mg cm ⁻³)	K_p (-)	R (-)	E_{GDH} (%)	R.A.
ChCl:U:Gly (1:2:2, 20% H ₂ O (w/w))	0,5	nema razdvajanja faza			133,92 ± 10,42
	0,6				
	0,7				
	0,8				
ChCl:U:Gly (1:2:2, 30% H ₂ O (w/w))	0,5	nema razdvajanja faza			132,35 ± 12,80
	0,6				
	0,7				
	0,8				
ChCl:U (1:2, 20% H ₂ O (w/w))	0,5	nema razdvajanja faza			153,62 ± 9,31
	0,6				
	0,7	0,86	0,37 ± 0,01	24,11 ± 2,01	
	0,8	0,71	0,20 ± 0,01	9,86 ± 3,02	
ChCl:U (1:2, 30% H ₂ O (w/w))	0,5	nema razdvajanja faza			143,51 ± 9,23
	0,6				
	0,7				
	0,8	0,5	0,15 ± 0,001	6,70 ± 2,21	
ChCl:U (1:2, 20% H ₂ O (w/w))	0,5	nema razdvajanja faza			126,85 ± 9,44
	0,6				
	0,7				
	0,8	0,86	0,48 ± 0,02	29,23 ± 2,82	

4. Zaključak

U radu je razvijen sustavan i prediktivan pristup dizajnu ATPS temeljenih na DES za ekstrakciju enzima GDH. Umjesto tradicionalne metode pokušaja i pogreške, korištena je metodologija temeljena na racionalnom odabiru DES formulacija prema poznatim fizikalno-kemijskim svojstvima te je dodatno podržana računalnim modeliranjem i optimiranjem. Primjena Spearmanove korelacijske analize omogućava odabir relevantnih ulaznih varijabli za razvoj robusnih prediktivnih modela. Uspješnim odabirom sedam zajedničkih ulaznih varijabli (pH, L^* , S^1_{mix} , S^3_{mix} , S^4_{mix} , S^6_{mix} , S^8_{mix}), koje su se pokazale značajno koreliranim i s učinkovitošću ekstrakcije i s relativnom aktivnošću enzima GDH, osigurana je robusnost razvijenih modela i smanjen rizik od prekomjernog prilagođavanja. Razvijeni ANN modeli postigli su visoke RPD vrijednosti (> 2) i RER vrijednosti pogodne za kontrolu učinkovitosti ekstrakcije i relativne aktivnosti na temelju odabranih ulaznih varijabli modela (pH, L^* , S^1_{mix} , S^3_{mix} ,

S_{mix}^4 , S_{mix}^6 , S_{mix}^8). Funkcijom poželjnosti utvrđeni su optimalni σ -profili za postizanje maksimalne relativne aktivnosti i učinkovitosti ekstrakcije: $S_{\text{mix}}^1 = 0$, $S_{\text{mix}}^3 = 17,226$, $S_{\text{mix}}^4 = 12,013$, $S_{\text{mix}}^6 = 3,876$ i $S_{\text{mix}}^8 = 17,511$.

Zahvala

Rad je izrađen u okviru projekta "Integrirani mikrosustav za enzimatsku proizvodnju biovodika (MicroBioH₂)" financiranog od Hrvatske zaklade za znanost (IP-2022-10-2175).

5. Literatura

- [1] Hong Geow, C.; Ching Tan, M., Pin Yeap, S., Ling Chin, N.: A review on extraction techniques and its future applications in industry, *European Journal of Lipid Science and Technology*, **123** (2021) 2000302, <https://doi.org/10.1002/ejlt.202000302>
- [2] Yang, A. H.: Aqueous Two-Phase Extraction Advances for Bioseparation, *Journal of Bioprocessing & Biotechniques*, **4** (2013) 1, <https://doi.org/10.4172/2155-9821.1000140>
- [3] Ura, T.; Yoshida, T., Mikawa, T., Shiraki, K.: Polymer-engineered condensates for enzyme activation, *Polymer Journal*, **57** (2025) 885-896, <https://doi.org/10.1038/s41428-025-01042-8>
- [4] Ijardar, S. P.; Singh, V., Gardas, R. L.: Revisiting the Physicochemical Properties and Applications of Deep Eutectic Solvents, *Molecules*, **27** (2022) 1368, <https://doi.org/10.3390/molecules27041368>
- [5] Aktaş, H.; Kurek, M. A.: Deep eutectic solvents for the extraction of polyphenols from food plants, *Food Chemistry*, **444** (2024) 138629, <https://doi.org/10.1016/j.foodchem.2024.138629>
- [6] Smith, E. L.; Abbott, A. P., Ryder, K. S.: Deep eutectic solvents (DESs) and their applications, *Chemical Reviews*, **114** (2014) 11060-11082, <https://doi.org/10.1021/cr300162p>
- [7] Ling, J. K. U.; Hadinoto, K.: Deep Eutectic Solvent as Green Solvent in Extraction of Biological Macromolecules: A Review, *International Journal of Molecular Sciences*, **23** (2022) 3381, <https://doi.org/10.3390/ijms23063381>
- [8] Mani, K. A.; Kumar, L., Barrios, N., Agate, S., Mittal, A., Yarbrough, J., Jameel, H., Lucia, L. A., Pal, L.: Emergence of deep eutectic solvents (DES): Chemistry, preparation, properties, and applications in biorefineries and critical materials, *Progress in Materials Science*, **157** (2026) 101586, <https://doi.org/10.1016/j.pmatsci.2025.101586>.
- [9] Li, J.; Zhao, T., Yang, Q., Du, S., Xu, L.: A review of quantitative structure-activity relationship: The development and current status of data sets, molecular descriptors and mathematical models, *Chemometrics and Intelligent Laboratory Systems*, **256** (2025) 105278, <https://doi.org/10.1016/j.chemolab.2024.105278>
- [10] Pongtharangkul, T.; Chuekitumchorn, P., Suwanampa, N., Payongsri, P., Honda, K., Panbangred, W.: Kinetic properties and stability of glucose dehydrogenase from *Bacillus amylo-*

- liquefaciens* SB5 and its potential for cofactor regeneration, *AMB Express*, **5** (2015) 68, <https://doi.org/10.1186/s13568-015-0157-9>
- [11] Radović, M.; Hok, L., Panić, M., Cvjetko Bubalo, M., Vianello, R., Viković, M., Radojčić Redovniković, I.: Deep eutectic solvents as a stabilising medium for NAD coenzyme: unravelling the mechanism behind coenzyme stabilisation effect, *Green Chemistry*, **24** (2022) 7661-7674, <https://doi.org/10.1039/D2GC02656B>
- [12] Logarušić, M.; Šubar, K., Nikolić, M., Jurinjak Tušek, A., Damjanović, A., Radović, M., Radojčić Redovniković, I., Žnidaršič-Plazl, P., Kroutil, W., Cvjetko Bubalo, M.: Harnessing the potential of deep eutectic solvents in biocatalysis: design strategies using CO₂ to formate reduction as a case study, *Frontiers in Chemistry*, **12** (2024) 1467810, <https://doi.org/10.3389/fchem.2024.1467810>
- [13] Abranches, D. O.; Maginn, E. J., Colón, Y. J.: Boosting Graph Neural Networks with molecular mechanics: A case study of sigma profile prediction, *Journal of Chemical Theory and Computation*, **19** (2023) 9318-9328, <https://doi.org/10.1021/acs.jctc.3c00871>
- [14] Sharma, A.; Garg, A., Li, L., Chatterjee, I., Lee, B.-S., Garg, A.: Machine learning for deep eutectic solvents: advances in property prediction and molecular design, *Journal of Molecular Liquids*, **437** (2025) 128317, <https://doi.org/10.1021/acs.jctc.3c01003>
- [15] Wang, Y.-X.; Hou, X.-J., Zeng, J., Wu, K.-J., He, Y.: Random forest models to predict the densities and surface tensions of deep eutectic solvents, *AIChE Journal*, **69** (2023) e18095, <https://doi.org/10.1002/aic.18095>
- [16] Radović, M.; Jurinjak Tušek, A., Reiter, T., Kroutil, W., Cvjetko Bubalo, M., Radojčić Redovniković, I.: Rational design of deep eutectic solvents for the stabilization of dehydrogenases: an artificial neural network prediction approach, *Frontiers in Chemistry*, **12** (2024) 1436049, <https://doi.org/10.3389/fchem.2024.1436049>
- [17] Abranches, D. O.; Maginn, E. J., Colón, Y. J.: Stochastic machine learning via sigma profiles to build a digital chemical space, *Proceedings of the National Academy of Sciences of the United States of America*, **121** (2024) e2404676121, <https://doi.org/10.1073/pnas.2404676121>
- [18] Segler, M. H. S.; Kogej, T., Tyrchan, C., Waller, M. P.: Generating focused molecule libraries for drug discovery with Recurrent Neural Networks, *ACS Central Science*, **4** (2018) 120-131, <https://doi.org/10.1021/acscentsci.7b00512>
- [19] Nordness, O.; Kelkar, P., Lyu, Y., Baldea, M., Stadtherr, M. A., Brennecke, J. F.: Predicting thermophysical properties of dialkylimidazolium ionic liquids from sigma profiles, *Journal of Molecular Liquids*, **334** (2021) 116019, <https://doi.org/10.1016/j.molliq.2021.116019>
- [20] Scherer, C.; Scheid, R., Andrienko, D., Bureau, T.: Kernel-based machine learning for efficient simulations of molecular liquids, *Journal of Chemical Theory and Computation*, **16** (2020) 3194-3204, <https://doi.org/10.1021/acs.jctc.9b01256>
- [21] Schmidt, S.; Schindler, M., Eriksson, L.: Block-wise exploration of molecular descriptors with Multi-block Orthogonal Component Analysis (MOCA), *Molecular Informatics*, **41** (2022) 2100165, <https://doi.org/10.1002/minf.202100165>
- [22] Bekavac, N.; Radović, M., Jurinjak Tušek, A., Cvjetko Bubalo, M., Zelić, B., Šalić, A.: Smart design of deep eutectic solvent-based aqueous two-phase systems for efficient lipa-

- se extraction, *Chemical Engineering Journal*, **521** (2025) 166384, <https://doi.org/10.1016/j.cej.2025.166384>
- [23] Fearn, T.: Assessing calibrations: SEP, RPD, RER and R2, *NIR News*, **13** (2002) 12-13, <https://doi.org/10.1255/nirn.689>
- [24] Le Man, H.; Behera, S. K., Park, H. S.: Optimization of operational parameters for ethanol production from Korean food waste leachate, *International Journal of Environmental Science and Technology*, **7** (2010) 157-164, <https://doi.org/10.1007/BF03326124>
- [25] Matešić, N.; Jurina, T., Benković, M., Panić, M., Valinger, D., Gajdoš Kljusurić, J., Jurinjak Tušek, A.: Microwave-assisted extraction of phenolic compounds from *Cannabis sativa* L.: optimization and kinetics study, *Separation Science and Technology*, **56** (2021) 2047-2060, <https://doi.org/10.1080/01496395.2020.1804938>

Umjetna inteligencija, dubinsko učenje i kauzalnost u znanosti o materijalima

Želimir Kurtanjek¹

¹Sveučilište u Zagrebu Prehrambeno-biotehnološki fakultet, Pierottijeva 6, 10000 Zagreb
zelimir.kurtanjek@gmail.com

Sažetak: Predstavljene su primjene kauzalne umjetne inteligencije (AI) za dizajn i otkrivanje novih materijala. Pristup je utemeljen na umjetnoj inteligenciji i spajanju velikih skupova podataka s algoritmima sposobnim za predviđanje i otkrivanje uzročnih odnosa između atomskih i molekularnih svojstava te makroskopskih značajki materijala. Naglasak je stavljen na funkcionalno povezivanje atomskih svojstava i strukturnih podataka s grafičkim neuronskim mrežama (GNN) i otkrivanje služenih uzročnih veza. Zbog nelinearnih funkcionalnih ovisnosti između strukturnih i materijalnih svojstava, podaci se analiziraju u Hilbertovom prostoru reproducirajućih jezgri (RKHS). Sinteza uzročnih ovisnosti prikazana je putem usmjerenih acikličkih grafova (engl. Directed Acyclic Graphs, DAG), koji olakšavaju analizu kroz tri temeljne razine hijerarhije uzročnog zaključivanja: predikciju, intervenciju i protu činjenično zaključivanje. Posebno su prikazani rezultati dizajna molekula i supravodiča.

Cljučne riječi: kauzalnost, Bayesova mreža, supravodljivost, metalno-organski okviri (MOF), polimeri

1. Uvod

Primjena umjetne inteligencije (AI), strojnog učenja (ML) i dubokog učenja (DL) u znanosti o materijalima prešla je put od nišnog eksperimentalnog alata do okosnice onoga što mnogi istraživači nazivaju "Drugom računalnom revolucijom". Do 2026. godine područje je nadraslo jednostavno predviđanje svojstava i usmjerilo se prema autonomnom otkrivanju i inverznom dizajnu, gdje modeli ne daju samo predikciju svojstva materijala, već dizajniraju specifičnu atomsku strukturu potrebnu za postizanje zadanog cilja. Ovaj pomak udaljava područje od tradicionalnih, intuitivno vođenih metoda pokušaja i pogrešaka prema podatkovno orijentiranoj paradigmi koja obećava dramatično ubrzanje otkrića i razvoja. Iskorištavanjem moćnih algoritama i

rastućih skupova podataka, istraživači sada mogu predviđati svojstva materijala, otkrivati nove spojeve i optimizirati procese sinteze s dosad neviđenom učinkovitošću.

Tradicionalni izazov

Otkrivanje novih materijala (npr. supravodiča, metalo-organskih okvira MOF-va, lijekova, baterije, legura) tradicionalno zahtijeva godine eksperimenata metodom pokušaja i pogrešaka te skupe simulacije.

Doprinos ML/DL-a

- Modeli za predviđanje svojstava
- Algoritmi predviđaju širinu zabranjene zone (engl. *bandgap*), elastičnost, vodljivost, tvrdoću, toplinsku stabilnost itd.
- Visoko-propusno pretraživanje (engl. *high-throughput screening*)
- ML zamjenjuje skupe izračune teorije funkcionala gustoće (DFT) radi brže evaluacije.
- Inverzni dizajn materijala
- Umjesto predviđanja svojstava iz sastava, modeli generiraju kandidate materijala s ciljanim svojstvima.

Uobičajene metode


- Slučajnim stablima odlučivanja (engl. *Random Forest*)
- Modeli s potpornim vektorima (SVM)
- Modeli temeljem gradijenata (engl. *Gradient Boosting*)
- Grafičke neuronske mreže (GNN)
- Varijacijski autoenkoderi (VAE)

Metode kauzalnog modeliranja

- Modeli statističkog zaključivanja (uvjetovane nezavisnosti)
- Modeli optimalne predikcije BIC kriterijem
- Modeli kontinuiranog optimiranja kauzalne DAG mreže

2. AI modeli molekula i materijali

Najvažniji doprinos umjetne inteligencije dubokim učenjem je modeliranje molekula u latentnom prostoru varijabli otkrivenih učenjem iz velikog broja podataka. To je bitna razlika od uobičajenih modela utemeljenim na molekularnim deskriptorima i otiscima. Velika važnost je u bitnoj razlici prirode između unaprijed određenih prediktora (deskriptora, otisaka) i prediktora iz latentnih prostora otkrivenih u procesu učenja. Varijable iz latentnih prostora otkrivaju se prijenosom utjecaja (poruke) u višeslojnoj strukturi neuronskih mreža MPNN (engl. *Message Passing Neural Network*) što je prikazano na Slici 1. Svaka molekula je graf nosilac informacija: atomarnih, kemijskih veza, i strukture matricom susjedstva (engl. *adjacency matrix*).




Slika 1: Algoritam MPNN dubinskog učenja modela molekule algoritmom prijenosa poruka višeslojnim neuronskim mrežama. M, U, i R su neuronske mreže modela zavisnosti latentnih varijabli h i varijabli m utjecaja (poruka)

Otkrivanje kauzalnih odnosa između latentnih varijabli je najvažniji korak za dizajn molekula. Kauzalni odnosi prikazuju se kao usmjereni grafovi (engl. *Directed Acyclic Graph*, DAG) Bayesove kauzalne mreže. Kauzalni modeli određuju sve tri razine znanja o materijalima: 1) razina predikcije svojstva materijala, 2) određuje posljedice na svojstva materijala intervencijom na sastav i pripremu, 3) inovacije novih materijala protučinjeničnim zaključivanjem (engl. *counterfactual inference*) [1].

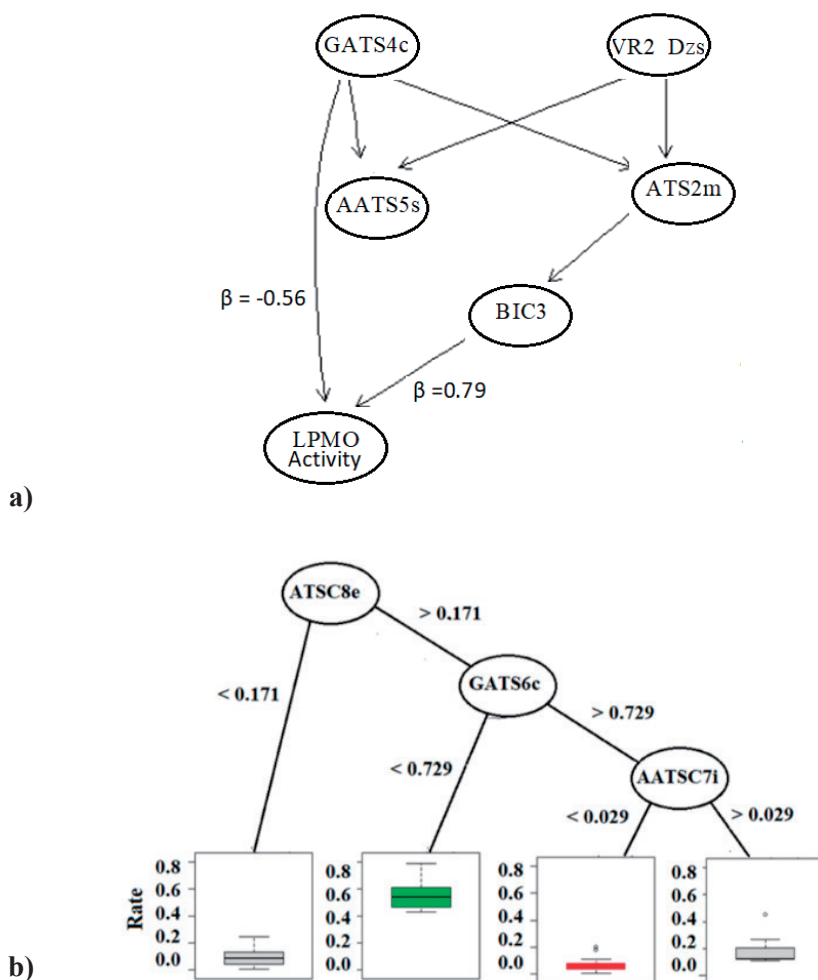
3. Rezultati

Kao primjer AI u modeliranju molekula provedena je usporedba strojnog učenja molekulskim prediktorima, strukturnim molekularnim cirkularnim Morganovim otiscima i dubokom neuronskom MPNN mrežom. Razvijeni su modeli topljivosti 1270 organskih molekula iz ESOL baze podataka. Koeficijenti determinacije za MPNN, deskriptore i molekulске otiske su $R^2 = 92,82, 91,93$ i $74,52$ %. Na Slici 2 prikazani su eksperimentalni podaci i predikcije MPNN modelom. Prednost MPNN modela se ističe usporedbom pogreške s podacima za testiranje (nove molekule): RMSE = 1,933, 2,051 i 2,573.



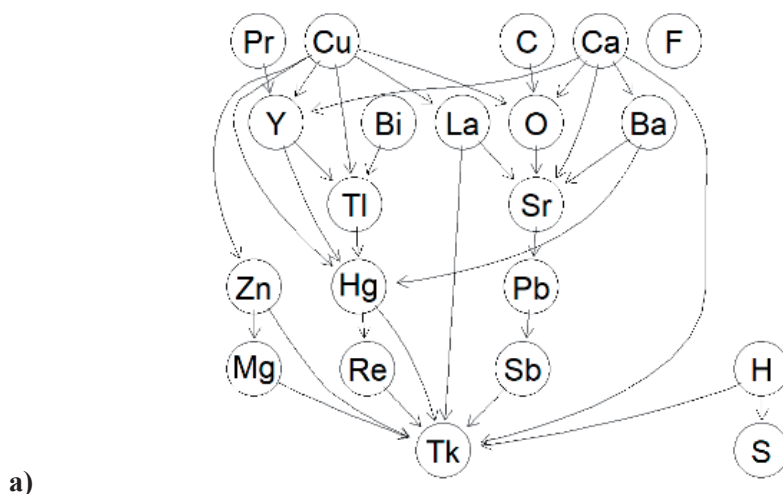
Slika 2: Usporedba predikcije topljivosti (standardne vrijednosti) malih organskih molekula modelom duboke neuronske mreže MPNN

Značajna prednost modeliranjem dubinskim učenjem MPNN je značajna za baze s velikim brojem podataka s brojem molekula većim od 10.000. Najvažnija primjena modeliranja dubinskim učenjem je u određivanju kauzalnih veza između prediktora iz prostora latentnih varijabli i fizikalno-kemijskih značajki materijala [1-4]. Na primjer, ovdje su prikazani rezultati modeliranja Bayes-ove kauzalne mreže molekularskih deskriptora enzima polisaharidne monooksigenaze (LPMO) koji ima bitnu primjenu u razvoju tehnologija za proizvodnju biogoriva i zaštiti okoliša. Kauzalni usmjereni aciklički graf (DAG) LPMO rezidualne aktivnosti prikazan je na Slici 3a, a stablo odlučivanja za predikciju aktivnosti u procesima razgradnje tekstilnih boja na Slici 3b.




Slika 3: a) Bayes-ova kauzalna mreža molekularnih deskriptora prediktivnosti LPMO enzima; b) stablo odlučivanja molekularnih deskriptora za predikciju LPMO aktivnosti u procesu razgradnje boje tekstilne otpadne vode

Oba istraživanja potvrđuju da najvažniji direktni inhibirajući kauzalni učinak ima 2D topološki auto korelacijski Geary koeficijent GATS određen cjelokupnim grafom LPMO molekule. Srednja vrijednost GATS kauzalnog učinka Average Causal Effects je $ACE = -0,56$. Linearnom regresijom određen je najveći pozitivan neposredni kauzalni učinak BIC deskriptora koji je određen entropijom populacije kemijskih veza LPMO molekule. Isti postupak određivanja Bayesove kauzalne mreže primijenjen je za analizu supravodljivosti 21.263 uzoraka materijala dostupnih u UCI bazi podataka. Kauzalna povezanost kemijskog sastava prikazana je na Slici 4a. Postignuta je visoka točnost predikcije kritične temperature T_k prelaska električne vodljivosti u područje supravodljivosti, koeficijent determinacije $R^2 = 93\%$ (Slika 4b).




a)



b)

Slika 4: a) Bayes-ova kauzalna mreža učinaka pojedinih kemijskih elemenata na kritičnu temperaturu T_k supravodljivih materijala; b) usporedba kritične temperature T_k i predikcije modelom Bayesove mreže, podaci za učenje su označeni crnom bojom, predikcije test podacima (novim) su označene crveno



Slika 5: Prikazi prosječnih kauzalnih učinaka na kritičnu temperaturu T_k supravodljivih materijala: A) standardna devijacija gustoće, B) geometrijska težinska srednja vrijednost elektronske aktivnosti; C) geometrijska težinska srednja vrijednost valencije

Neposredni kauzalni učinci na kritičnu temperaturu supravodljivosti materijala određeni su analizom doprinosa pojedinih atomskih značajki korelacijskom analizom podataka u Hilbertovom prostoru. Prve tri najvažnije značajke su: 1) standardna devijacija atomskih gustoća materijala, 2) geometrijske težinske srednje vrijednosti elektronskog afiniteta, 3) geometrijska težinske srednje vrijednosti atomarnih valencija. Redukcijom s 51 dimenzionalnog prostora statističkih značajki na 3 dimenzionalni prostor ključnih kauzalnih varijabli koeficijent determinacije je s 93 % sveden na 90 %. Funkcionalna zavisnost kritične temperature tranzicije supravodljivosti o neposrednim kauzalnim varijablama je nelinearna. Primijenjen je model Bayesove MLP neuronske mreže za modeliranje zavisnosti gustoće vjerojatnosti $P(T_k | x)$. Rezultati prikazani na Slici 5 pokazuju nelinearnost, raspršenje intervala pouzdanosti predikcije T_k i uske intervale optimalnih vrijednosti elektronske aktivnosti i valencije. Razvijeni kauzalni model supravodljivih materijala omogućuje racionalno modelom potpomognuto eksperimentalno istraživanje novih supravodljivih materijala.

4. Diskusija

Opisani primjeri vlastitog istraživanja primjene umjetne inteligencije modeliranja molekule, Bayesove kauzalne mreže za primjenu LPMO enzima u zaštiti okoliša i razvoj novih supravodljivih materijala, pokazuju velike mogućnosti integracijom inženjerskog znanja i algoritamskog otkrivanja zakonitosti određivanjem uzoraka ponašanja u skupovima velikog broja podataka.

Temelji budućih smjerova metodologija zaključivanja:

- Razvoj kvantnih modela za materijale;
- Multimodalno učenje (struktura + tekst + slike);
- Aktivno učenje primjenom robotiziranih laboratorija;
- Objašnjiva umjetna inteligencija za zaključivanje o svojstvima materijala;
- Integracija sa simulacijama kvantnog računarstva.

5. Zaključak

Strojno učenje i duboko učenje revolucioniraju znanost o materijalima bitnim za razvoj održivih tehnologija, nove izvore energije, zaštitu okoliša, i razvoj novih lijekova. Osnovne značajke umjetne inteligencije u znanosti o materijalima su:

- Ubrzavanje otkrića;
- Smanjenje troškova;
- Omogućavanje inverznog dizajna;
- Automatizacija karakterizacije;
- Pokretanje autonomnih laboratorija.

Umjetna inteligencija mijenja temelje znanosti o materijalima od empirijskog otkrivanja prema inteligentnom dizajnu temeljenom na podacima.

6. Literatura

- [1] Pearl, J.; Mackenzie, D.: *The Book of Why: The New Science of Cause and Effect*, Penguin Books, Harlow (2019), ISBN: 9780465097609 Dostupno na <https://www.penguin.co.uk/books/289825/the-book-of-why-by-judea-pearl-and-dana-mackenzie/9780141982410>, Pristupljeno: 2013-07-15
- [2] Rezić, T.; Kracher, D., Oros, D., Mujadžić, S., Andelini, M., Kurtanjek, Ž., Ludwig, R.: Application of causality modelling for prediction of molecular properties for textile dyes degradation by LPMO, *Molecules*, **27** (2022) 6390, <https://doi.org/10.3390/molecules27196390>
- [3] Rezić, T.; Vrsalović Presečki, A., Kurtanjek, Ž.: New approach to the evaluation of lignocellulose derived by-products impact on lytic-polysaccharide monooxygenase activity by using molecular descriptor structural causality, *Bioresource Technology*, **342** (2021) 125990, <https://doi.org/10.1016/j.biortech.2021.125990>
- [4] Kurtanjek, Ž.: Molecule structure causal modelling (SCM) of choline chloride based eutectic solvents, *Chemical and Biochemical Engineering Quarterly*, **36** (2022) 4, 223-230, <https://doi.org/10.15255/CABEQ.2022.2104>

IMAGINEHEART nakon završetka projekta: kritički osvrt i preostali izazovi u računalnoj analizi srca i srčanih struktura

Irena Galić¹, Marija Habijan¹

¹Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek, Kneza Trpimira 2B, 31000 Osijek

***Sažetak:** Kardiovaskularne bolesti vodeći su uzrok smrtnosti u Europskoj uniji, zbog čega je razvoj pouzdanih metoda procjene zdravlja srca od velike važnosti. Napredne tehnike snimanja (ultrazvuk, CT i MRI) omogućuju detaljan uvid u strukturu i funkciju srca, dok metode strojnog i dubokog učenja značajno unapređuju analizu medicinskih slika. U radu su prikazane metode za automatsku segmentaciju, kvantifikaciju i vizualizaciju kardiovaskularnih struktura iz CT i MRI snimaka razvijene u projektu ImagineHeart. Predloženi pristupi omogućuju dobivanje većeg broja klinički relevantnih informacija iz manjeg broja snimki. Rad donosi i kritički osvrt na izazove poput nedostatka podataka, interpretabilnosti modela te integracije u kliničku praksu, uz smjernice za buduća istraživanja. Dodatno, rezultati ukazuju na potencijal kliničke primjene te na poboljšanje dijagnostike i planiranja terapije.*


***Ključne riječi:** analiza i obrada medicinskih slika, obrada slika kardiovaskularnog sustava, strojno i duboko učenje, umjetna inteligencija*

1. Uvod

Pojam kardiovaskularnih bolesti podrazumijeva funkcionalne i morfološke abnormalnosti srca i krvožilnog sustava. Prema posljednjim dostupnim statistikama Svjetske zdravstvene organizacije, kardiovaskularne bolesti uzrokuju čak 17,9 milijuna (32 %) svih smrti na godišnjoj razini [1]. Rana dijagnoza i primjereni tretman za pojedinu kardiovaskularnu bolest mogu značajno smanjiti smrtnost te poboljšati kvalitetu pacijentova života. Napredak u količini računalne moći omogućio je značajno ubrzanje u prikupljanju i interpretaciji medicinskih snimaka. Primjer takvog napretka je i računalno snimanje u medicinske svrhe koje omogućuje medicinskim stručnjacima neinvazivan uvid u ljudsko tijelo bez kirurških procesa. Računalno snimanje u

medicinske svrhe nadišlo je jednostavne primjene vizualizacije anatomskih struktura te je postalo izrazito bitan alat u raznim drugim aktivnostima, kao što je planiranje kirurških zahvata, praćenje razvoja bolesti, navigacija katetera za vrijeme operacija i mnogim drugim. Postoji nekoliko različitih tehnologija neinvazivnog snimanja srca, gdje svaka od tehnika ima svoju primjenu i svoje prednosti i nedostatke. Ta prednost može biti u obliku manje radijacije za pacijenta, kraćeg trajanja snimanja, jeftinijeg pregleda, više rezolucije, bolje detekcije tkiva i slično. Najpoznatije metode koje se koriste za snimanje kardiovaskularnog sustava su magnetska rezonanca (MRI), računalna tomografija (CT), pozitronska emisijska tomografija (PET), jednofotonska pozitronska računalna tomografija (SPECT) i ultrazvuk (US). Istraživanja pokazuju kako je MRI kao modalitet snimanja srčanog ciklusa bolji i precizniji za svrhe određivanja funkcije srca i krvnih žila (neki ga čak nazivaju zlatnim standardom), dok je CT bolji za utvrđivanje anatomije [2].

S obzirom na to da kompleksnost i veličina snimljenih medicinskih podataka drastično raste s računalnom moći i razvojem elektronike, pojavljuje se potreba za izdvajanjem bitnih anatomskih struktura iz takvih snimaka kao i za ekstrakcijom klinički korisnih podataka o anatomiji snimanog dijela tijela. Primjeri kvantifikacija koje se mogu koristiti su: geometrija i volumen srca, geometrija bitnih arterija, morfologija aurikula lijeve pretkljetke, tok krvi kroz aortu, analiza srčane popustljivosti te kvantizacija epikardijalne masti [3-5]. Odstupanje od normalnih vrijednosti gotovo svake od ovih kvantifikacija čimbenik je rizika u razvoju neke od srčanih bolesti. Nadalje, dokazano je da hipertrofija lijeve srčane klijetke predstavlja visok faktor rizika u razvoju fibrilacije atrijske [6] kao i masnih naslaga na srcu [7]. Isto tako dokazano je kako pri fibrilaciji atrijske pterostrukture raste rizik od moždanog udara, a oko 20 % svih moždanih udara nastalih zbog fibrilacije atrijske nastaje u aurikulu lijeve pretkljetke [8]. Dokazano je i da volumen i morfologija aurikula lijeve pretkljetke utječu na broj moždanih udara od tromba nastalih u srcu iako pacijenti nemaju dokazanu fibrilaciju atrijske [8, 9]. S obzirom na to da postoji i korelacija između brzine toka krvi unutar aurikule lijeve pretkljetke i njezine morfologije [10] te korelacija između tromboembolizma nastalog u aurikulu lijeve pretkljetke i smanjenog toka krvi kroz aurikulu lijeve pretkljetke [11] moguće je razviti računalnu metodu koja će moći pretpostaviti postoji li povećan rizik od moždanog udara pacijenta i prije nego se razvije neka od bolesti koje taj rizik drastično povećavaju (npr. fibrilacija atrijske). Prema tome, pravovremeno prepoznavanje takvih odstupanja omogućava prognozu potencijalnih rizika za zdravlje pacijenta što predstavlja fundamentalno poboljšanje u dijagnostici i tretmanu pacijenata. Moderni uređaji za radiološko snimanje tijela daju snimke koje prikazuju anatomiju tijela na takav način da ih klinički eksperti mogu interpretirati. Ipak, automatizacija interpretacije takvih snimaka je iznimno zahtjevan proces, jer takve snimke sadrže i veliku količinu šuma kao što je prikazano na Slici 1.



Slika 1: Gore (s lijeva na desno): jedan 2D presjek volumetrijske CT slike iz 3 različita pogleda, aksijalni pogled, sagitalni pogled i koronalni pogled. Dolje (s lijeva na desno): jedan 2D presjek volumetrijske MRI slike iz 3 različita pogleda, aksijalni pogled, sagitalni pogled i koronalni pogled

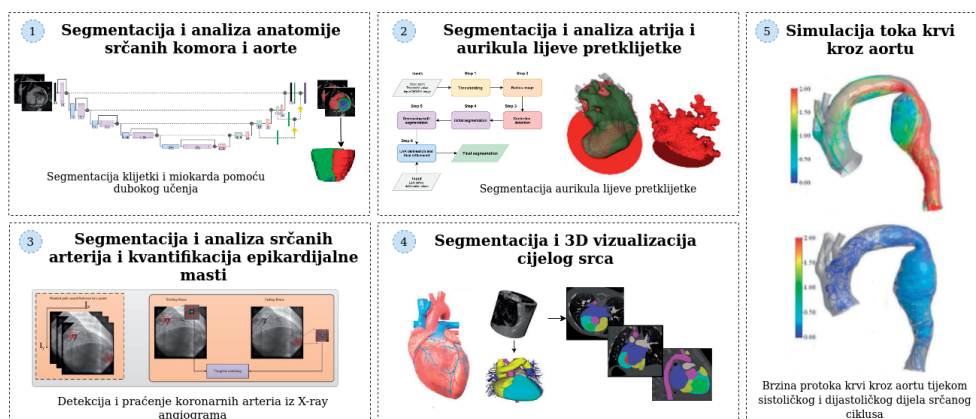
Kako bi se proces interpretacije medicinskih slika ubrzao i poboljšao, medicinske snimke dobivene procesima medicinskog snimanja obrađuju se naprednim računalnim metodama koje su integrirane u specijaliziranu programsku podršku. Metode implementirane u takvoj programskoj podršci najčešće su vezane za neku određenu primjenu (npr. neke metode rade izolaciju i vizualizaciju srca, neke prikazuju srčane žile, neke se koriste za određivanje volumena određenog dijela srca i slično). Snimanje pacijenta često se obavlja za točno određenu pretragu, pa metode za tu pretragu očekuju specifičan tip slike. Zbog toga je istu snimku teško iskoristiti kao ulaz za više metoda, što zahtijeva ponovno snimanje pacijenta i stvara dodatne troškove. Nadalje, postojeće metode često nisu dostupne unutar standardnih paketa takve programske podrške, već se dodatno naplaćuju. Samim time nije moguće koristiti sve dostupne metode kako bi se dobila kompletna slika kardiovaskularnog zdravlja, već pojedine metode daju pojedinačne kvantifikacije određenih srčanih parametara, prema kojima liječnici određuju koje su daljnje pretrage potrebne. Prema tome, potrebno je težiti razvoju novih metoda koje će biti otvorenog koda, potpuno besplatne te koje će omogućiti liječnicima bolju dijagnostiku pacijenata, a istraživačima mogućnost testiranja i unapređivanja razvijenih metoda.

U nastavku ovoga rada predstavljene su metode za obradu i analizu slika kardiovaskularnog sustava razvijene tijekom uspostavno-istraživačkog projekta Hrvatske zaklade za znanost “Metode za interpretaciju medicinskih snimki za detaljnu analizu zdravlja srca - ImagineHeart”. Nakon uvodnog dijela, u Poglavlju 2. predstavljene su razvijene metode klasificirane u pet osnovnih skupina na temelju dijelova kardiovaskularnih struktura koje obrađuju. Spomenute skupine uključuju: (1) metode za segmentaciju i analizu anatomije srčanih komora i aorte, (2) metode za segmentaciju i analizu atriya i lijevog srčanog aurikula, (3) metode za segmentaciju i analizu srčanih

arterija i kvantifikaciju epikardijalne masti, (4) metode za simulaciju toka krvi kroz dijelove srca te (5) metode za izolaciju i vizualizaciju cijeloga srca. Nakon detalja o razvijenim metodama za svaku pojedinu tematiku, u Poglavlju 3., dana je rasprava o mogućnostima primjene razvijenih metoda temeljenih na dubokom učenju u stvarnoj kliničkoj praksi. Naposljetku, u Poglavlju 4., dan je kratak osvrt na sve predložene metode te zaključak projekta i ovoga rada.

2. Računalne metode za segmentaciju i kvantifikaciju srca i srčanih struktura

Kako bi se dobila kompletna slika kardiovaskularnog zdravlja potrebno je razviti metode koje će odrediti više različitih kardiovaskularnih kvantifikacija na srcu i srčanim komorama te ih povezati s kvantifikacijama najbitnijih arterija (aorte, koronarnih arterija, karotide). Umjesto pojedinačnih kvantifikacija koje se danas primjenjuju, ovaj projekt predlaže fundamentalna poboljšanja u dijagnostici i tretmanu pacijenata. Navedeno je postignuto razvojem naprednih metoda temeljenih na strojnom i dubokom učenju koje omogućuju automatsko izdvajanje srca i njegovih pojedinih dijelova kao i određivanje što većeg broja kvantifikacija srca iz što manjeg skupa podataka. Tijekom projekta razvijene su potpuno automatske metode za lokalizaciju srca i segmentaciju srčanih komora iz CT i MRI snimaka, izolaciju i vizualizaciju srca i bitnih arterija, određivanje geometrije srca i srčanih komora, određivanje geometrije i položaja bitnih srčanih žila u odnosu na ostale dijelove srca, segmentaciju i analizu aurikula lijeve pretklijetke, mjerenje minutnog volumena i protoka krvi, određivanje brzine pulsog vala, simulaciju toka krvi kroz aortu, određivanje srčane popustljivosti, kao i segmentaciju i kvantifikaciju epikardijalne masti. Osnovne tematske cjeline obuhvaćene unutar projekta ilustrirane su na Slici 2.




Slika 2: Osnovne tematske cjeline projekta IMAGINEHEART i ilustrativni primjeri rezultata razvijenih računalnih algoritama za obradu kardiovaskularnih slika

2.1 Segmentacija i analiza anatomije srčanih komora i aorte

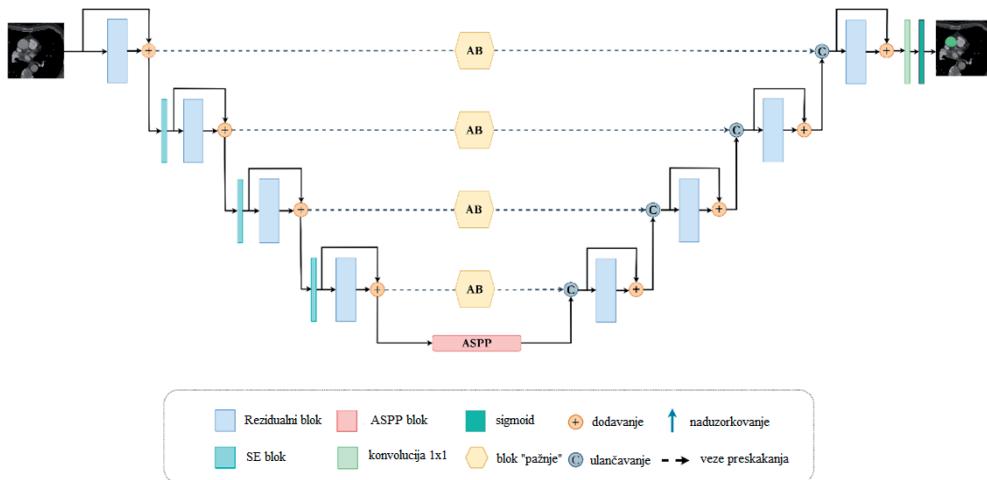
Ljudsko srce je mišićni organ veličine šake, smješteno u sredini prsnog koša, s malim pomakom ulijevo. Sastoji se od četiri osnovne komore: dvije pretkljetke i dvije kljetke. Uz primarnu zadaću pumpanja krvi kroz ljudski krvožilni sustav i opskrbu stanica kisikom i hranjivim tvarima, srce i krvožilni sustav imaju nezamjenjivu ulogu u preuzimanju suvišnih i štetnih tvari iz tijela. Kao što je već objašnjeno u uvodnom dijelu, različite tehnologije medicinskog snimanja, poput računalne tomografije (CT) i magnetske rezonance (MRI), razvijene su kako bi se omogućio detaljan uvid u strukture unutar tijela. Kako bi se tako dobiveni podaci mogli dalje obrađivati (izdvajanje pojedinih dijelova, 3D vizualizacija) koriste se različiti algoritmi iz područja obrade slike, računalnog vida i umjetne inteligencije.

Tijekom projekta razvijene su automatske metode za segmentaciju srca i njegovih struktura iz CT i MRI snimaka. Pristup se temelji na dubokim neuronskim mrežama koder-dekoder tipa, ponajprije na U-Net i 3D U-Net arhitekturi, koje omogućuju učinkovito učenje prostornih i semantičkih značajki. Koder izdvajanja niskorazinske informacije, dok dekoder rekonstruira sliku i omogućuje preciznu lokalizaciju struktura, uz povezivanje putem veza preskakanja. Razvijena metoda omogućuje segmentaciju ključnih anatomskih dijelova, uključujući kljetke, pretkljetke, aortu i plućne vene (Slika 3). Postignuta točnost od 89 % u odnosu na referentne segmentacije potvrđuje učinkovitost i primjenjivost predloženog pristupa.



Slika 3: Predložena metoda za lokalizaciju i segmentaciju cijelog srca

Duboko učenje, osobito kroz konvolucijske mreže i U-Net arhitekturu, pokazalo je značajan potencijal u automatskoj segmentaciji medicinskih slika. Ipak, značajke nižih razina sadrže detaljne prostorne informacije, ali manjak semantike, dok značajke viših razina imaju bogat semantički sadržaj uz gubitak prostorne preciznosti, zbog čega njihovo izravno spajanje nije optimalno. Postojeći pristupi, poput ResNet, DeepLabV3 i ResUNet++, nastoje unaprijediti prijenos i fuziju značajki, dok SENet dodatno uvodi mehanizme za isticanje važnih informacija [15-19]. Polazeći od tih spoznaja, razvijena je arhitektura AB-ResUNet+, koja poboljšava iskorištavanje značajki i kontekstualnih informacija. Model se temelji na U-Netu uz tri ključne nadogradnje: uvođenje rezidualnih jedinica radi stabilnijeg učenja, primjenu mehanizma samopažnje za selektivno naglašavanje važnih značajki te korištenje ASPP modula za proširenje receptivnog polja kao što je prikazano na Slici 4. Ovakav pristup omogućuje precizniju i robusniju segmentaciju.




Slika 4: Ilustracija predložene 3D AB-ResUNet+ arhitekture neuronske mreže za segmentaciju srčanih struktura

Predložena arhitektura upotrijebljena je za segmentaciju 11 značajnih kardiovaskularnih struktura, a to su: koronarni sinus (CS), silazna aorta (DA), donja šuplja vena (IVC), aurikula lijeve pretklijetke (LAA), stijenka lijevog atrija (LAW), papilarni mišić (PM), stražnji mitralni list (PML), proksimalna uzlazna aorta (PAA), plućna aorta (PA), stijenka desne klijetke (RVW) i gornja šuplja vena (SVC).

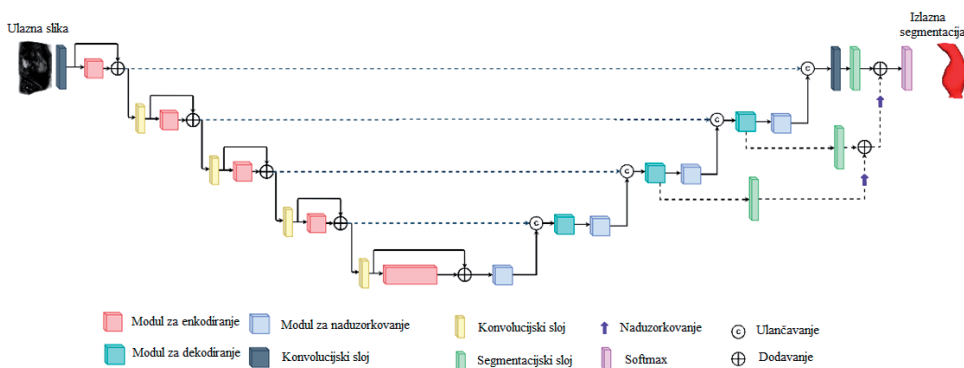
S obzirom na ostvarene uspjehe razvijenih metoda dubokog učenja, daljnje istraživanje usmjereno je i na kvantifikaciju lijeve i desne klijetke. Kvantifikacija podrazumijeva računanje značajnih kliničkih parametara koji su neophodni za postavljanje različitih dijagnoza. Tako se na temelju dobivenih 3D segmentacija može izračunati volumen lijeve i desne klijetke u različitim fazama srčanog ciklusa (na kraju sistole i dijastole) kao i masa i volumen miokarda. Na temelju volumena se dalje mogu izračunati značajni funkcionalni indikatori kardiovaskularnog sustava poput frakcije izbacivanja, odnosno udjela krvi koja se ispušta iz pojedine klijetke prilikom svakog srčanog otkucaja, zatim volumena miokarda na kraju sistole kao i masa miokarda. Razvijena metoda za kvantifikaciju temeljena je na optimizaciji 3D U-Net arhitekture dodavanjem SERes blokova unutar njenih koder i dekode dijelova [21]. SERes blokovi sastoje se od operacija “stiskanja” i “uzbuđenja” (SE blok) praćenih s rezidualnim blokovima. Operacija stiskanja koristi globalno prosječno udruživanje za grupiranje mapi značajki preko prostornih dimenzija kako bi stvorila deskriptore. Na tako dobiveni izlaz u koraku operacije uzbuđenja primjenjuju se potpuno povezani slojevi kako bi se stvorile skupine aktivacija koje su dalje primijenjene na mape značajki kako bi se generirao izlaz iz SE bloka. Na ovaj način, zbog rekalibracijske strategije, mreža može razlikovati važnost značajki iz rezidualnih kanala te na temelju razine važnosti odvojiti korisne značajke odnosno odbaciti one manje važne. Tako se povećava reprezentacijska moć mreže te se postigne značajno ubrzanje konvergencije modela kao i samog procesa učenja mreže. Dobiveni

rezultati segmentacija na kraju dijastole prikazani su na Slici 5. Na temelju dobivenih rezultata možemo zaključiti da dodavanje SE blokova u predloženoj metodi ostvaruje bolje rezultate od arhitekture bez SE blokova.




Slika 5: S lijeva na desno: jedan 2D presjek volumetrijske MRI slike na kraju dijastole s označenim srčanim strukturama: desna klijetka (plavo), lijeva klijetka (crveno), i miokardij (žuto), 3D vizualizacija, jedan 2D presjek volumetrijske MRI slike na kraju sistole s označenim srčanim strukturama: desna klijetka (plavo), lijeva klijetka (crveno), i miokardij (žuto), 3D vizualizacija

Aneurizma abdominalne aorte ozbiljno je kardiovaskularno stanje uzrokovano slabljenjem stijenke aorte, što dovodi do njezina širenja, degeneracije i stvaranja tromba. Bez pravodobnog liječenja aneurizma progresivno raste i može završiti rupturom sa smrtnim ishodom. Kao terapija primjenjuju se kirurški zahvati ili endovaskularni popravak, pri kojem se ugrađuje stent-graft radi smanjenja tlaka na stijenku aorte i rizika od pucanja. Za procjenu rizika i praćenje razvoja bolesti nužno je kontinuirano analizirati promjene aneurizme, što je ručno zahtjevno te zahtijeva automatizaciju. U tom je kontekstu razvijena metoda za segmentaciju i analizu aorte temeljena na modificiranoj 3D U-Net arhitekturi s rezidualnim jedinicama i dubokim nadzorom. Model omogućuje preciznu lokalizaciju i segmentaciju aneurizme, pri čemu se informacije iz različitih razina mreže integriraju u konačan rezultat (Slika 6 i Slika 7). Ograničenje metode proizlazi iz korištenog skupa podataka, koji je unaprijed izdvojen na područje interesa, što može utjecati na sposobnost generalizacije modela.



Slika 6: Ilustracija predložene 3D U-Net RE+SE arhitekture neuronske mreže za segmentaciju lijeve klijetke, desne klijetke i miokarda iz cineMRI slika [21]



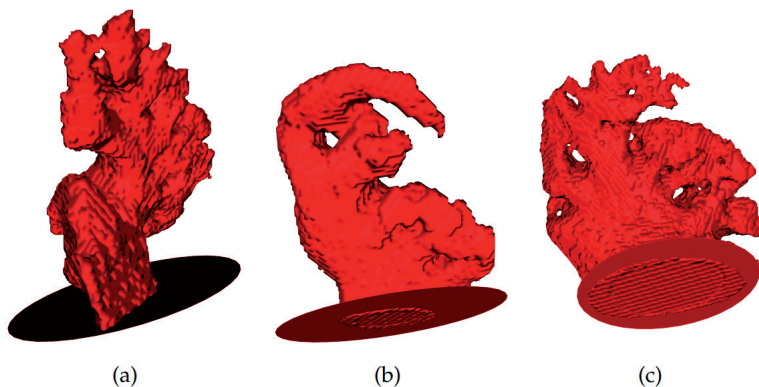
Slika 7: Primjer dobivenih segmentacija aneurizme abdominalne aorte (lijevo). Usporedba između “ground-truth” segmentacija i dobivenih segmentacija predloženom metodom (desno)

U području obrade medicinskih slika, nedostatak velike količine kvalitetnih i raznovidnih označenih podataka medicinskih slika predstavlja uobičajenu prepreku za modele dubokog učenja. Kako bi modeli dubokog učenja bili robusni te kako bi imali visoku mogućnost generalizacije na novim podacima iz stvarne kliničke prakse, potrebno je povećati skupove označenih podataka. S obzirom da je ručno označavanje od strane kliničkih eksperata izuzetno zahtjevan posao, potrebno je razvijati i poboljšavati metode za učinkovitost i robusnost neuronskih mreža za treniranje na manjim skupovima podataka. Tijekom projekta razvijena je metoda temeljena na samonadziranom učenju kako bi bili u mogućnosti izdvojiti važne informacije iz neoznačenih medicinskih slika koje se zatim mogu koristiti za lakše treniranje na ograničenom skupu označenih podataka [22].

2.2 Segmentacija i analiza atrijske i aurikule lijeve pretkljetke

Fibrilacija atrijske je poremećaj srčanog ritma uzrokovan nepravilnim električnim signalima, što dovodi do asinkronih kontrakcija i zadržavanja krvi u pretkljetkama. Time se povećava rizik od stvaranja tromba i moždanog udara, pri čemu više od 90 % tromboembolija nastaje u aurikulu lijeve pretkljetke. Kako bi se smanjio taj rizik, koristi se perkutana okluzija aurikule, pri čemu se implantira uređaj koji sprječava protok krvi. Za pravilan odabir okludera nužno je poznavati anatomiju, što se može analizirati pomoću CT snimaka. Preoperativno planiranje na temelju CT-a omogućuje sigurniju i učinkovitiju provedbu zahvata te identifikaciju pacijenata kod kojih za-

hvat nije moguć. Tijekom projekta razvijena je nova metoda za određivanje centralne linije kroz aurikul, od početne odabrane točke do centra lijeve pretkljetke. Predložena metoda traži put u 3D slici od početne točke prateći voksele duž središta LAA dok ne dođe do centra lijeve pretkljetke. Određena centralna linija se koristi kao ulaz u metodu za segmentaciju te metodu za određivanje lokacije ostiuma LAA. Nadalje, predložena metoda za segmentaciju obavlja segmentaciju iterativnim rastom regije određene detektiranom centralnom linijom. Metoda iz binarne maske (određene pomoću vrijednosti praga koju je postavio korisnik) izdvaja regiju koja sadrži LAA i većinu lijeve pretkljetke. Izdvajanjem područja pretkljetke u okolini aurikula omogućeno je bolje razumijevanje anatomije aurikula u kontekstu lokalne anatomije pretkljetke (npr. poziciju i smjer aurikula u zidu atrija, blizinu plućnih vena). Na Slici 8 prikazani su dobiveni rezultati segmentacije aurikula lijeve pretkljetke.

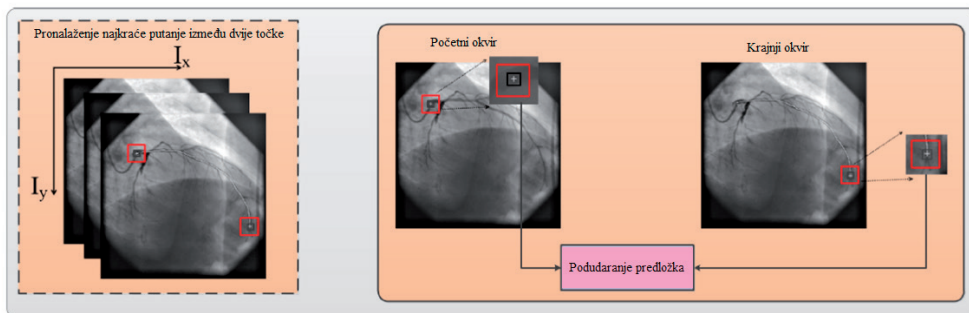


Slika 8: Primjeri uspješnih rezultata segmentacije aurikule lijeve pretkljetke dobiveni predloženom metodom [25]

2.3. Segmentacija i analiza srčanih arterija i kvantifikacija epikardijalne masti


Kateterizacija srca važna je dijagnostička procedura koja omogućuje prikaz srčanih zalistaka i koronarnih arterija. Tijekom zahvata kateter se uvodi u krvne žile i vodi do srca, gdje se ubrizgava kontrast za dobivanje rendgenskih snimki. Segmentacija tih sekvenci omogućuje procjenu stanja krvnih žila, otkrivanje stenoza i planiranje liječenja. Ključan korak je određivanje središnje linije krvne žile, koja omogućuje analizu geometrije i kliničkih parametara poput frakcijskog protoka. Ovi zadaci su izazovni zbog preklapanja struktura, neujednačenog kontrasta i varijabilne kvalitete snimki. Inspirirani navedenom problematikom, tijekom projekta je razvijena metoda za praćenje glavne koronarne arterije. Predložena metoda temelji se na detekciji ruba grebena i određivanju praga nakon čega se središnja linija krvne žile izdvaja pomoću postupka skeletonizacije [26]. Nakon toga, ručno se odaberu dvije točke, na početku i na kraju glavne koronarne arterije te se traži najkraći put između odabranih točaka.

Na ovaj način izdvojena je tražena arterija, a kako bismo pratili odabranu koronarnu arteriju kroz video sekvencu, upotrijebljen je postupak podudaranja predložaka između odabranih točaka kao što je ilustrirano na Slici 9.



Slika 9: Ilustracija predložene metodologije za ekstrakciju glavne koronarne arterije (lijevo) i praćenje glavne koronarne arterije kroz rendgensku sekvencu (desno)

Nadalje, postojanje epikardijalne masti na perikardiju pokazalo je izravnu ulogu u nastanku koronarnih bolesti i kardiomiopatije [27] [28]. Debljina epikardijalne masti korelira s metaboličkim sindromom [29] te ima značajnu ulogu u progresiji kalcifikacije koronarnih arterija [30]. Prema tome, kvantifikacija epikardijalne masti ima značajnu ulogu u dijagnostici stoga je mjerenje njezina volumena i debljine izuzetno značajno u kliničkoj praksi. Segmentacija epikardijalne masti je izazovan zadatak zbog njezine neravnomjerne raspodjele oko srca, neobičnog oblika i sličnosti s drugim masnim tkivima. Upravo zbog toga, tijekom projekta je razvijena potpuno automatska metoda za segmentaciju epikardijalne masti čiji su rezultati prikazani na Slici 10.




Slika 10: Primjeri dobivenih segmentacija prediktivnim modelom

2.4 Segmentacija i vizualizacija cijelog srca

Automatska segmentacija i vizualizacija cijelog srca i njegovih struktura predstavlja ključne korake u suvremenoj kardiološkoj dijagnostici. Precizno izdvajanje srčanih komora, miokarda i velikih krvnih žila iz CT i MRI snimaka omogućuje detaljnu analizu anatomije i funkcije srca te dobivanje klinički relevantnih kvantitativnih pokazatelja. Razvoj naprednih metoda dubokog učenja omogućio je pouzdaniju i robusniju segmentaciju složenih anatomskih struktura, čak i u uvjetima ograničene kvalitete

podataka. Integracijom segmentacije i vizualizacije dobiva se cjelovit prikaz srca koji olakšava interpretaciju nalaza, planiranje terapije i praćenje bolesti. Takvi pristupi doprinose standardizaciji analize medicinskih snimki te imaju značajan potencijal za primjenu u kliničkoj praksi i unapređenje kardiološke skrbi. U svrhu postizanja precizne segmentacije cijelog srca i pripadajućih struktura razvijena je metoda temeljena na dubokim neuronskim mrežama koder-dekoder tipa, uz integraciju unaprijeđenih rezidualnih blokova. Predložena arhitektura omogućuje učinkovito učenje reprezentacija složenih anatomskih odnosa, uz očuvanje prostornih informacija važnih za točnu segmentaciju. Poseban naglasak stavljen je na stabilnost učenja i generalizaciju modela, čime se omogućuje primjena na različitim skupovima medicinskih podataka. Dobiveni rezultati segmentacije omogućuju jasnu i konzistentnu vizualizaciju srčanih struktura, čime se olakšava njihova interpretacija u kliničkom kontekstu. Kao što je prikazano na Slici 11, model uspješno segmentira cijelo srce i ključne anatomske komponente, uz visoku razinu preciznosti i prostorne koherentnosti.

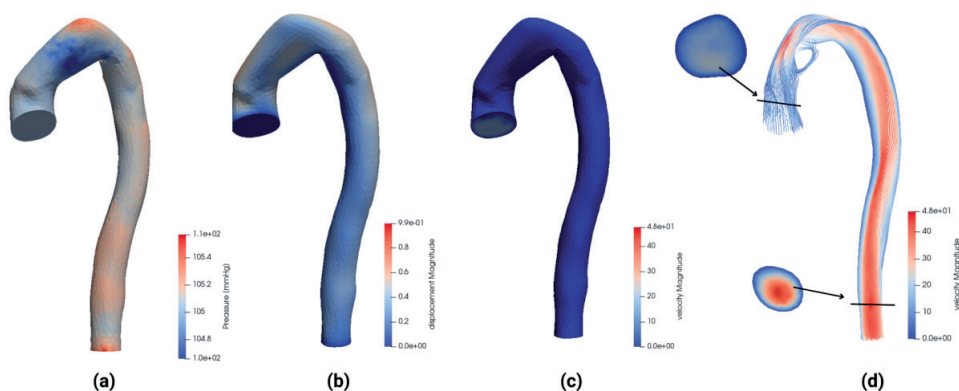


Slika 11: 3D vizualizacija dobivenih segmentacija s označenim srčanim strukturama: desna klijetka (magenta), desna pretklijetka (zeleno), aorta (narančasto), lijeva klijetka (crveno), lijeva pretklijetka (plavo), miokardij (žuto) i plućna arterija (cijan). Dolje s lijeva na desno: 3D vizualizacija srca i srčanih struktura iz različitih pogleda [32]

2.5 Simulacija toka krvi kroz aortu

Nadalje, u slučaju nekih kardiovaskularnih bolesti poput arterioskleroze, zid krvnih žila razvija abnormalnosti koje se nazivaju lezijama. Lezije mogu uzrokovati suženje krvnih žila koje je često uzrokovano stvaranjem ateromatoznog plaka te u ozbiljnim slučajevima može rezultirati koronarnom bolešću, bolešću perifernih arterija ili čak moždanim udarom [33-35]. Rane arteriosklerotične lezije razvijaju se u područjima

grananja krvnih žila gdje je protok krvi značajno poremećen zbog složene geometrije krvnih žila i pulsirajuće prirode protoka krvi [36]. Bolje razumijevanje arteriosklerotskog razvoja omogućeno je modeliranjem temeljenom na slikama i numeričkim simulacijama toka krvi u aorti. Kako bismo pomogli u rješavanju navedenog problema, dizajnirali smo programski okvir koji automatski odrađuje sve potrebne korake za dobivanje simulacije toka krvi kroz aortu. Predložena metoda sastoji se od četiri koraka (1) segmentacija 3D CT slika, (2) generiranje modela, (3) generiranje *mesh*-a i (4) rješavanje Navier-Stokesovih jednadžbi kroz koje je omogućena simulacija toka krvi. Navedeni koraci su implementirani bibliotekama otvorenog koda, mogu se izvršiti iz komandne linije pozivanjem jedne naredbe, ne zahtijevaju nikakvu korisničku interakciju čime je značajno smanjeno vrijeme potrebno za dobivanje simulacije toka krvi kroz aortu. Dobiveni rezultati simulacije toka kroz aortu prikazani su na Slici 12.



Slika 12: Rezultati simulacije za (a) pritisak, (b) pomak, (c) brzinu, (d) brzinu toka s primjerima brzinskih rezova na ulazu i na izlazu aorte

3. Primjena metoda dubokog učenja u kliničkoj praksi

Unatoč obećavajućim rezultatima dobivenih korištenjem strojnog i dubokog učenja, ostaje nekoliko neriješenih izazova s kojima se suočava potencijal primjene navedenih metoda u stvarnoj kliničkoj primjeni. Jedan od glavnih problema u razvoju algoritma dubokog učenja za primjenu u medicini predstavlja dostupnost skupova podataka. Javno objavljivanje snimaka pacijenata (čak i anonimiziranih) podložno je strogim etičkim regulativama kako bi se osigurala njihova privatnost. Ako bismo htjeli javno objaviti skup podataka potrebno je zatražiti pisanu dozvolu samih pacijenata te dobiti odobrenje etičkog povjerenstva unutar bolnica za njihovo javno objavljivanje, što je često teško ostvarivo. Do sada su organizirana različita medicinska natjecanja tijekom

kojih su označeni skupovi podataka od strane radiologa i kliničkih eksperata dani na korištenje. Često su ti podaci jako maleni i ne sadrže raznolike patologije srčanih bolesti. Iako je na neki način poanta razvoja novih algoritama dubokog učenja dobivanje visoke točnosti uz malu količinu podataka za treniranje, to istovremeno predstavlja i veliki problem u izradi produkcijski spremnih modela segmentacije koji bi se eventualno koristili u kliničkoj praksi. Ukoliko bi se takvi, čisto “tehnički” problemi uspješno riješili, odnosno kada bi se i napravile metode koje daju potencijalno savršene rezultate (u smislu točnosti, preciznosti, robusnosti, niskih računalnih zahtjeva) ostaju neriješeni etički i pravni izazovi (privatnost i sigurnost podataka, preuzima li odgovornosti u slučaju pogrešne dijagnostike pružatelj usluge odnosno softvera ili bolnica, i slično...). Isto tako, veliki problem predstavlja i kvaliteta podataka. Za razliku od drugih domena gdje su podaci čisti i dobro strukturirani, medicinski podaci su veoma heterogeni, dvosmisleni, sadrže šum, velike varijacije u intenzitetu te su često i nepotpuni. Učenje dobrog modela dubokog učenja s tako masivnim i raznolikim skupovima podataka je izazovan zadatak i treba uzeti u obzir nekoliko pitanja, kao što su rijetkost podataka, redundantnost i nedostajuće vrijednosti u podacima. Nadalje, bolesti uvijek napreduju i mijenjaju se tijekom vremena na nedeterministički način. Međutim, mnogi postojeći modeli dubokog učenja, uključujući one koji su već predloženi u medicinskoj domeni, pretpostavljaju statičke vektorske ulaze, koji se ne mogu nositi s faktorom vremena na prirodan način. Projektiranje pristupa dubokog učenja koji mogu obraditi vremenske zdravstvene podatke je važan aspekt koji će zahtijevati razvoj novih rješenja. Važno je spomenuti i izuzetno visoku složenost domene. Za razliku od drugih domena primjene (npr. analiza govora), problemi u biomedicini i zdravstvenoj zaštiti su kompleksniji. Bolesti su vrlo heterogene i za većinu bolesti još uvijek nema kompletnog znanje o njihovim uzrocima i načina progresije. Štoviše, broj pacijenata obično je ograničen u praktičnom kliničkom scenariju te nije moguće dobiti pristup većem broju pacijenata. Osim toga, interpretabilnost i dalje predstavlja veliki problem u razvoju metoda dubokog učenja u medicinske svrhe. Iako su modeli dubokog učenja pokazali izuzetnu uspješnost u različitim domenama primjene, oni se često tretiraju kao “crne kutije”. Dok to možda više nije problem u drugim slučajevima determinističkih domena kao što je označavanje slike (jer krajnji korisnik može objektivno potvrditi oznake dodijeljene slikama), u zdravstvu, ne samo da je važna kvantitativna algoritamska izvedba, već je relevantan i razlog zbog čega algoritmi rade na način na koji rade. Takva interpretabilnost modela dubokog učenja (tj. navođenje fenotipova koji pokreću predviđanja) ključna je za uvjeravanje medicinskih djelatnika o radnjama koje preporučuje razvijeni prediktivni sustav (npr. propisivanje određenog lijeka, potencijalni visoki rizik od razvoja određene bolesti, itd.). Iako su posljednjih godina uloženi i postignuti ogromni napreci u približavanju automatskih softvera za obradu i analizu medicinskih slika, zbog svega navedenog, čini se da smo još podosta daleko od njihove primjene u stvarnoj kliničkoj praksi. Unatoč tome, navedeni nedostaci predstavljaju odlične smjernice koje je potrebno uzeti u obzir tijekom budućih istraživanja.

4. Izazovi i otvorena pitanja uočena nakon završetka projekta ImagineHeart

Unatoč značajnim rezultatima ostvarenima tijekom projekta ImagineHeart i razvoju niza naprednih metoda za segmentaciju, kvantifikaciju i vizualizaciju kardiovaskularnih struktura, provedba istraživanja ukazala je i na niz otvorenih pitanja koja ostaju relevantna za daljnji razvoj područja obrade i analize medicinskih slika. Najznačajniji izazov odnosi se na nedostatak velikih, raznolikih i standardiziranih skupova podataka. Tijekom provedbe projekta postalo je jasno da trenutačno dostupni javni skupovi podataka ne pokrivaju dovoljan raspon anatomske i patološke varijacije te često sadrže ograničen broj pacijenata i modaliteta. Zbog toga je mogućnost generalizacije razvijenih modela na široku populaciju pacijenata i dalje ograničena. Dodatno, stroga etička regulativa otežava dijeljenje medicinskih slika, što znatno usporava napredak. Nadalje, iako su razvijeni algoritmi tehnički napredni, još uvijek su prisutna izrazita ograničenja njihove integracije u stvarnu kliničku praksu. Prijenos istraživačkih prototipova u kliničko okruženje zahtijeva dodatne korake poput certificiranja softvera, uvođenja intuitivnih korisničkih sučelja, integracije s PACS/RIS sustavima i validacije na multicentričnim podacima. Ovi izazovi nisu bili u opsegu projekta, ali predstavljaju ključne preduvjete za stvarnu primjenjivost razvijenih metoda.

Značajan izazov predstavlja i interpretabilnost modela dubokog učenja. Unatoč visokoj točnosti i robusnosti nekih od razvijenih arhitektura, modeli dubokog učenja i dalje se često percipiraju kao "crne kutije". U medicini je nužno razumjeti ne samo rezultat, već i logiku koja stoji iza odluka modela, osobito kod intervencija kao što je okluzija aurikula lijeve pretkljetke. Potreban je razvoj metoda koje kombiniraju visoku točnost s transparentnijim postupcima donošenja odluka. Nadalje, analizom rezultata projekta uočeno je i da postoje ograničenja u radu s podacima vremenske dimenzije. Kvantifikacije poput mjerenja minutnog volumena, analize protoka i simulacija hemodinamike temelje se na dinamičkim procesima, dok većina razvijenih metoda obrađuje slike kao statičke volumene. U budućim istraživanjima potrebno je razviti modele koji prirodno integriraju vremensku komponentu i omogućuju analizu cikličkih i nelinearnih fizioloških promjena. Dodatno, iako su razvijene metode pokazale obećavajuće rezultate, još uvijek nije u potpunosti ispitana robusnost i otpornost modela na ekstremne patologije, artefakte u snimkama, različite rekonstrukcijske algoritme i varijabilnost među uređajima različitih proizvođača. Ova pitanja ostaju otvorena i zahtijevaju sustavnu evaluaciju u realnim uvjetima. Konačno, iako su u projektu razvijeni djelomično automatizirani ili potpuno automatizirani sustavi, ostaje prostor za daljnje poboljšanje automatizacije cjelovitih kliničkih procesa, uključujući stabilniju automatizaciju segmentacije složenih struktura, automatsku procjenu kvalitete segmentacije te razvoj sustava koji obuhvaćaju cijelu kliničku proceduru počevši od prikupljanja snimke do dijagnostičkog izvještaja. Provedba projekta ImagineHeart otvorila je niz novih tema i otvorenih pitanja koja predstavljaju smjernice za nastavak istraživanja. Iako su projektni ciljevi ostvareni, ovi izazovi ukazuju na to da prostor za daljnje unaprjeđenje ostaje značajan te da je daljnji rad ključan kako bi se razvijene metode približile rutinskoj kliničkoj primjeni.

5. Zaključak

U ovom radu sažeto su predstavljene najvažnije metode razvijene tijekom provedbe uspostavno-istraživačkog projekta Hrvatske zaklade za znanosti “Metode za interpretaciju medicinskih snimki za detaljnu analizu zdravlja srca - ImagineHeart”. Cilj projekta bio je razviti metode za obradu i analizu slika kardiovaskularnog sustava kako bi se dobila kompletna slika kardiovaskularnog zdravlja. Navedeno je postignuto razvojem naprednih metoda temeljenih na strojnom i dubokom učenju koje omogućuju automatsko izdvajanje srca i njegovih pojedinih dijelova kao i određivanje što većeg broja kvantifikacija srca iz što manjeg skupa podataka. Tijekom projekta razvijene su potpuno automatske metode za lokalizaciju srca i segmentaciju srčanih komora iz CT i MRI snimaka, izolaciju i vizualizaciju srca i bitnih arterija, određivanje geometrije srca i srčanih komora, određivanje geometrije i položaja bitnih srčanih žila u odnosu na ostale dijelove srca, segmentaciju i analizu aurikula lijeve pretkljetke, mjerenje minutnog volumena i protoka krvi, određivanje brzine pulsog vala, simulaciju toka krvi kroz aortu, određivanje srčane popustljivosti, kao i segmentaciju i kvantifikaciju epikardijalne masti.

Zahvala

Projekt ImagineHeart - Metode za interpretaciju medicinskih snimki za detaljnu analizu zdravlja srca financiran je sredstvima Hrvatske zaklade za znanost kroz Uspostavno-istraživački projekt UIP-2017-05-4968.

6. Literatura

- [1] [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)), *Pristupljeno: 2022-08-23*
- [2] Mangalat, D.; Kalogeropoulos, A., Georgiopoulou, V., Stillman, A., Butler, J.: Value of Cardiac CT in Patients With Heart Failure, *Current Cardiovascular Imaging Reports*, **2** (2009) 6, 410-417, <https://doi.org/10.1007/s12410-009-0052-3>
- [3] Taratorin, A. M.; Sideman, S.: Constrained detection of left ventricular boundaries from cine CT images of human hearts, *IEEE Trans. Med. Imaging*, **12**, (1993) 3, 521-533, <https://doi.org/10.1109/42.241880>
- [4] White, H. D.; Norris, R. M., Brown, M. A., Brandt, P. W., Whitlock, R. M., Wild, C. J.: Left Ventricular End-Systolic Volume as the Major Determinant of Survival After Recovery from Myocardial Infarction, *Circulation*, **76** (1987) 1, 44-51, <https://doi.org/10.1161/01.CIR.76.1.44>
- [5] Solomon, S. D.; Anavekar, N., Skali, H., McMurray, J. J. V., Swedberg, K., Yusuf, S., Granger, C. B., Michelson, E. L., Wang, D., Pocock, S., Pfeffer, M. A.: Influence of Ejection Frac-

- tion on Cardiovascular Outcomes in a Broad Spectrum of Heart Failure Patients, *Circulation*, **112** (2005) 24, 3738-3744, <https://doi.org/10.1161/CIRCULATIONAHA.105.561423>
- [6] Katholi, R. E.; Couri, D. M.: Left Ventricular Hypertrophy: Major Risk Factor in Patients With Hypertension: Update and Practical Clinical Applications, *International Journal of Hypertension*, **2011** (2011), Article ID 495349, 1-10, <https://doi.org/10.4061/2011/495349>
- [7] Wong, C. X.; Sun, M. T., Odutayo, A., Emdin, C. A., Mahajan, R., Lau, D. H., Sanders, P.: Epicardial fat and atrial fibrillation: current evidence, potential mechanisms, clinical implications, and future directions, *European Heart Journal*, **38** (2017) 17, 1294-1302, <https://doi.org/10.1093/eurheartj/ehw045>
- [8] Budge, L. P.; Shaffer, K. M., Moorman, J. R., Lake, D. E., Ferguson, J. D., Mangrum, J. M.: Analysis of in vivo left atrial appendage morphology in patients with atrial fibrillation: a direct comparison of transesophageal echocardiography, planar cardiac CT, and segmented three-dimensional cardiac CT, *Journal of Interventional Cardiac Electrophysiology*, **23** (2008) 2, 87-93, <https://doi.org/10.1007/s10840-008-9281-7>
- [9] Di Biase, L.; Santangeli, P., Anselmino, M., Mohanty, P., Salvetti, I., Gili, S., Horton, R., Sanchez, J., Bai, R., Mohanty, S., Pump, A., Cereceda Brantes, M., Gallinhouse, G. J., Burkhardt, J. D., Natale, A.: Does the Left Atrial Appendage Morphology Correlate With the Risk of Stroke in Patients With Atrial Fibrillation? Results From a Multicenter Study, *Journal of the American College of Cardiology*, **60** (2012) 6, 531-538, <https://doi.org/10.1016/j.jacc.2012.04.032>
- [10] Fukushima, K.; Fukushima, N., Kato, K., Ejima, K., Sato, H., Fukushima, K., Saito, C., Hayashi, K., Arai, K., Manaka, T., Ashihara, K., Shoda, M., Hagiwara, N.: Correlation between left atrial appendage morphology and flow velocity in patients with paroxysmal atrial fibrillation, *European Heart Journal – Cardiovascular Imaging*, **17** (2016) 1, 59-66, <https://doi.org/10.1093/ehjci/jev089>
- [11] Goldman, M. E.; Pearce, L. A., Hart, R. G., Zabalgoitia, M., Asinger, R. W., Safford, R., Halperin, J. L.: Pathophysiologic correlates of thromboembolism in nonvalvular atrial fibrillation: I. Reduced flow velocity in the left atrial appendage (The Stroke Prevention in Atrial Fibrillation [SPAF-III] study), *Journal of the American Society of Echocardiography*, **12** (1999) 12, 1080-1087, [https://doi.org/10.1016/S0894-7317\(99\)90151-9](https://doi.org/10.1016/S0894-7317(99)90151-9)
- [12] Habijan, M.; Leventić, H., Galić, I., Babin, D.: Whole Heart Segmentation from CT Images Using 3D UNet Architecture, *26th International Conference on Systems, Signals and Image Processing (IWSSIP 2019)*, S. Rimac Drlje, D. Žagar, I. Galić, G. Martinović, D. Vranješ, M. Habijan, 121-126, 9781728132532, Osijek, Hrvatska, lipanj 2019, IEEE, Osijek (2019)
- [13] Habijan, M.; Leventić, H., Galić, I., Babin, D.: Neural Network based Whole Heart Segmentation from 3D CT Images, *International Journal of Electrical and Computer Engineering Systems*, **11** (2020) 1, 25-31, <https://doi.org/10.32985/ijeces.11.1.3>
- [14] Ronneberger, O.; Fischer, P., Brox, T.: UNet: Convolutional Networks for Biomedical Image Segmentation, *Lecture Notes in Computer Science*, **9351** (2015), 234-241, https://doi.org/10.1007/978-3-319-24574-4_28
- [15] Lin, G.; Milan, A., Shen, C., Reid, I.: RefineNet: MultiPath Refinement Networks for HighResolution Semantic Segmentation, *arXiv preprint arXiv:1611.06612* (2016) <https://doi.org/10.48550/arXiv.1611.06612>

- [16] Huang, G.; Liu, Z., van der Maaten, L., Weinberger, K.Q.: Densely Connected Convolutional Networks, *2017 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2017)*, -, 2261–2269, 978-1-5386-0457-1, Honolulu, HI, SAD, 21.–26. srpanj 2017, Institute of Electrical and Electronics Engineers (IEEE), Honolulu, (2017)
- [17] He, K.; Gkioxari, G., Dollár, P., Girshick, R.: Mask RCNN, *arXiv preprint arXiv:1706.05587* (2017), <https://doi.org/10.48550/arXiv.1706.05587>
- [18] Jha, D.; Smedsrud, P.H., Riegler, M.A., Johansen, D., de Lange, T., Halvorsen, P., Johansen, H.D.: ResUNet++: An Advanced Architecture for Medical Image Segmentation, *2019 IEEE International Symposium on Multimedia (ISM 2019)*, -, str. 225-230, 978-1-7281-5606-4, San Diego, CA, SAD, 9.–11. prosinac 2019, Institute of Electrical and Electronics Engineers (IEEE), San Diego, (2019)
- [19] Hu, J.; Shen, L., Albanie, S., Sun, G., Wu, E.: Squeeze and Excitation Networks, *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2018)*, -, str. 7132-7141, 9781538664216, Salt Lake City, UT, SAD, lipanj 2018, IEEE, (2018)
- [20] Habijan, M.; Galić, I., Romić, K., Leventić, H.: ABResUNet++: Improving Multiple Cardiovascular Structure Segmentation from Computed Tomography Angiography Images, *Applied Sciences*, **12** (2022) 6, 3024, <https://doi.org/10.3390/app12063024>
- [21] Habijan, M.; Galić, I., Leventić, H., Romić, K., Babin, D.: Segmentation and Quantification of Bi-Ventricles and Myocardium Using 3D SERes-U-Net, *28th International Conference on Systems, Signals and Image Processing (IWSSIP 2021)*, G. Rozinaj, R. Vargic, Communications in Computer and Information Science (CCIS, vol. 1527), 3-14, 978-3-030-96877-9, Bratislava, Slovačka, lipanj 2021 (objavljeno 2022), Springer, Cham, (2022)
- [22] Benčević, M.; Habijan, M., Galić, I., Pizurica, A.: Self Supervised Learning as a Means to Reduce the Need for Labeled Data in Medical Image Analysis, *30th European Signal Processing Conference (EUSIPCO 2022)*, -, str. 1328-1332, 978-9082797091, Beograd, Srbija, rujan 2022, Institute of Electrical and Electronics Engineers (IEEE), Beograd, (2022)
- [23] Ren, S.; He, K., Girshick, R., Sun, J.: Faster RCNN: Towards RealTime Object Detection with Region Proposal Networks, *29th International Conference on Neural Information Processing Systems (NIPS 2015)*, C. Cortes, str. 91-99, 9781510825024, Montreal, Kanada, prosinac 2015, Neural Information Processing Systems Foundation, Inc./Curran Associates (2015)
- [24] <https://simclr.github.io/>, *Pristupljeno*: 2022-08-25
- [25] Leventić, H.; Babin, D., Velicki, L., Devos, D., Galić, I., Zlokolica, V., Romić, K., Pižurica, A.: Left atrial appendage segmentation from 3D CCTA images for occluder placement procedure, *Computers in Biology and Medicine*, **104** (2019) 163-174, <https://doi.org/10.1016/j.compbiomed.2018.11.006>
- [26] Habijan, M.; Babin, D., Galić, I., Leventić, H., Velicki, L., Čanković, M.: Centerline Tracking of the Single Coronary Artery from X-ray Angiograms, *2020 International Symposium ELMAR*, Muštra, M.; Vuković, J.; Zovko-Cihlar, B., str. 117-121, 978-1-7281-5973-7, Zadar, Hrvatska, rujan 2020, Institute of Electrical and Electronics Engineers (IEEE), Zadar, (2020)
- [27] Sacks, H. S.; Fain, J. N.: Human epicardial adipose tissue: a review, *American Heart Journal*, **153** (2007) 907-917, <https://doi.org/10.1016/j.ahj.2007.03.019>

- [28] Marwan, M.; Achenbach, S.: Quantification of epicardial fat by computed tomography: why, when and how?, *Journal of Cardiovascular Computed Tomography*, **7** (2013) 1, 3-10, <https://doi.org/10.1016/j.jcct.2013.01.002>
- [29] Chenn, O.; Ahmad, I., Hua, B. et al.: Correlation of pericardial and mediastinal fat with coronary artery disease, metabolic syndrome, and cardiac risk factors, *Journal of Cardiovascular Magnetic Resonance*, **11** (2009), Suppl 1.O16, <https://doi.org/10.1186/1532-429X-11-S1-O16>
- [30] Gorter, P. M.; et al.: Relation of epicardial fat, *American Journal of Cardiology*, **102** (2008) 4, 380-385, <https://doi.org/10.1016/j.amjcard.2008.04.012>
- [31] He, K.; Zhang, X., Ren, S., Sun, J.: *Deep Residual Learning*, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016), -, str. 770-778, 9781467388511, Las Vegas, NV, SAD, lipanj 2016, Institute of Electrical and Electronics Engineers (IEEE), Las Vegas, (2016)
- [32] Habijan, M.; Galić, I., Leventić, H., Romić, K.: Whole Heart Segmentation Using 3D FMPre-ResNet Encoder–Decoder Based Architecture with Variational Autoencoder Regularization, *Applied Sciences*, **11** (2021) 9, 3912, <https://doi.org/10.3390/app11093912>
- [33] Warboys, C. M.; Amini, N., de Luca, A., Evans, P. C.: The role of blood flow in determining the sites of atherosclerotic plaques, *F1000 Medicine Reports*, **3** (2011) 5, –, <https://doi.org/10.3410/M3-5>
- [34] Pleouras, D. S.; Sakellarios, A. I., Tsompou, P., Aggelousis, G., Parcharidis, G., Fytanidis, D., Kanaris, C., Vavourakis, V., Pneumaticos, S. G.: Simulation of Atherosclerotic Plaque Growth Using Computational Biomechanics and PatientSpecific Data, *Scientific Reports*, **10** (2020) 17409, <https://doi.org/10.1038/s41598-020-74583-y>
- [35] Zhong, L.; Zhang, J. M., Su, B., Tan, R. S., Allen, J. C., Kassab, G. S.: Application of Patient-Specific Computational Fluid Dynamics in Coronary and Intra-Cardiac Flow Simulations: Challenges and Opportunities, *Frontiers in Physiology*, **9** (2018) 742, <https://doi.org/10.3389/fphys.2018.00742>
- [36] Jankowski, P.; Czarnecka, D.: Pulse Pressure, Blood Flow, and Atherosclerosis, *American Journal of Hypertension*, **25** (2012) 10, 1040-1041, <https://doi.org/10.1038/ajh.2012.117>

Određivanje parametara pougljičavanja čelika primjenom neuronske mreže

Božidar Matijević¹, Dragutin Lisjak¹

¹Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje, Ivana Lučića 5, 10000 Zagreb, bozidar.matijevic@fsb.hr

Sažetak: U ovom radu prikazana je primjena neuronskih mreža za izračun zakonitosti složenih procesa, među koje se ubrajaju i procesi difuzije ugljika pri pougljičavanju čelika. Prikazani su empirijski i matematički modeli procesa pougljičavanja Carbomaag, koji se primjenjuju u praksi za određivanje tehnoloških parametara pougljičavanja kojima se postiže zahtijevani profil koncentracije ugljika u pougljičenom sloju. U radu se posebna pozornost posvećuje usporedbi matematičkog modela (MM) i modela neuronske mreže (NNM) te empirijskog modela (EM) s obzirom na vrijeme potrebno za postizanje male i velike dubine cementiranja. Rezultati empirijskog modela pougljičavanja korišteni su kao skup podataka za treniranje neuronske mreže te su uspoređeni s rezultatima računalne simulacije matematičkog modela. Usporedba rezultata dobivenih pri malim i velikim dubinama pougljičavanja pokazuje da model neuronske mreže znatno bolje aproksimira empirijski model nego matematički model. Pretpostavlja se da bi provedba većeg broja eksperimenata i ponovno treniranje neuronske mreže s novim skupovima eksperimentalnih podataka dovelo do još kvalitetnijih rješenja. Time bi se izbjegli nedostaci teorijskih modela, odnosno matematičkih modela.

Ključne riječi: Carbomaag, pougljičavanje, cementiranje, neuronske mreže

1. Uvod

Osnovni zahtjevi za postupak cementiranja čelika su sljedeći:

- a) površinska tvrdoća: 60 - 64 HRC,
- b) efektivna dubina pougljičenog sloja: 0,1 - 3 mm.

Osim toga, često se postavljaju i zahtjevi vezani uz mikrostrukturu (npr. veličinu zrna) ili mehanička svojstva (npr. žilavost jezgre). Kako bi se zadovoljili osnovni zahtjevi tijekom pougljičavanja mora se postići određeni profil koncentracije ugljika u površinskom sloju. Koncentracija ugljika u površinskom sloju treba biti u rasponu od

0,6 - 0,8 %C, dok na traženoj efektivnoj dubini pougljičavanja (E_{dp}) treba iznositi približno 0,35 %C. Time se nakon kaljenja omogućuje postizanje tvrdoće od 550 HV1. Na profil koncentracije ugljika u pougljičenom sloju utječu sljedeći čimbenici: vrsta plinske atmosfere, potencijal ugljika plinske atmosfere, temperatura pougljičavanja, početna koncentracija ugljika u čeliku, koncentracija legirnih elemenata te vrijeme pougljičavanja.


Za određivanje tehnoloških parametara pougljičavanja, prvenstveno potencijala ugljika (C_p) i potrebnog vremena pougljičavanja (t) kojim se postiže zahtijevani profil koncentracije ugljika u pougljičenom sloju, koriste se različiti modeli. Ti se modeli svrstavaju u dvije glavne skupine, empirijski modeli (EM) i matematički modeli (MM). Empirijski modeli nisu univerzalni jer su ograničeni na usko područje primjene, što predstavlja njihov glavni nedostatak. Matematički modeli s druge strane, daju rješenja koja su univerzalnija po svojoj prirodi jer se temelje na temeljnim fizikalno-kemijskim zakonima procesa pougljičavanja. Njihov glavni nedostatak jest to što nije moguće predvidjeti sve međudjelovanja čimbenika uključenih u proces pougljičavanja.

Nedostaci empirijskih i matematičkih modela bili su glavni razlog za istraživanje i primjenu neuronskih mreža u procesu pougljičavanja čelika. Empirijski i matematički modeli korišteni za učenje i testiranje neuronske mreže opisani su u sljedećim poglavljima.

2. Empirijski model (EM)

Na temelju prethodno provedenih eksperimenata utvrđen je odnos između vremena pougljičavanja i efektivne dubine sloja u čeliku s traženim udjelom ugljika u površinskim slojevima. Utvrđeni odnos je eksponencijalan i vrijedi za određene parametre procesa kao što su: plinska atmosfera, C-potencijal plinske atmosfere, temperatura pougljičavanja i kemijski sastav čelika. Na taj način svaki empirijski model ograničen je na usko područje primjene. To znači da se odnosi u procesu pougljičavanja moraju određivati u različitim plinskim atmosferama, pri konstantnim C potencijalima i temperaturama pougljičavanja za svaku vrstu čelika (ugljične i brojne legirane čelike za cementiranje). Dubina pougljičenog sloja za postupak "Carbomaag" [1] približno je proporcionalna kvadratnom korijenu vremena pougljičavanja (Slika 1):

$$K = \frac{E_{dp}}{\sqrt{t}}, \frac{mm}{\sqrt{t}} \quad (1)$$



Slika 1: Ovisnost faktora K o temperaturi [1]

odnosno vrijeme pougljičavanja:

$$t = \left(\frac{E_{dp}}{K} \right)^2, h \quad (2)$$


gdje su: K - faktor proporcionalnosti u $\frac{\text{mm}}{\sqrt{t}}$, E_{dp} - efektivna dubina pougljičavanja u mm, a t - vrijeme pougljičavanja u satima h. Primjeri vrijednosti koeficijenta K dobivenih empirijskim izračunom prema spomenutim zakonitostima u praksi za različite vrste čelika navedeni su u Tablici 1.

Tablica 1: Prikaz dobivenih koeficijenta proporcionalnosti i vremena t [>1] za različite kvalitete čelika

DIN 17006	%C	%Si	%Mn	%Cr	%Ni	E_{dp} , mm	T , $^{\circ}\text{C}$	C_p , %	K , $\frac{\text{mm}}{\sqrt{t}}$	t , min
C10	0,10	0,25	0,45	0,00	0,00	0,1 - 0,4	880	1,20	0,375	4 - 68
						0,5 - 0,7	900			
C15	0,15	0,25	0,45	0,00	0,00	0,8 - 1,0	920	1,15	0,425	83 - 163
14NiCr14	0,14	0,40	0,55	1,50	3,25	1,1 - 3,0	940	1,15	0,475	170 - 266
15NiCr6	0,15	0,28	0,50	1,55	1,55	0,5 - 0,7	900	0,90	0,450	74 - 145
18CrNi8	0,18	0,28	0,50	1,95	1,95	0,8 - 1,0	920	0,90	0,500	154 - 240
16MnCr5	0,17	0,28	1,15	0,95	0,00	0,1 - 0,7	880	1,00	0,40	4 - 184
						0,5 - 0,7	900			
20MnCr5	0,20	0,28	1,25	1,15	0,00	0,8 - 1,0	920	1,00	0,425	53 - 163

3. Matematički model (MM)

Do sada je objavljen niz radova koji se bave problematikom matematičkog modeliranja procesa pougljičavanja, a neki od njih višestruko su citirani su u literaturi [2-7]. U ovom radu za potrebe usporedbe s modelom neuronske mreže (NNM) preuzet je matematički model (MM) opisan u radovima [3,4]. Proces pougljičavanja odvija se pri konstantnim temperaturama, umjesto kemijskog potencijala ugljika uvodi se njegova termodinamička aktivnost a_C . Pojam termodinamičke aktivnosti ugljika uvodi se zato što austenit nije idealna čvrsta otopina, odnosno aktivnost ugljika nije linearno proporcionalna koncentraciji tj. sadržaju ugljika u čeliku. Slika 2a prikazuje kvantitativni odnos između koncentracije i termodinamičke aktivnosti ugljika pri konstantnoj temperaturi za binarni sustav Fe–C (nelegirani čelici). Standardno stanje ($a_C = 1,0$) je grafit, što odgovara liniji S' - E' u dijagramu ravnotežnog stanja.



Slika 2: a) Odnos između termodinamičke aktivnosti i koncentracije ugljika u austenitu, b) shematski prikaz matematičkog modela (MM) pougljičavanja [3,4]

Većina čelika za cementiranje sadrži legirajuće elemente koji na različite načine utječu na termodinamičku aktivnost ugljika u austenitu. Na primjer, Si i Ni povećavaju termodinamičku aktivnost ugljika u austenitu, dok Cr, Mo i Co smanjuju termodinamičku aktivnost ugljika u austenitu. Utjecaj legirajućih elemenata može se izračunati primjenom poznatih koeficijenata međudjelovanja. Na taj način moguće je odrediti odnos između koncentracije ugljika u binarnom sustavu Fe–C i koncentracije ugljika u legiranom čeliku pri konstantnoj vrijednosti termodinamičke aktivnosti ugljika. Uzimajući u obzir navedeni koncept, matematički model (MM) temelji se na zakonima raspodjele aktivnosti ugljika, Slika 2b.

Drugi Fickov zakon definira vremensku raspodjelu termodinamičke aktivnosti ugljika u čeliku:

$$\frac{\partial a_C}{\partial t} = D_C^a \frac{\partial^2 a_C}{\partial x^2} \quad (3)$$

Koeficijent difuzije ugljika vrijedi za gradijent aktivnosti ugljika. Izračunava se primjenom sljedećih rubnih uvjeta:

- (a) Prvi rubni uvjet odnosi se na promjenu aktivnosti ugljika na granici faza tj. plinske atmosfere i površine čelika:

$$K(a_C^p - a_C^{x=0}) \text{ za } x = 0 \quad (4)$$

- (b) Drugi rubni uvjet odnosi se na proces difuzije koji se odvija u polu beskonačnom tijelu:

$$a_C^{x,t} = a_C^0 \text{ za } x = \infty. \quad (5)$$

Ako se proces odvija u skladu sa zakonima raspodjele termodinamičke aktivnosti ugljika, koeficijenti K i ne ovise o veličini termodinamičke aktivnosti ugljika. To znači da se njihove vrijednosti ne mijenjaju tijekom procesa. Time se rješenje modela znatno pojednostavljuje. Eksplicitno rješenje daje raspodjelu termodinamičke aktivnosti ugljika, uzimajući u obzir sve parametre:

$$a_C^{x,t} = a_C^0 + (a_C^p - a_C^0) \cdot \left(\operatorname{erfc} \frac{x}{2\sqrt{D_C^a \cdot t}} - \exp \frac{(K \cdot x + K^2 \cdot t)}{D_C^a} \cdot \operatorname{erfc} \left(\frac{x}{2\sqrt{D_C^a \cdot t}} + K \sqrt{\frac{t}{D_C^a}} \right) \right). \quad (6)$$

U sljedećem koraku rješenje se izražava kao profil koncentracije ugljika u pougljičenom sloju, budući da se te vrijednosti zahtijevaju i kontroliraju nakon pougljičavanja. Koriste se već poznati odnosi između termodinamičke aktivnosti i koncentracije ugljika, odnosno molarnog udjela ugljika (N_C):

$$\log a_C = \frac{2295}{T} - 0,863 + 0,15 \%C + \log N_C \quad (7)$$

$$N_C = \frac{\frac{\%C}{12,01}}{\frac{\%C}{12,01} + \frac{100 - \%C}{55,85}}$$

Za legirane čelike također se koristi Gunnarsonova jednačba [6], koja se odnosi na utjecaj legirajućih elemenata:

$$\log\left(\frac{c^{\text{Fe-C}}}{c^{\text{Leg}}}\right)_{ac} = 0,055 \% \text{Si} - 0,013 \% \text{Mn} - 0,04 \% \text{Cr} + 0,014 \% \text{Ni} \quad (8)$$


Na taj način može se izračunati teorijski profil koncentracije ugljika za bilo koju vrstu čelika pri određenim uvjetima pougljičavanja.

4. Model neuronske mreže (NNM)

Umjetne neuronske mreže (ANN) nadahnute su biološkim živčanim sustavom i njegovom sposobnošću učenja na temelju primjera [8, 11]. Umjesto da slijede skup jasno definiranih pravila koje specificira korisnik, neuronske mreže uče prema unutarnjim pravilima dobivenima iz prezentiranih uzoraka. Najčešće korištena arhitektura umjetne neuronske mreže je višeslojna neuronska mreža s povratnim širenjem pogreške (engl. *backpropagation*). Algoritam povratnog širenja pogreške razvijen je generalizacijom Widrow-Hoffovog pravila učenja na višeslojne mreže i nelinearne diferencijabilne prijenosne funkcije [9]. Ulazni vektori i pripadajući ciljni vektori koriste se za treniranje mreže sve dok ona ne bude sposobna aproksimirati funkciju, odnosno povezati ulazne vektore s odgovarajućim izlaznim vektorima. Standardna višeslojna neuronska mreža s povratnim širenjem pogreške je algoritam gradijentnog spusta, kao i Widrow-Hoffovo pravilo učenja, pri čemu se težine mreže pomiču u smjeru negativnog gradijenta funkcije pogreške. Pojam “povratno širenje” odnosi se na način izračuna gradijenta u nelinearnim višeslojnim mrežama. Višeslojne neuronske mreže s povratnim širenjem pogreške često imaju jedan ili više skrivenih slojeva s sigmoidnim neuronima, nakon kojih slijedi izlazni sloj s linearnim neuronima. Višestruki slojevi neurona s nelinearnim prijenosnim funkcijama omogućuju mreži učenje nelinearnih i linearnih odnosa između ulaznih i izlaznih vektora. Postoje brojne varijacije osnovnog algoritma temeljene na drugim standardnim optimizacijskim tehnikama, poput metode konjugiranih gradijenata i Newtonovih metoda. U ovom radu korišten je *feedforward backpropagation* algoritam treniranja, osmišljen za minimizaciju srednje kvadratne pogreške (MSE) između stvarnog (procijenjenog) izlaza (a, A) i željenog (ciljnog) izlaza (d, T). Slika 3. prikazuje princip *feedforward backpropagation* algoritma treniranja a potrebni parametari za učenje neuronske mreže navedi su u Tablici 2 i slici 4.

Osnovni algoritam učenja neuronske mreže može se sažeti na sljedeće korake:

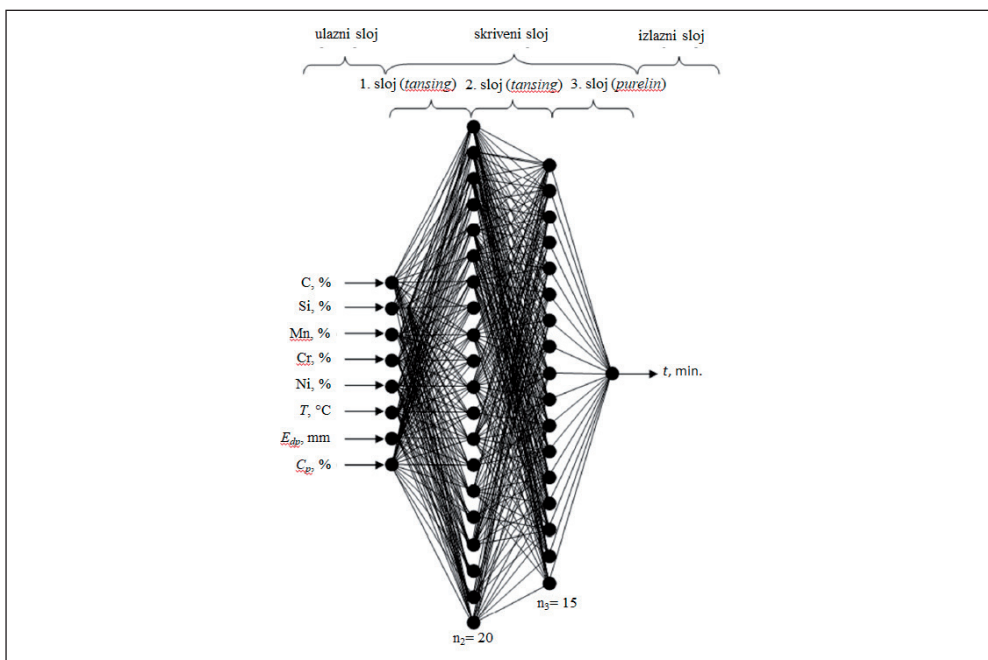
Korak 1. Postavljanje inicijalnih težina V_{ij} and W_{jk} .



Parametar	Vrijednost
Cilj performansi	0,0001
Brzina učenja	0,01
Omjer povećanja brzine učenja	1,05
Omjer smanjenja brzine učenja	0,5
Najveće povećanje performansi	1,04
Najmanje smanjenje performansi	$1e^{-10}$
Konstanta momenta	0,9
Broj slojeva	3
Broj neurona	20-15-1
Funkcija prijenosa	Tansig & tansig & purelin
Broj epoha treniranja	15.000

Slika 3: Princip *feedforward* backpropagation algoritma treniranja

Tablica 2: Parametri učenja neuronske mreže



Slika 4: Pojednostavljeni model korištene neuronske mreže

Korak 2. Izračunati izlaze svih neurona sloj po sloj, počevši od ulaznog sloja, kako je prikazano u nastavku:

$$net_j = \sum_{i=1}^I V_{ij} X_i, \quad j = 1, 2, 3, \dots, J - 1, \quad i = 1, 2, 3, \dots, I \tag{9}$$

$$Y_j = f(\text{net}_j) \quad (10)$$

$$\text{net}_k = \sum_{j=1}^J W_{jk} Y_j, \quad j = 1, 2, 3, \dots, J - 1, \quad k = 1, 2, 3, \dots, K \quad (11)$$

$$Y_k = f(\text{net}_k) \quad (12)$$

Gdje su:

- V_{ij} - težina između ulaznog sloja i skrivenog sloja,
- W_{jk} - težina između skrivenog sloja i izlaznog sloja,
- X_i - ulazni signali (vrijednosti kemijskog sastava),
- i - broj neurona ulaznog sloja,
- I - broj ulaza neurona j u skrivenom sloju,
- Y_j - izlaz skrivenih neurona,
- j - broj neurona skrivenog sloja,
- J - broj ulaza neurona k u izlaznom sloju,
- Y_k - izlazni signali (masa eluiranih iona po gramu uzorka),
- k - broj neurona izlaznog sloja.

U slučaju sigmoidne prijenosne funkcije skrivenog sloja, primjenjuje se sljedeća jednadžba:

$$f(x) = \frac{2}{1+e^{-x}} \quad (13)$$

Korak 3. Izračunati pogrešku sustava E:

$$E = \frac{1}{2} \sum_{k=1}^K (d_k - a_k)^2 \quad (14)$$

gdje K predstavlja ukupan broj uzoraka, d_k željene izlaze (eksperimentalne vrijednosti), a_k stvarne izlaze.

Korak 4. Ako je pogreška E dovoljno mala ili je broj iteracija prevelik, zaustaviti proces učenja.

Korak 5. Izračunati pogreške učenja za svaki neuron sloj po sloj:

$$\delta_k = (d_k - a_k) f'(\text{net}_k), \quad k = 1, 2, \dots, K \quad (15)$$

$$\delta_k = \sum_{j=1}^K W_{jk} \delta_j f'(\text{net}_j), \quad j = 1, 2, \dots, J-1, k = 1, 2, \dots, K. \quad (16)$$

Korak 6. Ažurirati težine funkcije pogreške E.

$$W_{jk}(n+1) = W_{jk}(n) + l_r \delta_k Y_j + \alpha(W_{jk}(n) - W_{jk}(n-1)) \quad (17)$$

$$V_{ji}(n+1) = V_{ji}(n) + l_r \delta_j X_{ji} + \alpha(V_{ji}(n) - V_{ji}(n-1)) \quad (18)$$

gdje jesu l_r - koeficijent učenja, α - momentum, n - broj tekuće iteracije.

Korak 7. Ponoviti postupak od Koraka 2.

Za procjenu učinkovitosti algoritma učenja u rješavanju zadanog zadatka definiran je indeks učinkovitosti kao što je prikazano na slici 5. Indeks učinkovitosti omogućuje usporedbu primijenjenog algoritma neuronske mreže s drugim algoritmima učenja. Najčešći indeks učinkovitosti je normalizirana srednja kvadratna pogreška (NRMSE) [7]:

$$NRMSE = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - a_n)^2}{N}}}{\sigma_{d_n}} \quad (19)$$

$$\sigma_{d_n} = \sqrt{\frac{1}{N} \sum_{n=1}^N (d_n - \bar{d})^2} \quad (20)$$

$$\bar{d} = \frac{1}{N} \sum_{n=1}^N d_n, \quad (21)$$

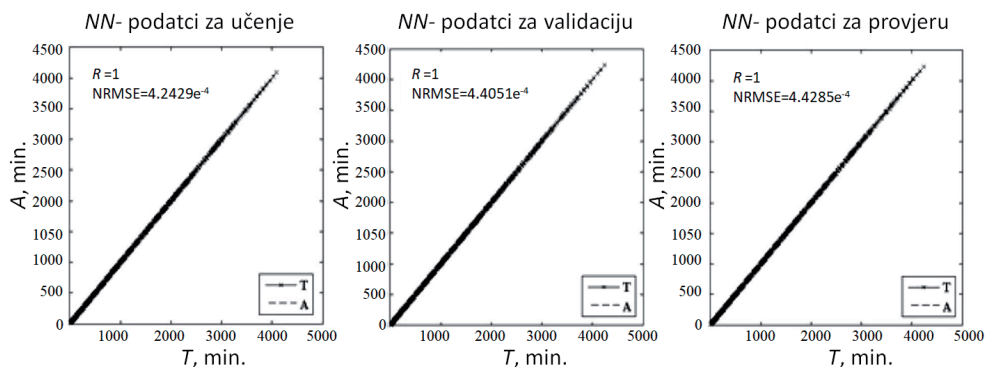
gdje su:

N - ukupan broj uzoraka,

d_n - željeni (*target*, T) izlaz,

a_n - stvarni (procijenjeni, A) izlaz,

σ_{d_n} - standardna devijacija.




Slika 5: Pokazatelj uspješnosti (NRMSE) trenirane neuronske mreže

Tablica 3: Usporedba vrijednosti vremena pougljičava dobivenih modelom EM- MM- NM

Oznaka čelika	Parametri pougljičavanja			K min/h	Vrijeme, min				
	T, °C	E_{dp} , mm	C_p , %		EM	MM	ΔMM , %	NN	ΔNN , %
C10	880	0,10	1,20	0,3511	5	9	+80,0	5	0,0
		0,20	1,20	0,3511	19	25	+316	20	+5,3
	900	0,50	1,15	0,4109	89	93	+45	89	0,0
		0,55	1,15	0,4109	108	110	+19	107	-0,9
	920	0,80	1,15	0,4744	171	161	-5,8	171	0,0
		0,85	1,15	0,4744	193	180	-6,7	193	0,0
940	1,10	1,10	0,5447	245	230	-6,1	245	0,0	
	1,50	1,10	0,5447	455	400	-12,1	455	0,0	
C15	880	0,25	1,20	0,3511	30	32	+67	31	3,3
		0,30	1,20	0,3511	44	43	+23	44	0,0
	900	0,55	1,15	0,4109	108	97	-10,2	107	-0,9
		0,60	1,15	0,4109	128	4	-10,9	128	0,0
	920	0,90	1,15	0,4744	216	176	18,5	216	0,0
		0,95	1,15	0,4744	241	194	-19,5	241	0,0
940	2,00	1,00	0,5447	809	610	-24,6	809	0,0	
	2,50	1,00	0,5447	1264	930	-26,4	1264	0,0	

14NiCr14	880	0,35	1,20	0,3511	60	58	-33	60	0,0
		0,40	1,20	0,3511	78	74	-5,1	78	0,0
	900	0,60	1,15	0,4109	128	117	8,6	128	0,0
		0,65	1,15	0,4109	150	135	-10,0	150	0,0
	920	0,95	1,15	0,4744	241	199	-17,4	241	0,0
		1,00	1,15	0,4744	267	219	18,0	266	-0,4
	940	2,50	1,00	0,5447	1264	997	21,1	1264	0,0
3,00		1,00	0,5447	1760	1416	-19,5	1752	-0,5	
15NiCr6	900	0,50	0,80	0,4109	89	110	+23,6	89	0,0
		0,60	0,80	0,4109	128	153	+19,5	128	0,0
	920	0,80	0,90	0,4744	171	171	0,0	171	0,0
		0,85	0,95	0,4744	193	190	1,6	193	0,0
18NiCr5	900	0,65	0,90	0,4109	150	144	-4,0	150	0,0
		0,70	0,90	0,4109	174	165	-5,2	150	-13,8
	920	0,90	1,00	0,4744	216	178	-17,6	216	0,0
		1,00	1,00	0,4744	267	216	19,1	267	0,0
16MnCr5	880	0,10	1,00	0,3511	5	9	+80,0	4	-20,0
		0,20	1,00	0,3511	19	24	+263	20	+5,3
	900	0,40	1,00	0,4109	57	57	0,0	56	-1,8
		0,50	1,00	0,4109	89	84	-5,6	89	0,0
	920	0,80	0,90	0,4744	171	150	12,3	171	0,0
		0,85	0,90	0,4744	193	170	-1	193	0,0
	940	1,50	1,05	0,5447	455	355	-26,4	455	0,0
2,00		1,05	0,5447	809	574	-29,0	809	0,0	
20MnCr5	880	0,25	1,00	0,3511	30	30	0,0	32	+67
		0,40	1,00	0,3511	78	69	-	8	0,0
	900	0,50	1,00	0,4109	89	16	-14,6	88	-1,1
		0,65	1,00	0,4109	150	122	18,7	151	+0,7
	920	0,90	0,90	0,4744	216	175	-19,0	216	0,0
		1,00	0,90	0,4744	267	213	-20,2	266	-0,4
	940	2,00	1,05	0,5447	809	521	-35,6	808	-0,1
3,00		0,05	0,5447	1760	1131	-35,7	1820	+3,4	



Slika 6: Grafička usporedba procjena vremena pougljičavanja dobivenih EM, MM i NN modelima

5. Eksperimentalni dio

Modeliranje neuronske mreže temelji se na stvarnom empirijskom modelu (EM) opisanom u poglavlju 2. Jednadžba (2) korištena je za izračun vremena cementiranja t za čelike navedene u Tablici 1, za različite kombinacije kemijskog sastava (%C, %Si, %Mn, %Cr, %Ni), temperature T , dubine cementiranja E_{dp} i C-potencijala C_p . Iz jednadžbe (2) proizlazi da je vrijeme cementiranja:

$$t = f[\%C, \%Si, \%Mn, \%Cr, \%Ni, E_{dp}, C_p, K = f(T)], h \quad (22)$$

Faktor proporcionalnosti je funkcija temperature T , a za gornje područje prikazano na Slici 1. iznosi:

$$K = 0.0000000628725T^3 - 0.0001650877376T^2 + 0.1474365831237t - 44.3950366158371 \quad (23)$$

Ulazni skup podataka za treniranje neuronske mreže definiran je u skladu s jednadžbama (22) i (23), prema pravilima navedenima u nastavku:

Pravilo 1: $T = [850 \text{ °C} \cdots 940 \text{ °C}]$ STEP1,

Pravilo 2: $E_{dp} = [0,1 \text{ mm} \cdots 3,0 \text{ mm}]$ STEP 0.05,

Pravilo 3: Ako je $E_{dp} \geq 0,1$ i $E_{dp} \leq 0,4$ onda je $C_p = 1,2\%$

Pravilo 4: Ako je $E_{dp} \geq 0,4$ i $E_{dp} \leq 1,0$ onda je $C_p = 1,15\%$

Pravilo 5: Ako je $E_{dp} \geq 1,0$ i $E_{dp} \leq 3,0$ onda je $C_p = 1,07\%$


Tablica 4: Usporedba trajanja pougljičavanja za parametre $T = 880$ °C, $E_{dp} = 0,2$ do $0,6$ mm, $C_p = 1,0\%$ i $C_p = 1,2\%$

Oznaka čelika	Parametri pougljičavanja			K mm/\sqrt{h}	Vrijeme, min.				
	$T, ^\circ C$	E_{dp} , mm	$C_p, \%$		EM	MM	$\Delta MM, \%$	NN	$\Delta NN, \%$
C10	880	0,2	1,20	0,3511	19	25	+31,6	20	+5,3
		0,3			44	50	+13,6	44	0
		0,4			78	82	+5,1	78	0
		0,5			122	123	+0,8	122	0
		0,6			175	172	-1,7	177	+1,1
14NiCr14		0,2	1,00		23	+21,1	20	+5,3	
		0,3			45	+2,3	45	+2,3	
		0,4			74	-5,1	78	0	
		0,5			111	-9,0	121	-0,8	
		0,6			155	-11,4	172	-1,7	
16MnCr5		0,2	1,00		19	+26,3	20	+5,3	
		0,3			44	+4,5	45	+2,3	
		0,4			78	-1,3	78	0	
		0,5			122	-5,7	122	0	
		0,6			1675	-8,0	177	+1,1	
20MnCr5	0,2	1,00	21	+10,5	21	+10,5			
	0,3		42	-4,5	45	+2,3			
	0,4		69	-11,5	78	0			
	0,5		103	-15,6	122	0			
	0,6		144	-17,7	176	+0,6			

Napomena: EM- vrijednosti trajanja dobivene empirijskim modelom, MM - vrijednosti trajanja dobivene matematičkim modelom, NN - vrijednosti trajanja dobivene modelom neuronske mreže, $\Delta MM = ((MM/EM)-1) \cdot 100$, $\Delta NN = ((NN/EM)-1) \cdot 100$

Ako se primijene prethodno definirana pravila, veličina ulazno-izlaznog skupa podataka za treniranje neuronske mreže iznosi 19.076 zapisa. U radu je provedeno ispitivanje troslojne (20-15-1) *feedforward back propagation* neuronske mreže, čiji je pojednostavljeni model prikazan na Slici 4. Ulazni sloj sastoji se od podataka o kemijskom sastavu čelika (%C, %Si, %Mn, %Cr, %Ni), dubini cementiranja E_{dp} i C-potencijalu C_{pot} . Izlazni sloj sastoji se od podataka o vremenu cementiranja t . Za modeliranje je korišten MathWorks Neural Network Toolbox, verzija 4.0.1 [9], prema čijim su pravilima označeni skriveni slojevi mreže. Kao prijenosna funkcija prvog i drugog skrivenog sloja primijenjena je sigmoidna funkcija (tansig), a za treći

skriveni sloj primijenjena je funkcija linearnog tipa (purelin). Kao funkcija treniranja primijenjena je *traingdx*- metoda gradijentnog spusta s momentom i prilagodljivom brzinom učenja (engl. *backpropagation*). Parametri treniranja neuronske mreže prikazani su u Tablici 2. Zbog relativno velikog broja ulazno- izlaznih podataka za treniranje, bilo je moguće definirati zasebne skupove podataka (50 % za treniranje, 25 % za validaciju, 25 % za testiranje) tijekom procesa treniranja te primijeniti metodu ranog zaustavljanja (engl. *early stopping*) radi poboljšanja sposobnosti generalizacije mreže. Slika 5 daje grafički prikaz pokazatelja uspješnosti treniranih neuronskih mreža za sva tri skupa ulazno-izlaznih podataka. Za prethodno navedene čelike i eksperimentalne temperature cementiranja iz Tablice 1, generirano je 48 zapisa različitih kombinacija vrijednosti dubine cementiranja E_{dp} i C-potencijala C_{pot} slučajnim odabirom. Vrijednosti vremena cementiranja izračunate su primjenom matematičkog modela (MM) i modela neuronske mreže (NNM). Te vrijednosti, odnosno vremena cementiranja dobivena svakim modelom (MM, NNM), kao i njihove razlike (ΔMM %, ΔNN %) u odnosu na empirijski model (EM), prikazane su u Tablici 3. Grafička usporedba točnosti procjene vremena cementiranja (Tablica 3) dobivene empirijskim modelom te matematičkim i NN modelom prikazana je na Slici 6. Slika 7 prikazuje točnost procjena vremena cementiranja za svaki čelik zasebno, uzimajući u obzir dubinu cementiranja E_{dp} navedenu u Tablici 3.



Slika 8: Grafička usporedba procjene vremena pougljičavanja za $T = 880$ °C, $E_{dp} = 0,02 - 0,06$ mm, $C_p = 1,0$ % i $C_p = 1,2$ %

6. Zaključak

Osnovni cilj ovog rada jest istraživanje i modeliranje strukture neuronske mreže koja bi s dovoljnom točnošću procjenjivala potrebno vrijeme cementiranja za različite kemijske sastave čelika i različite parametre procesa cementiranja, kako bi se izbjeglo provođenje dodatnih eksperimenata za određivanje tih parametara. Istražena je mogućnost primjene neuronske mreže za procjenu vremena pougljičavanja. Provedena je usporedba dobivenih rezultata s empirijskim (EM) i matematičkim modelom (MM). Ključ uspješne procjene ili aproksimacije određenih podataka pomoću neuronske mreže jest njezina sposobnost aproksimacije podataka koji nisu korišteni kao parametri treniranja, odnosno podataka na kojima mreža nije trenirana. Modelirana (20-15-1) *feedforward backpropagation* neuronska mreža sa strukturom prikazanom na Slici 4 i parametrima navedenima u Tablici 2 pokazala je vrlo dobru aproksimaciju skupa podataka za treniranje (50 % podataka, $R = 1$, $\text{NRMSE} = 4,2429\text{e}-004$) te validacijskog skupa podataka (25 % podataka, $R = 1$, $\text{NRMSE} = 4,4051\text{e}-004$), koji su korišteni tijekom procesa treniranja neuronske mreže. Vrlo dobra aproksimacija vremena pougljičavanja dobivena je i na trećem, testnom skupu podataka, tzv. "nikad viđenim" podacima (25 % podataka, $R = 1$, $\text{NRMSE} = 4,4385\text{e}-004$). Na temelju empirijskih podataka iz Tablice 1, generirani su podaci o potrebnim vremenima pougljičavanja i prikazani u Tablici 3. te su uspoređeni s rezultatima procijenjenog vremena (t) dobivenim matematičkim modelom (MM, stupac 7) i numeričkim NN modelom (stupac 9) te s vrijednostima dobivenim empirijskim modelom (EM, stupac 6). Stupci 8 i 10 prikazuju odstupanja matematičkog i NN modela izražena u postocima ($\Delta\text{MM} \%$ i $\Delta\text{NN} \%$) u odnosu na EM. Može se uočiti da je odstupanje NN modela znatno manje (uglavnom ispod $\pm 10\%$) nego odstupanje MM modela (uglavnom iznad $\pm 10\%$). Odstupanja u procjeni vremena pougljičavanja grafički su prikazana na Slici 6, gdje je jasno vidljivo da su NN model i EM u dobroj suglasnosti, dok MM to nije. Iz Tablice 3 može se uočiti da MM pokazuje znatno veća odstupanja od EM-a u vrijednostima vremena pougljičavanja s porastom dubine pougljičavanja E_{dp} ispitivanih čelika. Na temelju podataka iz Tablice 3, odstupanja u vremenu pougljičavanja za svaki tip čelika prikazana su na Slici 7. Može se uočiti da se veća odstupanja MM modela javljaju pri dubini pougljičavanja $E_{dp} > 0,06$ mm, dok su odstupanja u rasponu dubina $0,2 \text{ mm} < E_{dp} < 0,6$ mm (približno) manjeg stupnja. Rezultati i usporedba procjene vremena pougljičavanja za raspon $0,2 \text{ mm} < E_{dp} < 0,6$ mm prikazani su u Tablici 4 i na Slici 8. Prikazani rezultati odnose se na čelike C10, 14NiCr14, 16MnCr5 i 20MnCr5. Ti čelici, kako je prikazano na Slici 7, pokazuju manji stupanj odstupanja u navedenom rasponu dubina pougljičavanja. U slučaju manjih dubina pougljičavanja MM također pokazuje značajna odstupanja od EM-a, ali ne u tolikoj mjeri kao kod većih dubina pougljičavanja. NN model se također pokazao boljim modelom za procjenu, odnosno aproksimaciju potrebnog vremena pougljičavanja u slučaju manjih dubina pougljičavanja. Autori smatraju da se odstupanje u procjeni vremena pougljičavanja do $\pm 10\%$ u odnosu na empirijsku procjenu može smatrati prihvatljivim. Prema rezultatima navedenima u Tablici 3, prosječno odstupanje MM modela u procjeni

vremena pougljičavanja pri većim dubinama pougljičavanja prelazi $\pm 10\%$ u odnosu na EM, dok je za manje dubine (Tablica 4) prosječno odstupanje približno $\pm 10\%$. S odstupanjima znatno ispod $\pm 10\%$, NN model se pokazao boljim modelom i u prvom i u drugom slučaju razmatranih dubina pougljičavanja. Autori smatraju da se nadmoć NN modela nad MM modelom može objasniti nedostatnošću Gunnarsonove formule (jednadžba 8). Analiza MM modela pokazala je da Gunnarsonova formula, koja uzima u obzir utjecaj legiranih elemenata, ima najveći utjecaj na procjenu vremena pougljičavanja. Očito je da su koeficijenti korišteni u Gunnarsonovoj formuli dobiveni eksperimentalno, na ograničenom skupu podataka, koji nije bio dovoljno opsežan da obuhvati sve “nevidljive” interakcije koje se javljaju tijekom procesa pougljičavanja. Bolja procjena vremena pougljičavanja dobivena pomoću NN modela za veće i manje dubine pougljičavanja rezultat je činjenice da NN model bolje obuhvaća “nevidljive” interakcije procesa pougljičavanja.

Te su interakcije zapravo integrirane u empirijsku funkciju $F = f(T)$ danu u jednadžbi (23). Zaključno, sve bolji rezultati u procjeni vremena pougljičavanja primjenom NN modela postići će se uključivanjem sve većeg broja eksperimentalnih rezultata, dobivenih na čelicima različitog sastava i pri različitim parametrima pougljičavanja, u proces treniranja neuronske mreže.

8. Literatura

- [1] Wyss, U.: *Principes De La Cementation Gazeuse, Härterei Technik*, Lausanne, 1982
- [2] Paviosoglou, J.: Das Erstellen von mathematischen Modellen und die Anwendung derartiger Modelle bei der Gasaufkohlung, *Härterei-Technische Mitteilungen*, **32** (1977) 4, 169-176 i 32, 215-223
- [3] Stupnišek, M.; Koroušić, B., Dobovišek, B.: Beitrag zur Modellieren des Gasaufkohlungsprozesses von Stahl, *Proceedings of the 3rd Int. Congress on Heat Treatment of Materials*, Shanghai, November 7-11, 1983. Session 7., 23-28., The Camenon Press Limited, London, 1984
- [4] Stupnišek, M.; Virag, Z.: Novi matematički model plinskog pougljičavanja čelika, *Zbornik radova, Faculty of Mechanical Engineering and Naval Architecture*, Zagreb, 1982, 85-99
- [5] Wüning, J.: Processrechner zur Steuerung des Diffusionsverlaufs während der Aufkohlung: *Zeitschrift für wirtschaftliche Fertigung*, **77** (1982) 9, 424-426
- [6] Hiremath, P.; Gurumurthy, B. M., Shivaprakash, Y. M., Naik, N., Jain, P., Kowshik, S., Murthy, B. R. N.: Elevating carbon diffusion: deciphering the interplay of alloy composition and carburizing treatment in low carbon steels, *Cogent Engineering*, **11** (2024) 1, 2345847, <https://doi.org/10.1080/23311916.2024.2345847>
- [7] Maisuradze, M. V.; V. Yudin, Y. V., Kuklina, A. A., Abakumov, K. V.: Methodology for Predicting the Results of Carburizing of Alloy Steels, *Steel in Translation*, **55** (2025) 10, 1041-1049, <https://doi.org/10.3103/S096709122570192X>

-
- [8] Yingtao, Zh.; Zirong, T., Lei, H., Mahdipanah, M.H., Yanjie, W.: Real-time prediction method of carbon concentration in carburized steel based on a BP neuralnetwork, *Heat Treatment and Surface Engineering*, **6** (2024) 1, 2331865, <https://doi.org/10.1080/25787616.2024.2350184>
- [9] Golden, R. M.: *Mathematical Methods for Neural Networks Analysis and Design*, A Bradford Book; The MIT Press: Massachusetts, 1996., <https://api.semanticscholar.org/CorpusID:62133699>, *Pristupljeno*: 2026-03-11
- [10] Raissi, M.; Perdikaris, P., Karniadakis, G.E.: Physics-informed neural networks, A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, **378** (2019) 686-707, <https://doi.org/10.1016/j.jcp.2018.10.045>
- [11] The MathWorks, Neural Network Toolbox, Release 4.0.1, 2003, www.mathworks.com, *Pristupljeno*: 2007-09-01
- [12] Hagan, T. M.; Demuth, B. H., Beale, H. M.: *Neural Network Design*; PWS Publishing Company: ISBN-0534943322, Boston, 1995

Predviđanje kočene snage i brzine vrtnje motora brodova za rasuti teret primjenom metoda strojnog učenja

Ivana Martić¹, Nastia Degiuli^{1*}, Marko Valčić^{2,3}, Carlo Giorgio Grlj¹

¹Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje, Ivana Lučića 5, 10000 Zagreb

²Sveučilište u Zadru, Pomorski odjel, Ulica Mihovila Pavlinovića 1, 23000 Zadar

³Sveučilište u Rijeci, Tehnički fakultet, Vukovarska ulica 58, 51000 Rijeka

*nastia.degiuli@fsb.unizg.hr

Sažetak: U ovom istraživanju primijenjen je niz metoda strojnog učenja za razvoj modela za predviđanje kočene snage motora i brzine vrtnje motora brodova za rasuti teret. Poseban naglasak stavljen je na smanjenje šuma u ulaznim i izlaznim podacima primjenom metode zaglađivanja splajnom, s ciljem poboljšanja sposobnosti generalizacije razvijenih modela strojnog učenja. Provedena je detaljna usporedba rezultata dobivenih primjenom različitih metoda, pri čemu su ocijenjene njihova točnost i sposobnost generalizacije. Rezultati dobiveni na temelju zaglađenih podataka pokazuju da modeli ansambla regresijskih stabala ostvaruju uravnotežen kompromis između interpretabilnosti i točnosti, što ih čini posebno prikladnima za praktične inženjerske primjene. U učinkovitosti ih slijede optimizirani modeli regresijskih stabala te regresije Gaussovom procesom. Nadalje, modeli linearne regresije temeljeni na zaglađenim podacima također postižu zadovoljavajuću razinu točnosti za praktične primjene, što omogućuje razvoj jednostavnih prediktivnih formula za kočenu snagu i brzinu vrtnje motora, prikladnih za primjenu u okviru preliminarnog projektiranja broda.

Cljučne riječi: strojno učenje, projektiranje broda, brod za rasuti teret, kočena snaga, brzina vrtnje motora

1. Uvod

Preliminarna faza projektiranja broda, između ostalog, uključuje određivanje glavnih dimenzija i oblika trupa te odabir porivnog sustava. Procjena kočene snage i brzine vrtnje motora u preliminarnom projektiranju broda ključna je za odabir najpovoljnije projektne varijante s obzirom na energetske učinkovitost broda. U preliminarnom

projektiranju broda njegove se značajke u pravilu određuju primjenom regresijskih formula izvedenih na temelju postojećih baza podataka brodova, koje su često zastarjele i neprikladne za suvremene brodske forme. Takvi modeli su nerijetko razvijeni na temelju sirovih i zašumljenih podataka te se u tom kontekstu linearna regresija može promatrati kao niskopropusni filtar. Pouzdanost i točnost modela razlikuju se ovisno o tome primjenjuje li se model na sirove i često zašumljene podatke ili na prethodno zaglađene podatke.

Značajni naponi usmjereni su na unapređenje postojećih regresijskih formula, uključujući integraciju novo prikupljenih podataka te objedinjavanje više empirijskih modela [1]. Primjerice, Rinauro et al. [2] primijenili su višestruku regresiju u kombinaciji s algoritmom stabla odluke (engl. *forest trees*) kako bi razvili prediktivni model za procjenu glavnih dimenzija kontejnerskih brodova, brzine i kočene snage u fazi preliminarnog projektiranja. Osim toga, predloženi su relativno jednostavni modeli temeljeni na umjetnim neuronskim mrežama (engl. *artificial neural network*, ANN) za procjenu dodatnog otpora broda na pravilnim valovima [3–6]. Modeli strojnog učenja (engl. *machine learning*) sve se češće primjenjuju za rješavanje različitih problema u području brodogradnje. Neka od provedenih istraživanja uključuju između ostalog predviđanje snage glavnog pogonskog motora i emisija štetnih plinova [7], procjenu potrošnje goriva broda na temelju podataka prikupljenih tijekom plovidbe [8], predviđanje putanje broda [9], analizu učinaka obraštanja trupa [10], određivanje hidrodinamičkih značajki putem višeciljne optimizacije [11], predviđanje opterećenja koja djeluju na brodski trup uslijed plovidbe ledom [12], procjenu rizika od nasukavanja [13] te kvantifikaciju relativne vjerojatnosti incidenta u ekstremnim vremenskim uvjetima [14]. Mogućnost primjene strojnog učenja za predviđanje brzine broda primjenom metoda regresije, istražena je na temelju operativnih podataka trajekta prikupljenih tijekom plovidbe [15]. Korištene regresijske metode uključuju linearnu regresiju, regresijska stabla različitih veličina, ansamble regresijskih stabala, regresiju Gaussovima procesom te stroj s potpornim vektorima (engl. *support vector machines*). Višestruka linearna regresija, kao znatno jednostavniji algoritam, pokazala je usporedivu razinu točnosti u odnosu na složenije metode.

Za početak je potrebno identificirati relevantne podatke, provjeriti njihovu valjanost te ih statistički obraditi kako bi se osiguralo formiranje visokokvalitetnog skupa podataka. Taj postupak uključuje pažljivu analizu podataka radi uklanjanja anomalija i izdvojenih vrijednosti, uz istodobno razmatranje mogućeg utjecaja zaglađivanja na cjelovitost podataka. Skupovi sirovih podataka često sadrže šum i nedostajuće vrijednosti, što može znatno narušiti točnost modela strojnog učenja treniranih na takvim podacima [8]. Prediktivna učinkovitost bilo kojeg modela strojnog učenja uvelike ovisi o kvaliteti i količini ulaznih podataka. U mnogim slučajevima podaci pokazuju znatnu varijabilnost i nesigurnost, čemu je potrebno posvetiti dodatnu pažnju prilikom formiranja skupa podataka za učenje modela strojnog učenja. Liu i suradnici [16] primijenili su tzv. metodu teorije valića (engl. *wavelet*) kako bi uklonili šum iz


eksperimentalnih podataka gibanja KVLCC2 broda i autonomnog površinskog plovila. Slično tome, Xue i suradnici [17] koristili su Gaussov proces za uklanjanje šuma iz podataka o gibanjima broda. Nadalje, algoritam zaglađivanja podataka primijenjen je za uklanjanje šuma podataka korištenih pri razvoju ANN modela za predviđanje potrošnje goriva broda [18]. Metoda analize varijance (ANOVA) i splajnovi za zaglađivanje podataka primijenjeni su za smanjenje broja ulaznih varijabli u optimizacijskom postupku minimizacije potrošnje goriva za tipično plutajuće postrojenje za proizvodnju, skladištenje i iskrcaj (engl. *Floating Production Storage and Offloading*, FPSO) u promjenjivim radnim uvjetima [19].

U ovom radu provedena je sveobuhvatna analiza i usporedba rezultata dobivenih pomoću 18 različitih modela temeljenih na pet metoda strojnog učenja za predviđanje kočene snage i brzine vrtnje motora brodova za rasuti teret. Sirovi podaci često su značajno zašumljeni, što uvodi nesigurnost u razvoj modela. Stoga je naglašena važnost obrade zašumljenih podataka s visokom razinom nesigurnosti kako bi se razvili što pouzdaniji modeli primjenjivi na potpuno nove skupove podataka. Predstavljen je postupak pripreme podataka zaglađivanjem splajnovima s ciljem postizanja što bolje sposobnosti generalizacije, a koji se primjenjuje ne samo na složene modele strojnog učenja, već i na višestruku linearnu regresiju. Iako razvijeni modeli postižu visoku točnost u procjeni kočene snage i brzine vrtnje motora, njihova složenost onemogućuje izravnu primjenu u fazi preliminarnog projektiranja broda. Stoga su predloženi jednostavni regresijski izrazi koji omogućuju procjenu kočene snage i brzine vrtnje motora na temelju dimenzija broda i brzine plovidbe uz zadovoljavajuću točnost.


2. Baza podataka

S ciljem razvoja modela strojnog učenja korištena je IHS Fairplay [20] baza podataka brodova za rasuti teret korištena od strane MEPC-a (engl. *Marine Environment Protection Committee*) kao standardna referentna baza za određivanje referentne linije projektnog indeksa energetske učinkovitosti (engl. *Energy Efficiency Design Indeks*, EEDI). Dostupni podaci obuhvaćaju naziv broda, duljinu preko svega (L_{OA}), širinu (B), gaz (T), nosivost (DWT), istisninu (Δ), brzinu (V), kočenu snagu glavnog motora (P_B) i brzinu vrtnje motora (n). Baza podataka obuhvaća brodove izgrađene u razdoblju od 2000. do 2015. godine. Nakon uklanjanja podataka koji značajnije odstupaju od skupa (eng. *outliers*), od ukupno 8253 podatka dobiveno je 6660 podataka koji su korišteni za učenje, validaciju i testiranje modela strojnog učenja. Podaci o istisnini bili su dostupni za samo 24,3 % uzoraka, stoga je ista izostavljena iz daljnje analize. Uočena je snažna pozitivna korelacija između zavisne varijable P_B i prediktorskih varijabli L_{OA} , B , T , DWT i Δ , Slika 1. Međutim, među prediktorskim varijablama prisutna je i izražena multikolinearnost, što je očekivano s obzirom na njihove fizikalne međuodnose. Kako bi se ublažio negativan utjecaj multikolinearnosti, nosivost, koja

pokazuje visoku razinu multikolinearnosti s varijablama L_{OA} , B , T , isključena je iz daljnjeg modeliranja. Nasuprot tome, zavisna varijabla n pokazuje negativnu korelaciju s L_{OA} , B , T i V , pri čemu je ta korelacija nešto manje izražena u odnosu na onu uočenu za P_B . Konačno, za procjenu kočene snage i brzine vrtnje motora brodova za rasuti teret usvojene su četiri ulazne varijable: L_{OA} , B , T i V . Distribucija podataka za P_B i n prikazana je na Slici 2.



Slika 1: Korelacijska matrica



Slika 2: Distribucija podataka za P_B i n

Statistički pokazatelji ulaznih i izlaznih varijabli prikazani su u Tablici 1. Uočena je značajna varijabilnost kočene snage i brzine vrtnje motora, što upućuje na visoku razinu šuma u ulaznim podacima. Također je primijećeno da pojedini sestrinski brodovi imaju znatno različite vrijednosti kočene snage i brzine vrtnje motora. Kako bi se smanjio šum u podacima i poboljšala sposobnost generalizacije modela, postupak zaglađivanja podataka splajnovima proveden je u okviru pripreme podataka. Na taj način je smanjena nesigurnosti u podacima te značajno povećana pouzdanost i robusnost razvijenih modela.

Tablica 1: Statistički pokazatelji uzlaznih i izlaznih varijabli

	Ulazne varijable				Izlazne varijable	
	L_{OA} , m	B , m	T , m	V , kn	P_B , kW	n , o/min
Minimum	157,00	23,10	8,70	10,00	4539,00	72,00
Aritmetička sredina	215,31	34,18	13,37	14,34	9787,24	111,34
Medijan	197,00	32,30	12,80	14,50	8753,00	110,00
Mod	190,00	32,30	12,80	14,50	9480,00	127,00
Maksimum	330,00	57,00	21,40	17,00	19073,00	136,00
Standardna devijacija	39,65	6,04	2,61	0,39	3384,26	15,91

3. Metodologija

U okviru istraživanja primijenjene su različite metode strojnog učenja poput linearne regresije, regresijskih stabala, regresije Gausovim procesom, ansambla regresijskih stabala te neuronske mreže. Široko primjenjiva linearna regresija koristi se za opisivanje i analizu odnosa između zavisne varijable i jedne ili više prediktorskih varijabli. Cilj je pronaći linearnu funkciju koja najbolje opisuje podatke, a dobiveni model omogućuje jednostavnu interpretaciju [21].

Regresijska stabla predstavljaju jednostavnu i visoko interpretabilnu metodu nadziranog učenja namijenjenu rješavanju regresijskih problema s više prediktorskih varijabli. Njihova jednostavnost i učinkovitost, zajedno s obilježjima koja ih čine pogodnima za rješavanje različitih multivarijabilnih regresijskih problema, čine ih atraktivnim alatom u praksi [22].

Modeli regresije Gausovim procesom predstavljaju nelinearnu, probabilističku metodu regresije koja se temelji na teoriji vjerojatnosti [23]. Umjesto da unaprijed definira oblik funkcije, Gaussov proces opisuje distribuciju mogućih funkcija koje su u skladu s podacima. Zbog svoje fleksibilnosti i sposobnosti modeliranja složenih

odnosa, često se koriste u strojnome učenju te su poznati po visokoj točnosti. Međutim, njihova složenost može otežati interpretaciju rezultata. Važno je napomenuti kako izlaz nije pojedinačna vrijednost, već distribucija vjerojatnosti, što omogućuje kvantifikaciju nesigurnosti u predviđanjima.

Ansambli regresijskih stabala obuhvaćaju skup algoritama strojnog učenja koji se temelje na kombiniranju više stabala odlučivanja kako bi se postigla veća točnost i robusnost modela. Umjesto oslanjanja na jedno stablo, ansambli agregiraju predviđanja više stabala, čime se smanjuje pretreniranost modela. Općenito se dijele u dvije glavne kategorije: *boosted* stabla, koja se temelje na slijednom učenju algoritama na pogreškama prethodnih algoritama, te *bagged* stabla, koja koriste pristup treniranja na podskupovima skupa za učenje [24,25].

Neuronske mreže predstavljaju napredne algoritme učenja čiji postupak treniranja uključuje podešavanje težinskih faktora i pomaka korištenjem odgovarajućeg algoritma učenja. U nadziranom učenju ulazni podaci su dostupni mreži, a izlazne vrijednosti se uspoređuju s ciljnim vrijednostima kako bi se smanjila pogreška i poboljšala točnost predikcije [26].

Svaka metoda ima svoje specifične značajke, poput početnih uvjeta i topologije modela. Kako bi se uzeli u obzir ti specifični aspekti, u ovom su istraživanju za svaku metodu razvijeni višestruki modeli.

3.1. Zaglađivanje podataka splajnom

Kao što je prethodno navedeno, sirovi podaci pripremljeni su zaglađivanjem splajnom $s(x_i)$ temeljenom na parametru zaglađivanja p i težinama w_i . Zaglađivanje podataka splajnom minimizira sljedeći član:

$$p \sum_i w_i (y_i - s(x_i))^2 + (1-p) \int (d^2 s / dx^2)^2 dx \quad (1)$$

Parametar zaglađivanja odabran je tako da bude što bliži nuli kako bi se postiglo glatko prilagođavanje krivulje metodom najmanjih kvadrata:

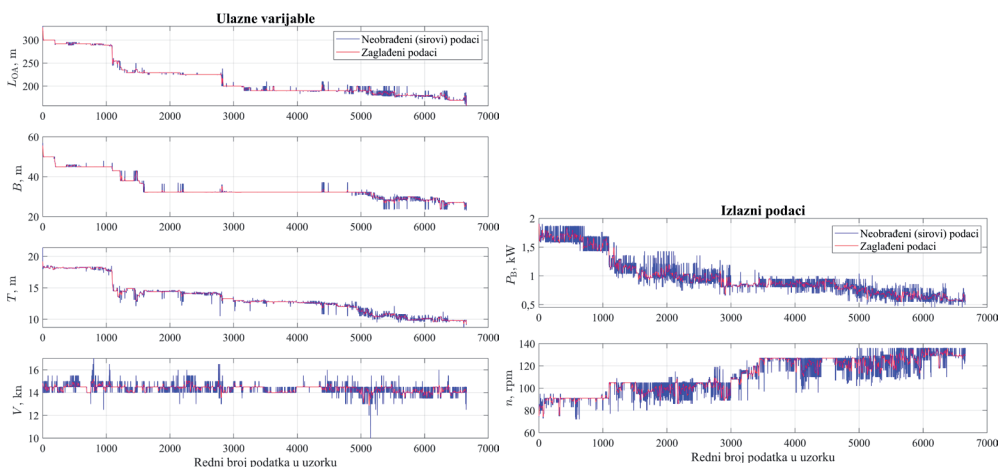
$$\begin{cases} \min_{p_j} (R_{j,\text{test}}^2 - R_{j,\text{val}}^2) \\ \text{s.t. } 0 \leq p_j \leq 1, \quad j = 1, 2, \dots, N \end{cases} \quad (2)$$

gdje R_{test}^2 i R_{val}^2 predstavljaju koeficijente determinacije za testni i validacijski skup podataka, a N broj analiziranih modela strojnog učenja.

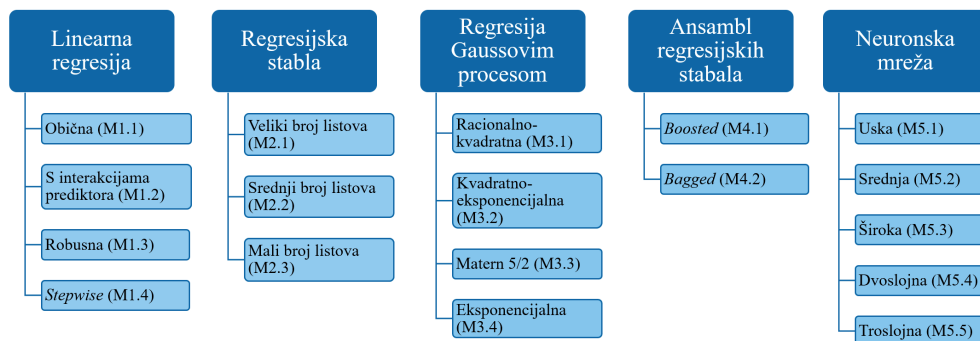
Cjelokupni postupak, koji uključuje zaglađivanje podataka i treniranje modela strojnog učenja započinje korakom inicijalizacije, u kojem se definiraju granice parametra zaglađivanja, zajedno s veličinom koraka za iterativni proces. Osim toga, za k -struku unakrsnu validaciju potrebno je odrediti broj dijelova skupa podataka (k) te postotak podataka namijenjenih za testiranje. Potom se odabrani trenutačni parametar zaglađivanja primjenjuje za zaglađivanje izvornog skupa podataka u tekućoj iteraciji te se definiraju ulazni i ciljani podaci koristeći zaglađeni skup podataka, zajedno s njihovom raspodjelom prema principu k -struke unakrsne validacije. Unutar istog koraka provodi se treniranje i validacija na temelju zaglađenog skupa podataka. Pokazatelji učinkovitosti računaju se na temelju trenutačnog parametra zaglađivanja, dok se prosječni pokazatelj validacije računa za sve dijelove skupa podataka k i pohranjuje za daljnju analizu. Validirani modeli strojnog učenja testiraju se na preostalom dijelu nasumično odabranih podataka iz zaglađenog skupa. Navedeni postupak ponavlja se iterativno za svaku vrijednost parametra zaglađivanja, dok se u završnom koraku odabire vrijednost parametra zaglađivanja koja minimizira funkciju cilja.

4. Rezultati

Kako bi se osigurala objektivna usporedba rezultata razvijenih modela, ključno je dosljedno koristiti isti skup podataka tijekom faza treniranja, validacije i testiranja. Stoga je za sve analizirane modele strojnog učenja usvojena srednja vrijednost parametra zaglađivanja. Zaglađeni podaci, generirani iz izvornog skupa podataka, prikazani su za ulazne i izlazne varijable na Slici 3. Pet metoda strojnog učenja analizirano je kroz ukupno 18 modela s različitim konfiguracijama, kako je prikazano na Slici 4. Svakom modelu dodijeljena je jedinstvena oznaka radi lakšeg praćenja i usporedbe rezultata.



Slika 3: Sirovi i zaglađeni podaci za ulazne i izlazne varijable



Slika 4: Modeli strojnog učenja

Kod *stepwise* linearne regresije početni članovi prediktorskih varijabli su linearni, uz interakcije prediktora te ograničenje na broj članova koje model može uključiti u maksimalno 1000 koraka. Regresijska stabla primijenjena su bez zamjenskih podjela odluka. Kod velikog broja listova najmanja veličina lista iznosi 4, kod srednjeg 12, a kod malog broja listova 36. U regresiji Gausovim procesom primijenjena je konstantna bazna funkcija i izotropna jezgrena funkcija, uz automatsko određivanje standardne devijacije signala te sigma parametra. Za ansamble regresijskih stabala minimalna veličina lista postavljena je na osam, s ukupno 30 učenika. Kod neuronskih mreža primijenjena je ReLU aktivacijska funkcija, a postupak treniranja ograničen je na 1000 iteracija. Uska, dvoslojna i troslojna neuronska mreža sadrže po 10 neurona u skrivenom sloju, dok srednja i široka mreža imaju 25, odnosno 100 neurona u skrivenom sloju.

Skup podataka podijeljen je na podskupove za treniranje, validaciju i testiranje. Za validaciju je korištena k -struka unakrsna validacija s pet podjela. Poseban testni podskup, koji obuhvaća 10 % ukupnog broja podataka, rezerviran je za procjenu učinkovitosti svih modela, dok su preostali podaci podijeljeni u pet jednakih dijelova za potrebe unakrsne validacije, gdje je svaki dio obuhvatio 1199 brodova, odnosno 18 % ukupnog broja podataka. Treniranje je u svakoj iteraciji provedeno na temelju podataka u četiri dijela skupa podataka, odnosno za 4795 brodova ili 72 % ukupnog broja podataka. Učinkovitost modela ocijenjena je na temelju koeficijenta determinacije R^2 , korijena srednje kvadratne pogreške *RMSE* (engl. *Root Mean Square Error*), srednje kvadratne pogreške *MSE* (engl. *Mean Square Error*) i srednje apsolutne pogreške *MAE* (engl. *Mean Absolute Error*), koji su izračunati kao prosjek vrijednosti preko svih pet skupova podataka za validaciju. Korišten je programski paket MATLAB R2022b [27], a analiza je provedena na sirovim i zaglađenim skupovima podataka. Usporedbom rezultata pokazalo se kako je postupak zaglađivanja podataka značajno poboljšao kvalitetu podataka, što je dovelo do povećane točnosti i bolje sposobnosti generalizacije [28].

Tablica 2: Pokazatelji učinkovitosti modela strojnog učenja u predviđanju kočene snage motora P_B

Model strojnog učenja		<i>RMSE</i>	<i>R</i> ²	<i>MSE</i>	<i>MAE</i>
M1.1	validacija	576,21	0,9694	332018,61	438,25
	testiranje	577,28	0,9675	333252,15	440,02
M1.2	validacija	536,11	0,9735	287413,95	405,93
	testiranje	537,92	0,9718	289356,79	404,93
M1.3	validacija	576,70	0,9694	332578,93	437,65
	testiranje	577,11	0,9675	333053,72	438,83
M1.4	validacija	536,11	0,9735	287413,95	405,93
	testiranje	537,92	0,9718	289356,79	404,93
M2.1	validacija	308,77	0,9912	95338,18	185,36
	testiranje	308,14	0,9907	94950,49	174,53
M2.2	validacija	352,31	0,9886	124122,02	236,88
	testiranje	334,22	0,9891	111704,40	219,53
M2.3	validacija	417,52	0,9839	174324,78	291,20
	testiranje	407,25	0,9838	165852,54	287,52
M3.1	validacija	364,91	0,9877	133159,05	245,29
	testiranje	322,45	0,9899	103974,26	212,53
M3.2	validacija	427,20	0,9832	182503,99	302,85
	testiranje	421,61	0,9827	177751,39	300,51
M3.3	validacija	411,72	0,9844	169511,17	289,31
	testiranje	408,27	0,9838	166685,83	287,50
M3.4	validacija	346,70	0,9889	120201,68	231,78
	testiranje	326,19	0,9896	106398,34	217,03
M4.1	validacija	604,42	0,9663	365317,89	477,73
	testiranje	598,56	0,9651	358277,24	474,02
M4.2	validacija	276,44	0,993	76416,40	185,70
	testiranje	243,53	0,9942	59304,92	170,96
M5.1	validacija	505,35	0,9765	255376,82	369,25
	testiranje	530,13	0,9726	281039,21	387,72
M5.2	validacija	491,35	0,9778	241421,89	357,20
	testiranje	492,82	0,9763	242870,22	355,44
M5.3	validacija	448,84	0,9814	201452,99	324,68
	testiranje	450,10	0,9803	202592,71	322,14
M5.4	validacija	507,12	0,9763	257172,18	373,21
	testiranje	504,12	0,9752	254137,13	371,41
M5.5	validacija	499,15	0,977	249152,02	365,71
	testiranje	717,92	0,9498	515407,28	548,13

Pokazatelji učinkovitosti razvijenih modela strojnog učenja za procjenu P_B i n prikazani su u Tablici 2 odnosno Tablici 3. Ansambl regresijskih stabala, tj. *bagged* stabla pokazuju najveću učinkovitost u predviđanju P_B i za validacijski i za testni skup podataka, a slijede ih stabla s velikim brojem listova. Najmanju učinkovitost pokazuju tzv. *boosted* stabla za validacijski skup podataka, odnosno troslojna neuronska mreža za testni skup podataka.

Tablica 3: Pokazatelji učinkovitosti modela strojnog učenja u predviđanju brzine vrtnje motora n

Model strojnog učenja		<i>RMSE</i>	R^2	<i>MSE</i>	<i>MAE</i>
M1.1	validacija	6,18	0,8305	38,21	4,93
	testiranje	6,29	0,8365	39,52	5,02
M1.2	validacija	5,47	0,8675	29,88	4,07
	testiranje	5,41	0,879	29,25	4,01
M1.3	validacija	6,22	0,8283	38,71	4,85
	testiranje	6,32	0,8346	39,98	4,93
M1.4	validacija	5,46	0,8675	29,86	4,07
	testiranje	5,41	0,8789	29,28	4,01
M2.1	validacija	2,42	0,9741	5,85	1,28
	testiranje	2,03	0,9829	4,12	1,08
M2.2	validacija	2,75	0,9665	7,56	1,69
	testiranje	2,43	0,9756	5,90	1,44
M2.3	validacija	3,21	0,9542	10,33	2,18
	testiranje	2,95	0,9639	8,72	2,01
M3.1	validacija	2,57	0,9707	6,61	1,63
	testiranje	2,27	0,9786	5,17	1,46
M3.2	validacija	3,07	0,9583	9,40	2,12
	testiranje	3,10	0,9603	9,60	2,17
M3.3	validacija	2,80	0,9652	7,85	1,88
	testiranje	2,64	0,9711	6,99	1,79
M3.4	validacija	2,50	0,9723	6,24	1,57
	testiranje	2,32	0,9778	5,38	1,49
M4.1	validacija	5,89	0,846	34,71	5,21
	testiranje	5,74	0,8635	32,99	5,08
M4.2	validacija	2,16	0,9792	4,68	1,35
	testiranje	1,86	0,9856	3,48	1,19
M5.1	validacija	4,54	0,9084	20,65	3,38
	testiranje	4,30	0,9236	18,46	3,17
M5.2	validacija	3,80	0,936	14,43	2,80
	testiranje	3,62	0,9458	13,10	2,62
M5.3	validacija	3,30	0,9516	10,91	2,36
	testiranje	3,35	0,9536	11,22	2,42
M5.4	validacija	3,94	0,9312	15,51	2,87
	testiranje	3,67	0,9444	13,45	2,63
M5.5	validacija	3,79	0,9363	14,37	2,78
	testiranje	3,49	0,9495	12,20	2,49

U slučaju brzine vrtnje motora, vidljivo je da *bagged* stabla nadmašuju preostale modele kako za validacijski, tako i za testni skup podataka, a slijede ih modeli eksponencijalne regresije Gausovim procesom i stabla sa srednjim brojem listova. Općenito, modeli regresijskih stabala te regresije Gausovim procesom pokazuju najveću učinkovitost u predviđanju brzine vrtnje motora n , a slijedi ih široka neuronska mreža. Ostali modeli, osobito linearna regresija i *boosted* stabla, imaju najniži koeficijent determinacije te najveće vrijednosti *MSE* i *RMSE*. S druge strane, ako se za pokazatelj učinkovitosti uzme *MAE*, stabla s velikim brojem listova pokazuju najnižu vrijednost za oba skupa podataka.

Za potrebe inženjerske primjene obična linearna regresija može biti zadovoljavajuća. Izraz za procjenu P_B i n kao funkcije brzine broda i glavnih dimenzija, koji se može primijeniti u preliminarnom projektiranju broda, glasi:

$$\hat{P}_B = -10617,7260 + 28,2814 \cdot L_{OA} + 195,9338 \cdot B + 381,9788 \cdot T + 175,3274 \cdot V \quad (3)$$

$$\hat{n} = 222,0986 - 0,3412 \cdot L_{OA} + 1,3351 \cdot B - 2,7910 \cdot T - 3,1832 \cdot V \quad (4)$$

Treba napomenuti da je točnost u ovom slučaju osjetno manja u usporedbi s prethodno spomenutim složenijim modelima strojnog učenja, što je potrebno uzeti u obzir pri praktičnoj primjeni ovih jednadžbi. Nešto veća točnost može se postići primjenom *stepwise* linearne regresije. Jednadžbe za procjenu P_B i n u tom su slučaju sljedeće:

$$\begin{aligned} \hat{P}_B = & 21017,6420 - 257,9705 \cdot L_{OA} - 1298,1847 \cdot B + 5988,9754 \cdot T \\ & - 1737,4671 \cdot V - 2,4606 \cdot L_{OA} \cdot B + 1,3145 \cdot L_{OA} \cdot T + 23,7887 \cdot L_{OA} \cdot V \\ & + 39,3344 \cdot B \cdot T + 104,2699 \cdot B \cdot V - 494,5938 \cdot T \cdot V \end{aligned} \quad (5)$$

$$\begin{aligned} \hat{n} = & 478,7795 - 8,1115 \cdot L_{OA} + 2,3376 \cdot B + 91,1797 \cdot T - 13,1283 \cdot V \\ & - 0,0064 \cdot L_{OA} \cdot B + 0,0496 \cdot L_{OA} \cdot T + 0,5013 \cdot L_{OA} \cdot V - 7,1916 \cdot T \cdot V \end{aligned} \quad (6)$$

5. Zaključak

U ovom istraživanju provedena je usporedba rezultata pet metoda strojnog učenja za procjenu kočene snage motora i brzine vrtnje motora brodova za rasuti teret. Razvijeno je 18 različitih modela strojnog učenja: četiri modela linearne regresije, tri modela regresijskih stabala, četiri modela regresije Gausovim procesom, dva modela ansambla regresijskih stabala te pet modela neuronskih mreža. Kako bi se ublažio utjecaj šuma u podacima i poboljšala sposobnost generalizacije modela, u okviru

pripreme podataka primijenjena je metoda zaglađivanja splajnom, čime je učinkovito smanjena nesigurnost u izvornom skupu podataka te značajno povećana pouzdanost i robusnost razvijenih modela.

Usporedba rezultata pokazala je da modeli ansambla regresijskih stabala ostvaruju uravnotežen kompromis između interpretabilnosti i točnosti, što ih čini posebno prikladnima za praktične inženjerske primjene. U učinkovitosti ih slijede optimizirani modeli regresijskih stabala te regresije Gaussovima procesom. Iako su napredniji modeli strojnog učenja očekivano postigli višu razinu učinkovitosti, modeli linearne regresije također su pokazali zadovoljavajuću točnost, čime je potvrđena njihova praktična primjenjivost u preliminarnom projektiranju broda, gdje su jednostavnost i interpretabilnost od ključne važnosti. Kao rezultat, predložene su regresijske formule za procjenu kočene snage i brzine vrtnje motora na temelju glavnih značajki broda i brzine plovidbe. Ove jednostavne formule predstavljaju učinkovite alate za brzu procjenu te doprinose kvalitetnijem donošenju odluka u ranim fazama projektiranja broda.

Zahvala

Ova rad je financirala Hrvatska zaklada za znanost projektima IP-2025-02-4779 i IP-2022-10-2821.

6. Literatura

- [1] Zhang, C.; Ringsberg, J. W., Thies, F.: Development of a ship performance model for power estimation of inland waterway vessels, *Ocean Engineering*, **287** (2023) 115731, <https://doi.org/10.1016/j.oceaneng.2023.115731>
- [2] Rinauro, B.; Begovic, E., Mauro, F., Rosano, G.: Regression analysis for container ships in the early design stage, *Ocean Engineering*, **292** (2024) 116499, <https://doi.org/10.1016/j.oceaneng.2023.116499>
- [3] Martić, I.; Degiuli, N., Grlj, C. G.: Prediction of added resistance of container ships in regular head waves using an artificial neural network, *Journal of Marine Science and Engineering*, **11** (2023) 7, 1293, <https://doi.org/10.3390/jmse11071293>
- [4] Martić, I.; Degiuli, N., Farkas, A., Grlj, C. G.: The application of ANN in estimating added resistance of container ships in regular head waves, *Sustainable Development and Innovations in Marine Technologies - Proceedings of the 19th International Congress of the International Maritime Association of the Mediterranean*, IMAM 2022, 26-29 September, Istanbul, Turkey, 175–182 (2023), <https://doi.org/10.1201/9781003358961-23>
- [5] Martić, I.; Degiuli, N., Majetić, D., Farkas, A.: Artificial neural network model for the evaluation of added resistance of container ships in head waves, *Journal of Marine Science and Engineering*, **9** (2021) 8, 826, <https://doi.org/10.3390/jmse9080826>

- [6] Cepowski, T.: The prediction of ship added resistance at the preliminary design stage by the use of an artificial neural network, *Ocean Engineering*, **195** (2020), 106657, <https://doi.org/10.1016/j.oceaneng.2019.106657>
- [7] Ozsari, I.: Predicting main engine power and emissions for container, cargo, and tanker ships with artificial neural network analysis, *Brodogradnja*, **74** (2023) 2, 77–94, <https://doi.org/10.21278/brod74204>
- [8] Fan, A.; Wang, Y., Yang, L., Tu, X., Yang, J., Shu, Y.: Comprehensive evaluation of machine learning models for predicting ship energy consumption based on onboard sensor data, *Ocean & Coastal Management*, **248** (2024) 106946, <https://doi.org/10.1016/j.ocecoaman.2023.106946>
- [9] Li, H.; Jiao, H., Yang, Z.: Ship trajectory prediction based on machine learning and deep learning: A systematic review and methods analysis, *Engineering Applications of Artificial Intelligence*, **126** (2023) 107062, <https://doi.org/10.1016/j.engappai.2023.107062>
- [10] Mittendorf, M.; Nielsen, U. D., Bingham, H. B.: Capturing the effect of biofouling on ships by incremental machine learning, *Applied Ocean Research*, **138** (2023) 103619 <https://doi.org/10.1016/j.apor.2023.103619>
- [11] Liu, J.; Wu, S., Yue, X., Yue, Q.: Hydrodynamic shape optimization of an autonomous and remotely-operated vehicle via a multi-surrogate model, *Brodogradnja*, **75** (2024) 3, 75301, <https://doi.org/10.21278/brod75301>
- [12] Lee, S. J.; Jung, K. H., Ku, N., Lee, J.: A comparison of regression models for the ice loads measured during the ice tank test, *Brodogradnja*, **74** (2023) 3, 1–15, <https://doi.org/10.21278/brod74301>
- [13] Zhang, M.; Kujala, P., Hirdaris, S.: A machine learning method for the evaluation of ship grounding risk in real operational conditions, *Reliability Engineering & System Safety*, **226** (2022) 108697, <https://doi.org/10.1016/j.res.2022.108697>
- [14] Rawson, A.; Brito, M., Sabeur, Z., Tran-Thanh, L.: A machine learning approach for monitoring ship safety in extreme weather events, *Safety Science*, **141** (2021) 105336, <https://doi.org/10.1016/j.ssci.2021.105336>
- [15] Bassam, A. M.; Phillips, A. B., Turnock, S. R., Wilson, P. A.: Ship speed prediction based on machine learning for efficient shipping operation, *Ocean Engineering*, **245** (2022) 110449, <https://doi.org/10.1016/j.oceaneng.2021.110449>
- [16] Liu, S. Y.; Ouyang, Z. L., Chen, G., Zhou, X., Zou, Z. J.: Black-box modeling of ship maneuvering motion based on Gaussian process regression with wavelet threshold denoising, *Ocean Engineering*, **271** (2023) 113765, <https://doi.org/10.1016/j.oceaneng.2023.113765>
- [17] Xue, Y.; Liu, Y., Ji, C., Xue, G., Huang, S.: System identification of ship dynamic model based on Gaussian process regression with input noise, *Ocean Engineering*, **216** (2020) 107862, <https://doi.org/10.1016/j.oceaneng.2020.107862>
- [18] Jeon, M.; Noh, Y., Shin, Y., Lim, O. K., Lee, I., Cho, D.: Prediction of ship fuel consumption by using an artificial neural network, *Journal of Mechanical Science and Technology*, **32** (2018) 5785–5796, <https://doi.org/10.1007/s12206-018-1126-4>

- [19] Allahyarzadeh-Bidgoli, A.; Dezan, D. J., Salviano, L. O., de Oliveira Junior, S., Yanagihara, J. I.: FPSO fuel consumption and hydrocarbon liquids recovery optimization over the lifetime of a deep-water oil field, *Energy*, **181** (2019) 927–942, <https://doi.org/10.1016/j.energy.2019.05.146>
- [20] IHS Fairplay, World Register of Ships Manual (2013)
- [21] Kutner, M.H.; Nachtsheim, C.J., Neter, J., Li, W.: *Applied Linear Statistical Models*, 5th Ed., McGraw-Hill Professional, New York, USA (2004)
- [22] Breiman, L.; Friedman, J., Olshen, R., Stone, C.: *Classification and regression trees*, Statistics/probability series, Chapman and Hall/CRC, Belmont (1984)
- [23] Rasmussen, C.E.; Williams, C.K.I.: *Gaussian Processes for Machine Learning*, MIT Press, Cambridge, Massachusetts, USA (2006) <https://doi.org/10.7551/mitpress/3206.001.0001>
- [24] Friedman, J.: Greedy function approximation: A gradient boosting machine, *Annals of Statistics*, **29** (2001) 5, 1189–1232, <https://doi.org/10.1214/aos/1013203451>
- [25] Breiman, L.: Bagging Predictors, *Machine Learning*, **26** (1996) 123–140, <https://doi.org/10.1023/A:1018054314350>
- [26] Beale, M.H.; Hagan, M.T., Demuth, H.B.: Deep Learning Toolbox User's Guide, The MathWorks, Inc., Natick, MA, USA (2023).
- [27] The MathWorks: MATLAB Software Package, R2022b, *Dostupno na* <https://uk.mathworks.com/>, *Pristupljeno*: 2025-12-19
- [28] Valčić, M.; Martić, I., Degiuli, N., Grlj, C.G., Zhang, M.: Comparative analysis of machine learning methods for the prediction of brake power and rate of revolution for bulk carriers, *Ocean Engineering*, **322** (2025) 120517, <https://doi.org/10.1016/j.oceaneng.2025.120517>

Primjena umjetne inteligencije za karakterizaciju nanotriboloških svojstava tehnoloških tankih filmova

Marko Perčić^{1,2,3}, Saša Zelenika^{1,2,3}

¹Sveučilište u Rijeci - Tehnički fakultet, Vukovarska 58, 51000 Rijeka

²Sveučilište u Rijeci, Centar za umjetnu inteligenciju i kibernetičku sigurnost, Radmile Matejčić 2, 51000 Rijeka

³Sveučilište u Rijeci, Centar za mikro- i nanoznanosti i tehnologije, Radmile Matejčić 2, 51000 Rijeka

Sažetak: *Trenje na nanometarskoj razini ograničava preciznost i točnost mikro- i nanosustava. Doista, stohastička varijabilnost trenja otežava predviđanje ponašanja i regulaciju. Konvencionalni pristupi strojnog učenja omogućuju dobivanje većih točnosti, ali uz nedostatak objašnjivosti. U ovome se radu, stoga, koriste transparentni i interpretabilni algoritmi umjetne inteligencije (UI) da bi se dobio bolji uvid uz visoku prediktivnu učinkovitost. UI modeli testirani su na skupovima podataka dobivenih mikroskopijom s pretražnim osjetnikom na tankim filmovima ostvarenim naprednim postupcima taloženja. Trenje je mjereno varirajući istovremeno normalno opterećenje, brzinu klizanja i temperaturu. Eksperimentalnim su podacima trenirani modeli simboličke regresije temeljeni na evolucijskim algoritmima. Dobiveni modeli omogućili su utvrđivanje ovisnosti nanometarskog trenja o procesnim parametrima, vjerno reproducirajući eksperimentalne rezultate na nevidenim skupovima podataka uz dobivanje jednostavnih matematičkih korelacija.*

Ključne riječi: *nanotribologija, umjetna inteligencija, tanki filmovi, eksperimentalna mjerenja, pretražna mikroskopija s osjetnikom*

1. Uvod

Tribologija, zbog svoje važnosti u proizvodnim procesima, potrošnji energije, okolišnim učincima, zrakoplovnoj tehnologiji te, u novije vrijeme, mikro- i nanotehnologijama, osobito u proučavanju temeljnih fizikalno-kemijskih mehanizama koji određuju nastanak trenja na nanorazini, predstavlja izrazito dinamično područje istraživanja [1, 2]. U radu [3] je predstavljen inovativan i strukturiran pristup eksperimentalnom ispitivanju istodobnog utjecaja najvažnijih utjecajnih procesnih parametara na suho

trenje na nanometarskoj razini u kontaktima pojedinačnih neravnina. Postupak se temelji na naprednoj metodologiji planiranja eksperimenata (engl. *Design-of-Experiment* - DoE), pri čemu se koristi uzorkovanje temeljeno na centroidnoj Voronoi teselaciji (CVT) [4], kao i na pažljivo provedenoj karakterizaciji krutosti korištenih osjetnika za pretražnu mikroskopiju uz razmatranje utjecaja trošenja vrška i adhezije na dobivene rezultate.

Eksperimentalna su mjerenja pritom provedena pretražnom mikroskopijom s osjetnikom (engl. *Scanning Probe Microscopy* - SPM) u modalitetu rada "mikroskopija poprečnom silom" (engl. *Lateral Force Microscopy* - LFM), odnosno poprečnim skeniranjem površine dimenzija $500 \times 500 \text{ nm}^2$ na uzorcima tankih filmova aluminijske oksida (Al_2O_3) i titanijske dioksida (TiO_2) sintetiziranih taloženjem atomskih slojeva (engl. *Atomic Layer Deposition* - ALD), odnosno molibdenova disulfida (MoS_2) i aluminijske (Al) sintetiziranih taloženjem pulsirajućim laserom (engl. *Pulsed Layer Deposition* - PLD). Vrijednosti trenja na nanometarskoj razini F_f određene su u 50 diskretnih mjernih točaka u višedimenzijском prostoru definiranom materijalom tankog filma, normalnom silom ($F_N = 10\text{--}150 \text{ nN}$), brzinom klizanja ($v = 5\text{--}500 \text{ nm/s}$) i temperaturom ($\vartheta = 20\text{--}80 \text{ }^\circ\text{C}$). Primjenom osnovnih statističkih analiza prvog reda, temeljenih na Pearsonovim korelacijama (PPMC) [5], dobiveni su važni uvidi u opće trendove ovisnosti trenja na nanometarskoj razini o ispitivanim parametrima, potvrđujući da se njihove strukturne interakcije i međusobni utjecaji mogu u potpunosti razumjeti tek na atomskoj razini.

Kako bi se prevladala ograničenja postojećih modela u opisivanju procesa i fenomena koji se javljaju u nanometarskim kontaktima, te kako bi se dobili prediktivni modeli koji povezuju procesne varijable s vrijednošću nanometarskog trenja, rezultati mjerenja iz [3] se u ovome istraživanju numerički validiraju prema metodi razvijenoj u [6]. Za karakterizaciju vrijednosti trenja iz relativno ograničenog skupa eksperimentalnih podataka, primijenjen je, stoga, postupak metode simboličke regresije (SR) temeljene na umjetnoj inteligenciji (UI) [7]. Modeli su trenirani na eksperimentalnim podacima dobivenima u [3], dok se nova i neovisna mjerenja na prethodno neispitanim skupovima podataka koriste za provjeru njihove prediktivne učinkovitosti. Konačno, prikazana je detaljna usporedna statistička analiza razvijenih modela.

Unatoč izrazitoj složenosti analiziranih fenomena i inherentnoj raspršenosti mjerenja, razvijeni modeli omogućili su postizanje vrlo visoke točnosti predviđanja. Dobivena relativno jednostavna matematička formulacija ovisnosti nanometarskog trenja o ispitivanim procesnim parametrima predstavlja, pak, učinkovit alat za predviđanje trenja na nanorazini prikladan za praktičnu primjenu, dok istovremeno daje temeljni uvid u nanotriboško ponašanje u uvjetima istovremenog djelovanja više utjecajnih parametara.

2. Metodologija primjene UI za karakterizaciju nanotriboških svojstava

Zbog izrazito nelinearne prirode trenja na nanometarskoj razini, obilježene stohastičkom raspodjelom i ograničenom količinom eksperimentalnih podataka, preliminarne analize provedene u radu [3] uobičajenim linearnim, nelinearnim i multivarijantnim regresijskim metodama, rezultirale su nezadovoljavajućom prediktivnom točnošću. Suvremene računalne metode - rudarenje podataka (engl. *data mining*), strojno učenje (engl. *machine learning* - ML) i umjetna inteligencija (UI) se, pak, često primjenjuju upravo u analizi složenih i/ili velikih skupova podataka [8, 9]. Doista, rudarenje podataka omogućuje dobivanje korisnih informacija i prepoznavanje obrazaca koji su, zbog složenih međuodnosa ili količine podataka, teško uočljivi ljudskom analitičaru [9]. Konvencionalni ML algoritmi za regresiju pružaju, pak, rješenja koja učinkovito uočavaju odnose između ulaza i izlaza iz sustava, ali ne daju eksplicitni matematički oblik tih odnosa te se, stoga, označavaju terminom “*black-box*” [9].

Kako bi se razvili prediktivni modeli koji povezuju utjecajne parametre karakteristične za promatrani fizikalni proces s vrijednošću trenja na nanometarskoj razini, eksperimentalni rezultati iz [3] u ovom se radu, koristeći metodologiju predloženu u radu [6], analiziraju zato UI metodama i to, kako bi se omogućilo dobivanje eksplicitnih matematičkih formulacija traženih međuovisnosti, primjenom metoda temeljenih na genetskom programiranju (GP) [10]. Doista, GP pristup se pokazao iznimno vrijednim alatom u rješavanju složenih problema u različitim područjima istraživanja i razvoja [11, 12]. U ovom se radu onda, s ciljem dobivanja modela koji najbolje opisuju dostupne podatke i postižu visoku prediktivnu točnost, istovremeno omogućujući dobivanje računalnih programa ili matematičkih izraza izravno primjenjivih u praksi, koristi oblik GP znan kao simbolička regresija (GP-SR) [9, 13].

Kako bi se osigurala neovisna testna baza za procjenu učinkovitosti korištenih UI modela, provedena su nova eksperimentalna mjerenja na istim materijalima tankih filmova korištenima u [3], i to u istom rasponu vrijednosti procesnih parametara (F_N , v i θ), ali potpuno odvojeno od izvornih mjerenja. Svaki je model potom vrednovan u odnosu na sposobnost predviđanja sile trenja F_f u nanometarskom području na tom novom testnom skupu podataka. Budući da pritom uzorci nisu sušeni prije mjerenja, dobiveni rezultati odražavaju realnije tehnološke uvjete i predstavljaju teži izazov za numeričke modele.

Testni podaci dobiveni su ponovo na SPM Bruker Dimension Icon uređaju primjenom LFM modaliteta rada, uz kalibraciju savojne i poprečne krutosti Brukerovih SNL-10 sonde, te uzimajući u obzir utjecaj sile adhezije F_A i njezinu ovisnost o temperaturi i o trošenju vrška osjetnika, kako je detaljno opisano u [3]. Mjerenja su provedena u zatvorenom prostoru SPM uređaja, uz stalno praćenje relativne vlažnosti, koja je tijekom cijelog postupka održavana na vrijednosti od $40,23 \pm 0,8 \%$.

U skladu s uobičajenom praksom u razvoja modela strojnim učenjem, cjelokupni skup podataka podijeljen je na skup za treniranje, validaciju i testiranje [8]. Skup za treniranje služi učenju modela i zahtijeva najveći broj podataka, validacijski skup koristi se za optimizaciju hiperparametara modela, dok je testni skup potpuno odvojen i služi isključivo za konačnu procjenu modela [8, 14]. Uobičajeno se oko dvije trećine podataka koristi za treniranje, a preostala trećina za validaciju i testiranje [9].

2.1 Korelacije i metrike

U ovome je radu, za svaki od četiri analizirana materijala, testni skup obuhvatio 15 mjernih točaka s pet ponavljanja mjerenja u svakome od njih, što približno odgovara jednoj trećini glavnog DoE skupa podataka iz [3]. Za odabir testnih točaka unutar granica raspona vrijednosti utjecajnih parametara F_N , v i θ , korišten je generator slučajnih brojeva (Monte Carlo – MC) [15], implementiran u softveru GoSumD [16]. Dobiveni učinci prikazani su, pak, pomoću Pearsonovih korelacijskih koeficijenata (PPMC) [5] kao statističke aproksimacije prvog reda (Tablica 1), pri čemu oznake + i – označavaju porast ili pad F_f ovisno o promjeni pojedinog utjecajnog parametra, dok “0” označava zanemarivu korelaciju. Dobiveni koeficijenti, na u Tablici 1 prikazanim podacima za TiO_2 kao primjer tankog filma dobivenog ALD metodom taloženja, te Al kao primjer tankog filma dobivenog PLD metodom taloženja, jasno ukazuju na utjecaj adhezije na vrijednosti nanometarskog trenja.

Tablica 1: Učinci utjecajnih parametara na F_f za uzorak tankog filma TiO_2 dobiven ALD te za uzorak Al tankog filma dobiven PLD metodom taloženja na testnom skupu podataka uzorkovanom MC metodom [6]

	F_N	F_A	v	J
TiO₂	+ (0,80)	- (-0,53)	+ (0,24)	+ (0,63)
Al	0 (-0,15)	+ (0,72)	- (-0,24)	- (-0,75)

Prije treniranja modela, podaci se, ovisno o korištenoj UI metodi, standardiziraju ili normaliziraju [14]. Eksperimentalni podaci dobiveni u ovdje korištenih 50 točaka uzorkovanja se za svaki analizirani tanki film koriste za treniranje modela te se za svaki materijal razvija poseban model. Normalna distribucija podataka procijenjena je pomoću parametara asimetrije i kurtoze [5, 8], pri čemu je utvrđeno da svi skupovi podataka pokazuju prihvatljivu normalnu distribuciju. Najbolje karakteristike distribucije su dobivene za Al tanke filmove, dok je kod ostalih uzoraka dobivena izražena pozitivna asimetrija.

Kako bi se ispitao potencijal razvoja jedinstvenog modela za sve materijale, ali i povećala količina podataka za učenje, svi algoritmi UI trenirani su i na objedinjenoj, tj. skupnoj (engl. *pooled*) bazi podataka od ukupno 200 mjerenja, koja uključuje sve

materijale, gdje je klasifikacija pojedine klase materijala uvedena pomoću tzv. *dummy* binarne varijable [9]. Kako bi se, pak, izbjegla prevelika pristranost modela u odnosu na podatke na kojima je treniran (tzv. *overfitting*), dio podataka je izdvojen i za validaciju hiperparametara, što je ostvareno primjenom metode unakrsne validacije (engl. *cross-validation*), odnosno slučajnim dijeljenjem izvornog skupa podataka na skup za treniranje i na skup za validaciju. Time je omogućena procjena sposobnosti modela da generalizira naučene trendove na neviđene podatke [8, 14].

Za usporedbu i procjenu kvalitete razvijenih UI modela potrebno je definirati i odgovarajuće metričke pokazatelje. Budući da se pouzdanost modela ne može ocijeniti jednom metrikom, u ovome je radu analizirano više aspekata: numerička metrika, grafički prikaz rezultata, reziduali (ostaci) i distribucija predikcija [17].

Jedna od najčešće korištenih numeričkih metrika je pritom srednja apsolutna pogreška (engl. *mean absolute error* - MAE), koja se može izračunati kao [14, 17]:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (1)$$

Korijen srednje kvadratne pogreške (engl. *root mean square error* - RMSE) predstavlja standardnu devijaciju reziduala i mjeri prosječnu udaljenost predikcija od regresijske linije [14, 17]:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (2)$$

RMSE je uvijek jednak ili veći od MAE, a što je razlika veća, to je veća varijabilnost pojedinačnih grešaka.

Koeficijent determinacije, odnosno određenja (engl. *coefficient of determination* - R^2) opisuje, pak, udio varijance objašnjen modelom i definira se kao [14, 17]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2} \quad (3)$$

Vrijednosti bliže 1 označavaju bolju prilagodbu modela varijanci podataka.

2.2 Procjena kvalitete dobivenih modela

Za razliku od ML modela, a budući da se kod simboličke regresije dobivaju matematički izrazi, vrijednosti metrika MAE, RMSE i R^2 nisu dovoljne, nego je nužno procijeniti i složenost samih matematičkih izraza [10, 12]. Najbolji se model, stoga, bira kombinacijom maksimalnih vrijednosti parametra R^2 i minimalne složenosti izraza.

To se postiže metodom Paretoove granice (engl. *Pareto frontier*) [18, 19], kojom se identificiraju rješenja koja se mogu smatrati optimalnima prema više kriterija istodobno; u ovom su slučaju to ona koja istovremeno jamče minimalnu vrijednost $1-R^2$ i rezultiraju najmanjom složenošću dobivenih modela.

3. Genetsko programiranje temeljeno na UI - simbolička regresija

Iako ML modeli pokazuju visoku prediktivnu sposobnost, njihova praktična primjena u detaljnim analizama i numeričkom modeliranju je ograničena jer koriste velik broj parametara. Kako bi se postigla istovrsna razina prediktivne točnosti, ali uz dobivanje matematičkih izraza kojima se opisuje ovisnost nanometarskog trenja o utjecajnim parametrima, u ovom se radu zato primjenjuju evolucijski algoritmi (engl. *evolutionary algorithms* - EA) temeljeni na UI [14]. Doista, dobivanje analitičkih izraza ovisnosti vrijednosti trenja o procesnim parametrima predstavlja ne samo važan korak prema razumijevanju temeljnih fizikalnih zakonitosti, što je jedan od glavnih ciljeva provedenog istraživanja, nego omogućuje i integraciju u postojeće modele trenja, njihovu usporedbu i prilagodbu, kao i izravnu primjenu u predviđanju trenja te u adaptivnoj regulaciji sustava s trenjem.

Za razliku od klasičnih EA metoda, simbolička regresija (GP-SR) razvija populaciju čiji su rezultati simbolički izrazi, a ne samo numeričke predikcije. U ovom radu primijenjeno je više pristupa genetskog programiranja (GP) i to Kozaov pristup genetskom programiranju (engl. *Koza style* - KS GP) [11], gramatička evolucija (engl. *grammatical evolution* - GE GP) [20], genetsko programiranje s odabirom potomaka (engl. *offspring selection genetic programming* OS GP) [21], dobno-slojevita populacijska struktura (engl. *Age-Layered Population Structure* – ALPS GP) [10] te višegensko genetsko programiranje (engl. *Multi-Gene Genetic Programming* – MG GP) [10]. Ti algoritmi evoluiraju početnu populaciju slučajno generiranih izraza, istodobno vrednujući kvalitetu dobivenih jednadžbi prema definiranim metričkim kriterijima.

Dobiveni matematički modeli zatim su usporedno analizirani. Za procjenu njihove prediktivne učinkovitosti, modeli su trenirani na eksperimentalnim podacima uz deseterostruku unakrsnu validaciju [14], pri čemu je 30 % podataka korišteno za optimizaciju parametara, dok je konačna provjera provedena na neovisnom testnom skupu. U Tablici 2 prikazane su dobivene metričke vrijednosti za GP-SR modele trenirane na uzorcima tankih filmova TiO_2 dobivenih ALD taloženjem, te na uzorcima tankih filmova Al dobivenih PLD metodom taloženja, pri čemu se, uz vrijednosti MAE, RMSE i R^2 metrika, navode i duljina te dubina izraza, koje opisuju složenost modela (manje navedene vrijednosti označavaju jednostavnije i poželjnije modele). Iz prikazanih je rezultata vidljivo da se primjenom KS GP, OS GP i ALPS GP algoritama postižu slabiji rezultati, GE GP generira jednostavne matematičke izraze ali

opet uz slabiju metriku, dok MG GP metoda tendencijalno rezultira najboljim rezultatima. U radu je utvrđeno i da modeli trenirani na objedinjenoj bazi podataka svih materijala daju najbolje rezultate, što je u skladu s pravilom da veći skupovi podataka omogućuju bolju generalizaciju i točnija predviđanja [6].

Tablica 2: Usporedba prediktivnih svojstava UI modela na testnim skupovima podataka za TiO_2 (ALD) uzorke i za Al (PLD) uzorke tankih filmova [6]

Algoritam	Uzorak	RMSE	MAE	R ²	Duljina	Dubina
KS GP	TiO ₂	9,32	8,28	0,35	151	18
	Al	5,43	5,26	0,57	153	19
GE GP	TiO ₂	8,17	6,64	0,35	37	14
	Al	5,16	4,93	0,41	21	12
OS GP	TiO ₂	18,4	14,9	0,02	151	23
	Al	7,82	4,04	0,17	203	23
ALPS GP	TiO ₂	3,59	2,91	0,59	48	11
	Al	5,36	4,13	0,16	101	18
MG GP	TiO ₂	2,10	1,67	0,54	39	4
	Al	1,08	0,95	0,82	81	4

4. Validacija rezultata razvijenih UI modela

Na temelju gornje analize, MG GP model, treniran dodatno na objedinjenom skupu podataka za sva četiri analizirana materijala tankih filmova, odabire se kao najbolji te se dodatno ispituje na testnim skupovima pojedinih materijala. Dobiveni rezultati, prikazani u Tablici 3, pokazuju visoku prediktivnu točnost s vrijednostima koeficijenta determinacije R² u rasponu od 0,72 za TiO₂ do 0,91 za Al.

Tablica 3: Prediktivne metrike MG GP modela razvijenog na skupnim podacima razmatranih tankih filmova [6]

	RMSE	MAE	R ²
TiO ₂	2,19	1,51	0,725
Al	1,04	0,774	0,909

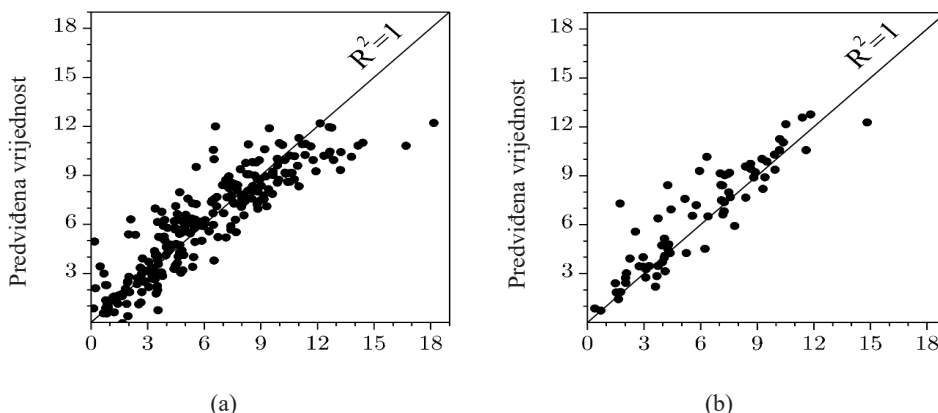
Rezultirajući MG GP modeli odabrani su kao najbolji pojedinci iz populacije od 5.000 modela u svakom ciklusu treniranja, što odgovara deset ponavljanja deseterostruke unakrsne validacije, s 50 gena korištenih u višegenskom programiranju. Kako bi se istodobno minimizirala složenost modela i vrijednost 1-R², odabir optimalnog rješenja proveden je onda pomoću Paretoove granice. Dobiveni optimalni model daje matematički izraz koji uključuje tri utjecajna procesna parametra (F_N , ϑ i ν) te binarne

(*dummy*) varijable (x_4 – x_7) koje označavaju materijale uzorka. Odgovarajuća jednadžba (4), koja odgovara dobivenim prediktivnim rezultatima, predstavlja optimalno rješenje koje povezuje nanometarsku silu trenja F_f s navedenim varijablama. Unatoč relativnoj složenosti, model je kompaktan, prediktivno vrlo učinkovit te, u usporedbi s konvencionalnim (*black-box*) ML modelima, znatno jednostavniji za praktičnu primjenu.

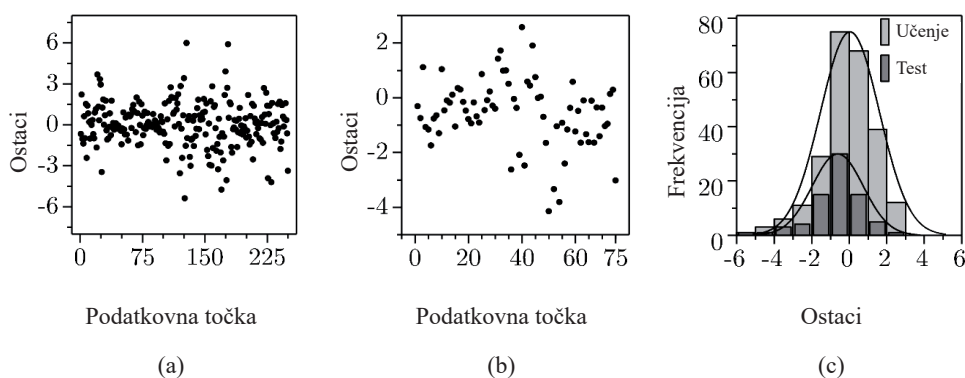
$$\begin{aligned}
 F_f = & 0,04559 \cdot F_L - 0,0008751 \cdot v - 0,1808 \cdot \vartheta + 2,824 \cdot x_4 + 4,512 \cdot x_5 - \\
 & -15,67 \cdot x_6 - 21,07 \cdot x_7 - 0,3031 \cdot \vartheta \cdot x_5 + 0,02764 \cdot (\vartheta + x_4 + x_5)^3 + \\
 & + 0,02599 \cdot (\vartheta + x_6 + x_7 + 3,994)^3 - 0,03376 \cdot F_L \cdot x_5^2 + \\
 & + 0,07963 \cdot \vartheta \cdot x_7^2 + 0,0005558 \cdot (\vartheta + 2 \cdot x_5 + 3,944)^3 - \\
 & -0,4198 \cdot \vartheta^2 - 0,05406 \cdot \vartheta^3 + 0,4198 \cdot x_4^3 - 0,0001781 \cdot F_L \cdot \vartheta \cdot x_4 - 15,92
 \end{aligned} \quad (4)$$

Prošireni oblik jednadžbe (4) predstavlja regresijski model koji je detaljnije analiziran kako bi se utvrdila njegova pouzdanost u predviđanju sile trenja [6]. Prvi korak u tom postupku je procjena raspršenosti između predviđenih i eksperimentalno izmjerenih vrijednosti. Model koji je dobro prilagođen eksperimentalnim podacima trebao bi idealno biti blizak liniji $R^2 = 1$ na kojoj bi sve eksperimentalne točke ležale kada ne bi bilo odstupanja u mjerenjima te kada bi model savršeno opisivao promatrani fizikalni fenomen. Na Slici 1 je vidljivo da razvijeni model pokazuje vrlo malu raspršenost predviđanja kod skupa za učenje (Slika 1a) kao i kod skupa za testiranje (Slika 1b). Predviđanja testnog skupa posebno su važna jer odražavaju sposobnost modela da predviđa nove, prethodno neviđene podatke, bez utjecaja pristranosti iz faze učenja. Prikaz na Slici 1b pokazuje izraženu linearnu povezanost i gusto grupiranje točaka oko linije $R^2 = 1$, što upućuje na vrlo dobru prediktivnu funkcionalnost.

Kako bi model uspješno predviđao buduća mjerenja, mora također odražavati i stohastička svojstva podataka [6]. To se statistički provjerava analizom grafičkih prikaza ostataka (reziduala) prikazanih na Slici 2, gdje je, s ciljem utvrđivanja slijede li prikazane točke slučajaj (stohastički) obrazac, prikazana razlika između predviđenih i eksperimentalnih vrijednosti. Pojava pravilnosti, poput zakrivljenog ili linearnog trenda, ukazivala bi na pristranost modela i činila bi ga nepouzdanim za predikciju. Na Slikama 2a i 2b vidljivo je da reziduali ukazuju na dobru slučajnost, bez vidljivih obrazaca. Sa Slike 2c je, pak, vidljivo da distribucija reziduala za oba skupa podataka slijedi Gaussovu raspodjelu, što potvrđuje normalnu raspodjelu ostataka i statističku valjanost modela.

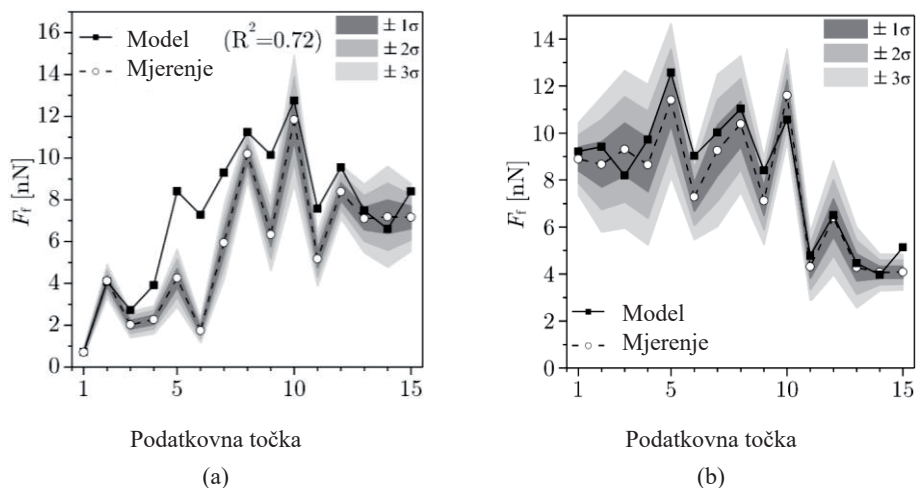


Slika 1: Predviđene vrijednosti modela iz jednadžbe (4) u odnosu na eksperimentalne podatke za skupove podataka za učenje (a) i za testiranje (b) [6]

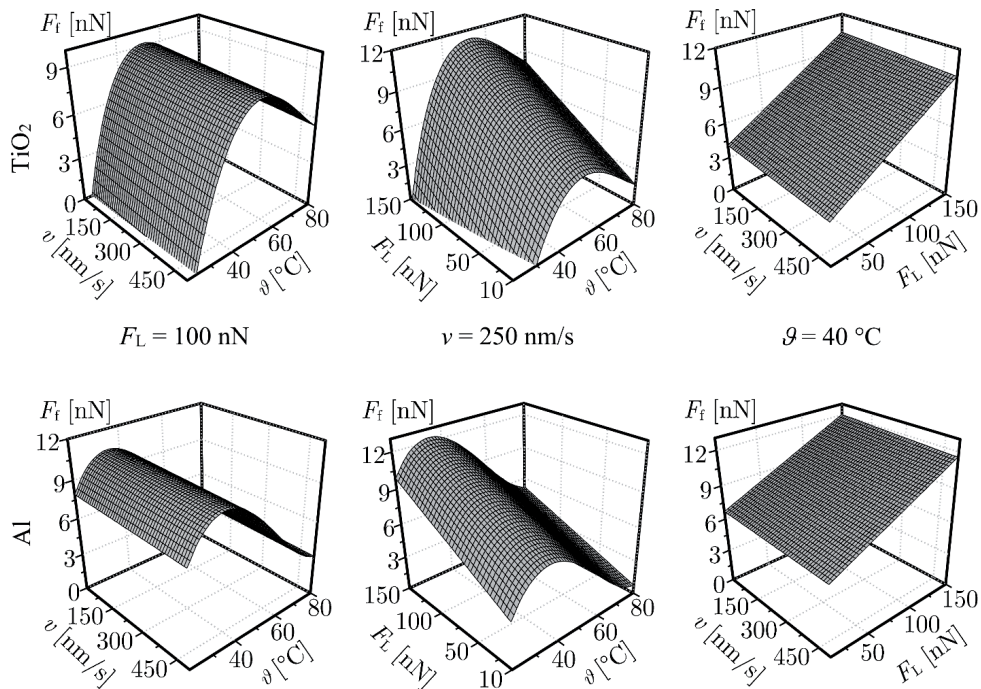


Slika 2: Reziduali (ostaci) modela iz jednadžbe (4) na podacima iz faze učenja (a) te na testnom skupu podataka (b), s odgovarajućim distribucijama (c) [6]

Razmatra se potom i prilagođenost razvijenog optimalnog UI MG GP modela za svaku od analiziranih vrsta materijala u testnom skupu podataka, odnosno sposobnost modela da pouzdano predviđi neviđene eksperimentalne podatke o nanometarskoj sili trenja F_f u ovisnosti o promatranim procesnim parametrima F_N , ν i \mathcal{G} , unatoč njihovoj stohastičnosti [6]. Na Slici 3a prikazana su predviđanja i eksperimentalni podaci za ALD-om sintetizirani uzorak TiO_2 tankog filma. Vidljivo je da, iako je podudarnost na prvih nekoliko točaka gotovo savršena, predviđanja djelomično pokazuju određena odstupanja od eksperimentalnih vrijednosti. To je uočeno kod gotovo svih razmatranih modela, a proizlazi iz specifične prirode distribucije podataka za ovaj uzorak. S druge strane, prilagođenost modela iz jednadžbe (4) na testnom skupu za PLD-om sintetizirani Al tanki film prikazana na Slici 3b pokazuje iznimno visoku kvalitetu, te je za sve eksperimentalne točke gotovo u potpunosti unutar dvostruke standardne devijacije.



Slika 3: Prediktivna sposobnost optimalnog razvijenog MG GP modela na testnom skupu podataka za TiO_2 (a) i Al (b) [6]



Slika 4: Vizualizacija rezultata optimalnog MG GP modela za konstantne varijable u stupcima (slijeva na desno) F_L , v i ϑ , za TiO_2 (gornji red) i Al (donji red) [6]

Na Slici 4 prikazane su, pak, vrijednosti nanometarske sile trenja F_f dobivene primjenom modela iz jednadžbe (4) pri variranju dvaju procesnih parametara, dok se treći drži konstantnim, i to na vrijednosti $F_N = 100$ nN, $v = 250$ nm/s te $\vartheta = 40$ °C [6]. Za ALD-om sintetizirani uzorak TiO_2 tankog filma (gornje slike), utjecaj brzine klizanja na trenje je gladak, uz negativan linearni učinak u odnosu na temperaturu. Utjecaj temperature je nelinearan i ostaje relativno stabilan pri promjeni brzine klizanja i normalne sile. Učinci brzine klizanja i normalne sile pokazuju, pak, izrazito linearnu ovisnost. Slične su korelacije vidljive na donjim slikama za PLD-om sintetizirani uzorak Al, što je snažna indikacija da je prilagođenost modela općem trendu fizikalnog fenomena izvrsna.

Rezultati dobiveni primjenom razvijenog optimalnog MG GP modela pokazuju, dakle, vrlo jasno sličnost u utjecaju razmatranih istovremeno djelujućih utjecajnih parametara na nanometarsko trenje, što je u ranijim istraživanjima ovog tipa bilo praktički nemoguće utvrditi. Nakon svih provedenih testova i evaluacija može se, stoga, zaključiti s relativno visokim stupnjem sigurnosti da razvijeni model ne samo vjerno reproducira eksperimentalne rezultate za razmatrane tanke filmove, nego i (što je još važnije) pruža robustan prediktivni alat, pa čak i matematičku formulaciju ovisnosti vrijednosti F_f o promatranim varijabilnim procesnim parametrima. Dokazano je, dakle, da predložena MG GP matematička formulacija omogućuje vrlo precizno i pouzdano predviđanje vrijednosti nanometarskog trenja za različite tanke filmove, kao i predviđanje utjecaja najvažnijih procesnih parametara na tu vrijednost [6].

Izraz u obliku danom jednadžbom (4) može se algebarski dodatno pojednostaviti u odnosu na razmatrane varijable, zamjenom binarnih kodnih parametara karakterističnih za svaki od korištenih materijala tankih filmova. Dobiva se tako gotovo zapanjujuće jednostavni izraz dan jednadžbom (5), kojom se izražava prediktivni model vrijednosti nanometarske sile trenja F_f u nN i njegova ovisnost o ukupnoj normalnoj sili $F_L = F_N + F_A$ (nN), brzini klizanja v (nm/s) i temperaturi ϑ (°C) [6]:

$$F_f = a \cdot F_L - 87,51 \cdot 10^{-5} \cdot v + b \cdot \vartheta - c \cdot F_L \cdot \vartheta - d \cdot \vartheta^2 + 12,58 \cdot 10^{-5} \cdot \vartheta^3 - e \quad (5)$$


Za ovdje razmatrane materijale su pripadajuće konstante a do e prikazane u Tablici 4, gdje je jasno vidljiva visoka razina sličnosti utjecaja sile F_L i brzine klizanja v na F_f za TiO_2 i Al. Vidljiva je pritom snažna linearna ovisnost F_f o F_L kroz istovrijedni faktor a , slabi linearni učinak brzine klizanja v kroz drugi član jednadžbe, te snažan nelinearan karakter utjecaja temperature, koji ima članove prvog, drugog i trećeg reda, uz intrigantnu interakciju s F_L putem koeficijenta c [6].

Tablica 4: Konstante koje definiraju prediktivni model jednadžbe (5) za razmatrane uzorke TiO_2 i Al tankih filmova [6]

	a	b	c	d	e
TiO₂	0,04559	1,831	0	0,02774	33,81
Al	0,04559	1,141	0,0001781	0,02279	11,02


Dobivena matematička formulacija izražena jednadžbom (5), sa svojom visokom prediktivnom učinkovitošću u izražavanju ovisnosti trenja na nanometarskoj razini o promatranim varijabilnim parametrima, iskorištena je potom za proučavanje utjecaja svakog razmatranog parametra zasebno, kao i za određivanje interakcije istovremenog utjecaja dvaju učinaka na nanometarsko trenje. Dobivena rješenja se dodatno grafički analiziraju kako bi se sagledale implikacije i učinci promatranih procesnih parametra na trenje.

Rješenja jednadžbe (5) dana su, stoga, grafički na Slici 5 da bi se vizualno prikazala ovisnost nanometarske sile trenja F_f o ukupnoj normalnoj sili F_L , pri varijabilnoj temperaturi ϑ i brzini klizanja v . Vidljiva je tu linearna ovisnost o opterećenju, što je u skladu i s predviđanjima kontaktne mehanike kada se u obzir uzmu učinci adhezije [22]. Dobivene linearne ovisnosti pokazuju također blagi oslabljujući učinak brzine klizanja v , što je eksperimentalno potvrđeno i u ranijim radovima [23], pri čemu se pad sile trenja s porastom brzine klizanja najčešće pripisuje mazivom učinku sloja vodene pare adsorbiranog na površini uzoraka. Može se uočiti i složeni međudnos sile adhezije i trenja, gdje prikazane linije, kao posljedica dominantnog utjecaja adhezije, pokazuju promjenu nagiba i presjeka s osi y pri promjeni temperature. Kako je već primijećeno u radu [3], budući da u nanometarskom području utjecaj vodenog meniskusa postaje značajan te povećava ukupne kontaktne sile, ovaj se učinak superponira učinku normalne sile. Promjena temperature mijenja, pak, količinu adsorbirane vode, odnosno utječe na stanje meniskusa, mijenjajući sile adhezije pa time i ukupna normalna opterećenja koja djeluju na površinu tankih filmova.



Slika 5: Ovisnost F_f o F_L dobivena iz razvijenog MG GP modela za različite vrijednosti v (puna linija: $v = 5$ nm/s, isprekidana linija: $v = 255$ nm/s, točkasta linija: $v = 500$ nm/s) i ϑ za TiO_2 (a) i Al (b) [6]

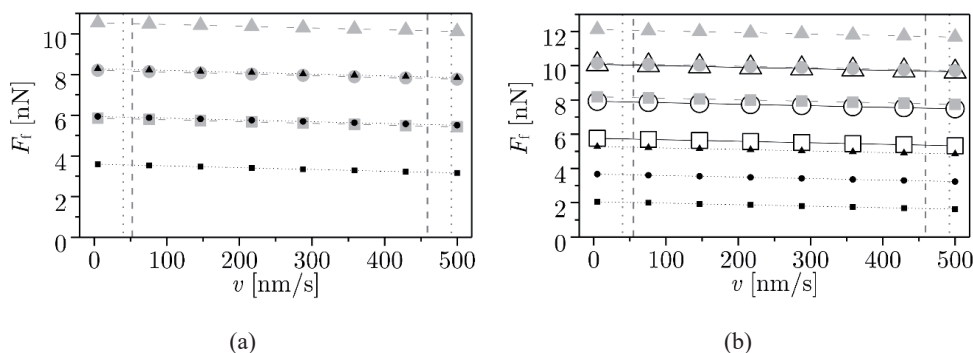
Varijabilnost utjecaja temperature vidljiva je i na dijagramima na Slici 6, što se može uočiti iz razmaka između prikazanih linija trenja. Veći razmak uzrokovan promjenom temperature ϑ ukazuje pritom na izraženiji temperaturni učinak.



Slika 6: Ovisnost F_f o θ dobivena iz razvijenog MG GP modela za različite vrijednosti v (puna linija: $v = 5$ nm/s, isprekidana linija: $v = 255$ nm/s, točkasta linija: $v = 500$ nm/s) i F_L (A: $F_L = 10$ nN, B: $F_L = 50$ nN, C: $F_L = 100$ nN, D: $F_L = 150$ nN), za TiO_2 (a) i Al (b) [6]

Utjecaj brzine klizanja na vrijednost nanometarskog trenja prikazan je, konačno, za razmatrane tanke filmove na Slici 7. Tu je vizualizacija nešto zahtjevnija zbog dvaju snažnih preklapajućih učinaka u preostale dvije dimenzije. Ipak, jasno je da je utjecaj v uglavnom malen i, kao što je već više puta navedeno, oslabljujući, dok jači nelinearni utjecaj temperature θ mijenja apsolutnu vrijednost učinka brzine, ali ne i trendove niti intenzitet tog učinka. Utjecaj F_L također je vidljiv kao linearni pomak skupina linija F_f u odnosu na v , što uzrokuje povećanje vrijednosti F_f .

Grafovi na Slikama 5, 6 i 7 prikazuju, dakle, vrijednosti nanometarske sile trenja F_f dobivene korištenjem funkcionalnih ovisnosti iz jednadžbe (5) za razmatranu skupinu materijala tankih filmova i sve analizirane varijabilne procesne parametre. Ovi se grafovi mogu koristiti kao grafički alat za određivanje očekivanih vrijednosti F_f . Na dijagramima su također prikazane okomite isprekidane i točkaste granične linije koje označavaju granice razmatranih varijabli u glavnom i testnom skupu podataka. Budući da su modeli korišteni za dobivanje grafova trenirani i testirani isključivo unutar tih granica, ove linije određuju svojevrsnu marginu njihove valjanosti.



Slika 7: Ovisnost F_f o v dobivena iz razvijenog MG GP modela za različite vrijednosti F_L (kvadratna oznaka: $F_L = 50$ nN, krug: $F_L = 100$ nN, trokut: $F_L = 150$ nN) i θ (bijela ispunjena: $\theta = 20$ °C, siva ispunjena: $\theta = 40$ °C, crna ispunjena: $\theta = 80$ °C) za TiO_2 (a) i Al (b) [6]

5. Zaključak i buduća istraživanja

Na temelju strukturirane metodologije za eksperimentalno određivanje trenja na nanometarskoj razini pod istodobnim utjecajem više parametara, normalne sile, brzine klizanja i temperature, razvijene na naprednom DoE postupku i odgovarajućem postavljanju mjernog procesa, u ovom je radu prikazan sustavan proces rudarenja podataka s ciljem dobivanja dubokih i metodičnih uvida u nanometarsko trenje. Metodologija se temelji na primjeni više suvremenih metoda UI, s ciljem dobivanja jednostavne matematičke formulacije koja povezuje sve promatrane utjecaje. Primijenjeni su algoritmi UI genetskog programiranja metodom simboličke regresije (GP SR). Dobiven je tako iznimno jednostavan matematički izraz, s vrlo visokim prediktivnim svojstvima, razvijen primjenom višegenskog genetskog programiranja (MG GP).

Razvijenim je modelima potvrđen mali utjecaj brzine klizanja, snažan pozitivan utjecaj ukupne normalne sile te izraženo nelinearan utjecaj temperature na trenje na nanometarskoj razini. Dobivene korelacijske funkcije, koje povezuju promatrane procesne varijable s vrijednošću nanometarskog trenja, pružaju ne samo vrlo detaljan uvid u proučavane pojave složenih interakcija, već i izuzetno koristan i originalan doprinos području nanotribologije. Procjena velikog broja eksperimentalnih rezultata primjenom suvremenih numeričkih metoda, sustavna evaluacija njihovih prediktivnih svojstava te inovativni predloženi model s jednostavnom implementacijom, prikladan za praktičnu primjenu, predstavljaju važne doprinose provedenog istraživanja.

Sve navedeno stvara preduvjete za temeljno razumijevanje i praktična poboljšanja u području nanotribologije, te donosi novi uvid u ovaj fundamentalni fizikalni i inženjerski fenomen. To bi u konačnici trebalo omogućiti proširenje formulacije postojećih modela trenja na nanometarsku domenu, čime se stvaraju temelji za razvoj proširenih modela trenja i naprednih zakonitosti upravljanja, što sve doprinosi povećanju preciznosti konstrukcijskih komponenti i preciznosti pozicioniranja strukturnih elemenata i sustava u nanometarskom području. Rezultati provedenog istraživanja omogućuju također višeskalarni pristup povezivanju nanotribologije s mikro-, mezo-, na gornjem kraju dimenzijske skale, makroskopskim sustavima s trenjem, čime se u inženjerskoj praksi otvara mogućnost razvoja i modificiranja postojećih algoritama upravljanja i numeričkih modela.

6. Literatura

- [1] Bhushan, B. (ur.): *Handbook of micro/nanotribology* - 2nd ed., u The mechanics and materials science series, Boca Raton: CRC Press (1999).
- [2] Bhushan, B.: *Introduction to tribology* - 2nd ed., u Tribology series, Chichester, West Sussex, UK: John Wiley & Sons Inc. (2013).

- [3] Perčić, M.; Zelenika, S., Mezić, I., Peter, R., Krstulović, N.: An experimental methodology for the concurrent characterization of multiple parameters influencing nanoscale friction, *Friction*, **8** (2020) 3, 577-593, <https://doi.org/10.1016/10.1007/s40544-019-0289-z>
- [4] Du, Q.; Faber, V., Gunzburger, M.: Centroidal Voronoi Tessellations: Applications and Algorithms, *SIAM Rev.*, **41** (1999) 4, 637-676, <https://doi.org/10.1137/S0036144599352836>
- [5] Mandel, J.: *The Statistical Analysis of Experimental Data*, Courier Corporation (2012).
- [6] Perčić, M.; Zelenika, S., Mezić, I.: Artificial intelligence-based predictive model of nanoscale friction using experimental data, *Friction*, **9** (2021) 6, 1726-1748, <https://doi.org/10.1007/s40544-021-0493-5>
- [7] de Silva, B. M.; Higdon, D. M., Brunton, S. L., Kutz, J. N.: Discovery of Physics From Data: Universal Laws and Discrepancies, *Front. Artif. Intell.*, **3** (2020) 1-25, <https://doi.org/10/ggw4nr>
- [8] Kecman, V.: *Learning and soft computing: support vector machines, neural networks, and fuzzy logic models*, u *Complex adaptive systems*, Cambridge, Mass: MIT Press (2001).
- [9] Billard, L.; Diday, E.: *Symbolic Data Analysis: Conceptual Statistics and Data Mining*, Chichester (UK): John Wiley & Sons (2012).
- [10] Riolo, R.; Worzel, B. (ur.): *Genetic Programming Theory and Practice*, u *Genetic Programming*, Springer US (2003), <https://doi.org/10.1007/978-1-4419-8983-3>
- [11] Koza, J. R.: Human-competitive results produced by genetic programming, *Genet Program Evolvable Mach*, **11** (2010) 3, 251-284, <https://doi.org/10/bz8br8>
- [12] Langdon, W. B.; Poli, R.: *Foundations of Genetic Programming*. Berlin Heidelberg: Springer-Verlag (2002), <https://doi.org/10.1007/978-3-662-04726-2>
- [13] Schmidt, M.; Lipson, H.: Distilling Free-Form Natural Laws from Experimental Data, *Science*, **324** (2009) 5923, 81-85, <https://doi.org/10.1126/science.1165893>
- [14] Hastie, T.; Tibshirani, R., Friedman, J.: *The Elements of Statistical Learning: Data Mining, Inference, and Prediction - 2nd ed.*, u *Springer Series in Statistics*, New York: Springer-Verlag (2009).
- [15] Gentle, J. E.: *Random Number Generation and Monte Carlo Methods*, u *Statistics and Computing*, New York: Springer-Verlag (1998), <https://doi.org/10.1007/978-1-4757-2960-3>
- [16] "GoSUMD", AIMdyn. <https://aimdyn.com/gosumd/>, *Pristupljeno*: 15. 05 2018.
- [17] Draper, N. R.; Smith, H.: *Applied Regression Analysis - 3rd ed.*, John Wiley & Sons (1998).
- [18] Knowles, J.; Corne, D., Deb, K. (ur.): *Multiobjective Problem Solving from Nature: From Concepts to Applications*, u *Natural Computing Series*. Berlin Heidelberg: Springer-Verlag (2008), <https://doi.org/10.1007/978-3-540-72964-8>
- [19] Lotov, A.; Bushenkov, V. A., Kamenev, G. K.: *Interactive Decision Maps: Approximation and Visualization of Pareto Frontier*, u *Applied Optimization*. Springer US (2004), <https://doi.org/10.1007/978-1-4419-8851-5>
- [20] Ryan, C.; O'Neill, M., Collins, J. J. (ur.): *Handbook of Grammatical Evolution*. Springer Int. Publ. (2018), <https://doi.org/10.1007/978-3-319-78717-6>
- [21] Affenzeller, M.; Wagner, S.: Offspring Selection: A New Self-Adaptive Selection Scheme for Genetic Algorithms, u *Adaptive and Natural Computing Algorithms*, Ribeiro, B.; Albrecht, R. F., Dobnikar, A., Pearson, D. W., Steele, N. C. (ur.), Vienna: Springer (2005), 218-221, <https://doi.org/10/bj3s8g>

- [22] Derjaguin, B. V.; Muller, V. M., Toporov, Y. P.: Effect of contact deformations on the adhesion of particles, *J. Colloid & Interface Sci.*, **53** (1975) 2, 314-326, <https://doi.org/10/dnf7ks>
- [23] Dagdeviren, O. E.: Exploring load, velocity, and surface disorder dependence of friction with one-dimensional and two-dimensional models, *Nanotechnology*, **29** (2018) 31, 315704, <https://doi.org/10.1088/1361-6528/aac43b>

Zahvale

Ovaj je rad napisan zahvaljujući potpori osiguranoj istraživačkim projektima Sveučilišta u Rijeci uniri-zi-25-256 “Višeskalarno interdisciplinarno nanotriboško istraživanje nanomaterijala” i uniri-mzi-25-4 “Praćenje stanja okoliša mrežom autonomnih senzora (EMAS)” koje financira Europska unija – NextGenerationEU.

Primjena metoda umjetne inteligencije u naprednim oksidacijskim procesima: fokus na fotokatalitičku razgradnju organskih mikrozagađivala

Irena Žmak¹, Lidija Ćurković¹, Paola Grobensi¹

¹Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje, Ulica Ivana Lučića 5, 10000 Zagreb

Sažetak: Primjena metoda umjetne inteligencije, osobito umjetnih neuronskih mreža, u fotokatalitičkoj razgradnji organskih mikrozagađivala (OMZ) danas predstavlja jedno od najdinamičnijih područja inženjerstva okoliša. Ovaj rad daje pregled aktualnih pristupa optimizaciji i predviđanju učinkovitosti fotokatalitičkih procesa primjenom različitih algoritama strojnog učenja. Posebna pozornost posvećena je hibridnim modelima, metodama odzivne površine te fizikalno-informiranim neuronskim mrežama kao perspektivnim alatima za industrijsku primjenu. Rezultati pokazuju da neuronske mreže dosljedno postižu visoku prediktivnu točnost, s koeficijentima determinacije iznad 0,95, čime se potvrđuje njihov potencijal kao pouzdanih inženjerskih alata u zaštiti okoliša.

Ključne riječi: umjetna inteligencija, umjetne neuronske mreže, strojno učenje, fotokataliza, organska mikrozagađivala

1. Uvod

Umjetna inteligencija (engl. *artificial intelligence*, AI) danas je jedna od najčešće spominjanih tema u znanosti i industriji. Pojmovi poput strojnog učenja (engl. *machine learning*), umjetnih neuronskih mreža (skraćeno ANN, prema engl. *artificial neural networks*) i velikih jezičnih modela (skraćeno LLM, prema engl. *large language models*) ušli su u svakodnevni rječnik, a rijetko koja struka propušta naglasiti da svoje procese transformira uz pomoć AI alata. Povijesni razvoj započinje šezdesetih godina prošlog stoljeća s idejom o algoritmima sposobnima za učenje iz podataka. Takvi sustavi, modelirani prema biološkim neuronskim mrežama, omogućuju rješavanje problema bez eksplicitnih uputa ili kruto postavljenih matematičkih okvira. Umjetna inteligencija u širem smislu obuhvaća raznolike metode, od neuronskih mreža i

strojnog učenja, preko genetičkih algoritama i neizrazite (engl. *fuzzy*) logike, do ekspertnih sustava i dubokog učenja, kojima računalni sustavi prepoznaju uzorke, uče iz podataka i podupiru donošenje odluka u složenim sustavima.

Krajem devedesetih godina 20. stoljeća umjetne neuronske mreže izazvale su značajan napredak u znanosti o materijalima i inženjerstvu, potaknute popularnošću algoritma povratnoga rasprostiranja pogreške. U tom razdoblju znanstvenici su počeli koristiti te modele za rješavanje različitih izazova, poput uspostavljanja složenih veza između strukture i svojstava materijala, optimizacije proizvodnih procesa i analize spektroskopskih podataka. Mogućnosti umjetnih neuronskih mreža danas obuhvaćaju širok spektar primjena, čime su postale nezaobilazan okvir za modeliranje nelinearnih odnosa i unaprjeđenje industrijske proizvodnje [1]. Na primjer, rane primjene pokazale su sposobnost upotrebe u strojnoj obradi materijala, gdje su neuronske mreže korištene za predviđanje sila rezanja pri tokarenju "pamćenjem" složene mehanike obrade metala, koja se klasičnim analitičkim modelima vrlo teško opisuju [2].

Model umjetnih neuronskih mreža našao je široku primjenu i u zaštiti okoliša, gdje su nelinearne mreže razvijene za postrojenja za pročišćavanje otpadnih voda s ciljem predviđanja dotoka otpadne vode i kvalitete vode tijekom složenih kišnih događaja [3]. Uvedene su metode nenadgledanog učenja, poput Kohonenovih samoorganizirajućih karata značajki, koje se koriste za klasifikaciju opsežnih skupova operativnih podataka. Te metode pomažu u vizualnoj identifikaciji procesnih varijabli, koje su odgovorne za visoke koncentracije fekalne koliformne bakterije i biokemijsku potrošnju kisika [4]. Prediktivne sposobnosti neuronskih mreža uspješno su primijenjene i na problematiku teških metala, primjerice u preciznom modeliranju učinkovitosti adsorpcije olova iz vodenih otopina na otpadne materijale poput ljuski pistacija [5]. Usporediva točnost ostvarena je i u specijaliziranim tehnologijama obrade, gdje višeslojne mreže prate nelinearno ponašanje u uklanjanju olova elektrodijalizom [6]. Složenost naprednih oksidacijskih procesa rješava se mrežama s povratnim rasprostiranjem pogreške za simulaciju i predviđanje uklanjanja kemijske potrošnje kisika tijekom razgradnje opasnih antibiotika Fentonovim procesom [7].

Primjena umjetnih neuronskih mreža u kemiji i inženjerstvu nije bila ograničena isključivo na vodeće međunarodne institucije. Hrvatska znanstvena zajednica aktivno prati ovaj razvoj od samih početaka, dajući svoj doprinos još od ranih devedesetih godina 20. stoljeća. Metoda konformacijskih preferencijskih funkcija primijenjena je za predviđanje sekundarne strukture membranskih proteina s točnošću od 84 %, nadmašujući tadašnje neuronske mreže [8, 9]. Genetički algoritmi primijenjeni su u radu iz 1995. godine i za automatsku prilagodbu arhitekture neuronskih mreža, s posebnim osvrtom na problem tzv. deceptije koji uzrokuje nekonvergentnost optimizacije [10], gdje je deceptija mogućnost da dobrota (engl. *fitness*) nekog niza nije u korelaciji s dobrotom njegovih sastavnih podnizova. Neuronske mreže temeljene na analizi glavnih komponenti pokazale su se učinkovitima 1998. godine za modeliranje i adaptivno upravljanje industrijskom proizvodnjom pekarskog kvasca, uz prosječnu relativnu pogrešku od 1 do 10 % [11].

Osnovna jedinica sustava koji oponaša rad ljudskog mozga je umjetni neuron, matematički operator koji prima otežane ulazne signale, zbraja ih i kroz aktivacijsku funkciju generira odziv. Međusobnim povezivanjem velikog broja takvih neurona u ulazni sloj, jedan ili više skrivenih slojeva i izlazni sloj nastaje umjetna neuronska mreža sposobna prepoznati skrivene uzročno-posljedične veze unutar eksperimentalnih podataka. Za razliku od tradicionalne linearne regresije, ANN uspješno modeliraju interakcije velikog broja varijabli, što je ključno u inženjerstvu materijala, gdje kemijski sastav, parametri toplinske obrade i mikrostruktura tvore složenu mrežu često nepoznatih međuzavisnosti [12]. Predviđanje mikrostrukture i mehaničkih svojstava središnja je domena primjene neuronskih mreža, budući da su ta svojstva izravna, ali često nelinearna posljedica prethodnih postupaka dobivanja, prerade ili toplinske obrade materijala. ANN su primijenjene za predviđanje parametara mikrostrukture nodularnog lijeva, kao što su nodularnost grafita, broj nodula po jedinici površine te udio ferita i perlita, pri čemu su ulazni podatci karakteristične točke krivulje hlađenja dobivene toplinskom analizom. Kao jedna od metoda u istraživanju dentalnih materijala, neuronske mreže su uspješno primijenjene za predviđanje vrijednosti količine eluiranih iona iz dentalne keramike nakon izlaganja klorovodičnoj kiselini [13]. Za modeliranje mehaničkih svojstava koriste se napredni algoritmi poput Levenberg-Marquardta, koji osigurava brzu konvergenciju prema globalnoj minimalnoj pogrešci i visoku točnost predviđanja za nove kemijske sastave, bez potrebe za dugotrajnim ljevaoničkim pokusima i laboratorijskim ispitivanjima.

Optimizacija tehnoloških parametara toplinske obrade i lijevanja još je jedno područje gdje AI daje mjerljive rezultate. Neuronske mreže koriste se za određivanje optimalnog trajanja nitriranja u plazmi, predviđanje ugljikovog potencijala kod pougljičavanja čelika ili procjenu dubine boridnog sloja [14]. Osim toga, u inženjerstvu materijala koriste se za predviđanje prokaljivosti čelika na temelju kemijskog sastava, toplinske vodljivosti čelika na povišenim temperaturama, što je svojstvo vrlo važno kod simulacija ohlađivanja pri kaljenju, tvrdoće konvencionalno nitriranih čelika i drugih [15]. U ljevačkoj industriji, računalno potpomognuti alati omogućuju kontrolu stanja taline i analizu procesa skrućivanja u stvarnom vremenu, identificirajući potrebu za korekcijom taline prije ulijevanja u kalup. Genetički algoritmi (GA) pritom služe kao dodatni sloj optimizacije, jer oni biraju optimalnu arhitekturu i algoritam učenja neuronske mreže, smanjuju rizik od preučenosti ili pretreniranosti (engl. *overfitting*) i osiguravaju dobru generalizaciju modela [16].


Primjena umjetne inteligencije u inženjerstvu materijala nije samo trenutni tehnološki trend. Riječ je o pristupima koji omogućuju rješavanje izrazito složenih, nelinearnih problema koje klasične matematičke i statističke metode ne mogu obuhvatiti. Jedna od već dobro uspostavljenih primjena je optimizacija izbora materijala u složenim radnim uvjetima, gdje je potrebno istovremeno zadovoljiti kriterije funkcionalnosti, trajnosti, otpornosti na trošenje i koroziju, tehnologičnosti, recikličnosti i ekologičnosti [17]. Klasični ekspertni sustavi, temeljeni na fiksnim pravilima tipa “ako-tada”, nailaze na granice kada broj varijabli i njihovih interakcija postane pre-

velik za eksplicitno programiranje. Rješenje leži u hibridnim sustavima koji integri-
raju neuronske mreže i neizrazitu (*fuzzy*) logiku, omogućujući asocijativnu procjenu
prikladnosti materijala čak i pri nepotpunim informacijama. Takvi sustavi integriraju
mehanizme zaključivanja prema naprijed i unatrag, omogućujući istraživanje scena-
rija putem modula “što ako?” i objašnjenje logike putem modula “zašto?”. Primjena
neizrazite logike omogućuje kvantifikaciju nepreciznih inženjerskih pojmova, poput
“niske temperature” ili “visoke agresivnosti medija”, pretvarajući ih u lingvističke
varijable s funkcijama pripadnosti. Posebno su vrijedni tzv. *neuro-fuzzy* modeli koji
kombiniraju sposobnost učenja neuronskih mreža s interpretabilnošću neizrazite lo-
gike. Na taj način inteligentni sustavi ne samo da predlažu rješenja, već povećavaju
pouzdanost odlučivanja u kritičnim inženjerskim primjenama.

2. Primjena umjetne inteligencije u fotokatalitičkoj razgradnji organskih mikrozagađivala

Ubrzani rast svjetske populacije, urbanizacija i klimatske promjene doveli su do sve
izraženije globalne vodne krize, uz istodobno pogoršanje kvalitete dostupnih vodnih
resursa [16-18]. Uz kvantitativna ograničenja, poseban problem predstavlja prisut-
nost tzv. novih onečišćivala (engl. *emerging contaminants*), odnosno organskih mi-
krozagađivala (OMZ), koja uključuju pesticide, farmaceutike, proizvode za osobnu
higijenu, hormone, endokrine modulatore, razne industrijske spojeve te njihove tran-
sformacijske produkte [17]. Te spojeve karakterizira visoka kemijska postojanost,
sklonost bioakumulaciji te potencijalno štetan utjecaj na vodene ekosustave i ljudsko
zdravlje. Iako su često prisutni u vrlo niskim koncentracijama, njihovi kumulativni
učinci predstavljaju značajan ekološki i zdravstveni rizik. Dodatni izazov proizlazi
iz činjenice da konvencionalni sustavi obrade voda nisu projektirani za njihovo učin-
kovito uklanjanje, što omogućuje njihovo širenje u površinske i podzemne vodne
sustave te uključivanje u prehrambeni lanac [22]. U takvim uvjetima raste potreba
za razvojem naprednih tehnologija obrade vode koje omogućuju učinkovito uklanja-
nje organskih mikrozagađivala. Napredni oksidacijski procesi (skraćeno AOP, prema
engl. *advanced oxidation processes*) ubrajaju se među najperspektivnije pristupe jer
se temelje na generiranju visoko reaktivnih oksidacijskih vrsta sposobnih za razgrad-
nju složenih organskih molekula. Unutar te skupine, heterogena fotokataliza poseb-
no se ističe zbog svoje učinkovitosti i mogućnosti primjene u različitim sustavima
obrade voda [18]. Međutim, učinkovitost fotokatalitičkih procesa ovisi o složenom
međudjelovanju brojnih parametara: pH-vrijednosti medija, količini katalizatora, in-
tenzitetu i valnoj duljini zračenja, početnoj koncentraciji organskih mikrozagađivala
i svojstvima samog fotokatalitičkog materijala (Slika 1), što otežava njihovo mo-
deliranje i optimizaciju primjenom klasičnih pristupa. Klasični pristup optimizaciji
temeljen na jednofaktorskim eksperimentima ne može u potpunosti obuhvatiti te in-
terakcije, a sveobuhvatno eksperimentalno istraživanje svih kombinacija parametara
bilo bi vremenski i financijski neizvedivo. Upravo tu nastupa umjetna inteligencija:

integracijom naprednih algoritama strojnog učenja s dizajnom eksperimenata moguće je izgraditi pouzdane prediktivne modele koji iz relativno malog broja mjerenja izvlače maksimum informacija, ubrzavaju optimizaciju i otvaraju put prema industrijskoj primjeni razvijenih rješenja. Korištenje AI alata ne samo da optimizira postojeće procese, već također služi kao vodič za dizajniranje novih fotokatalitičkih materijala s boljom apsorpcijom vidljive svjetlosti.



Slika 1: Shematski prikaz modela umjetne inteligencije za predviđanje učinkovitosti fotokatalitičke razgradnje na temelju podataka o utjecajnim čimbenicima [19]

2.1 Modeli strojnog učenja za optimizaciju fotokatalitičkih procesa


Sustavnim pregledima literature i eksperimentalnih studija ocjenjuje se učinkovitost različitih fotokatalizatora (TiO_2 , ZnO ili CdS) u kombinaciji s modelima umjetnih neuronskih mreža, metodom potpornih vektora i metodom odzivnih površina (engl. *response surface methodology*, RSM) [19]. Glavni cilj je utvrditi kako navedeni modeli mogu precizno predvidjeti razinu razgradnje organskih mikrozagađivala i optimizirati procesne uvjete bez potrebe za brojnim, skupim i dugotrajnim laboratorijskim testovima [20].

Metodološki gledano, primjenjuju se različite arhitekture neuronskih mreža, kao što su višeslojni perceptron, radijalne bazne funkcije i rekurentne mreže, za čije se učenje primjenjuju algoritmi poput Levenberg-Marquardtova algoritma. Ključni ulazni parametri su količina katalizatora, pH-vrijednost otopine, početna koncentracija organskih mikrozagađivala, vrijeme razgradnje i intenzitet zračenja, koji se procesiraju kroz skrivene slojeve s otežanim neuronima u cilju generiranja predviđenog izlaza [21]. U usporedbi s modelima RSM, bilo da su sa središnjim kompozitnim planom pokusa ili s Box-Behnkenovim, neuronske mreže pokazuju prednost u upravljanju izrazito nelinearnim interakcijama i nesigurnim parametrima okoliša. Točnost predviđanja dosljedno je visoka, s koeficijentima determinacije iznad 0,95, što potvrđuje pouzdanost tih modela kao praktičnih inženjerskih alata. Pokazalo se da su pH-vrijednost i količina katali-

zatora ključni faktori: primjerice, kod razgradnje norfloksacina pH-vrijednost bliska neutralnoj često osigurava optimalnu adsorpciju na površinu katalizatora, dok prevelika doza fotokatalizatora može smanjiti učinkovitost zbog efekta zasjenjenja i aglomeracije čestica. Napredni oksidacijski proces za uklanjanje norfloksacina uz pomoć plazme iz otpadnih voda modeliran je pomoću strojnog učenja i uspoređen je s više klasičnih algoritama u predviđanju učinkovitosti uklanjanja i energetske potrošnje. Model umjetne neuronske mreže, optimiziran algoritmom optimizacije balegara, pokazao se najboljim, postigavši koeficijent determinacije od 0,9981 i srednji korijen kvadratne pogreške 0,017435, uz eksperimentalno potvrđenu učinkovitost uklanjanja norfloksacina od 94,35 % pri potrošnji energije od 1,766 kWh/g [22].

2.2 Metoda odzivne površine u optimizaciji procesnih parametara

U potrazi za učinkovitijim rješenjima, istraživačka pozornost usmjerena je na razvoj i testiranje specifičnih nanokompozitnih fotokatalizatora za razgradnju benzofenona (UV-filtar), karbamazepina (antiepileptik) i amoksicilina (antibiotik). Pritom je ključnu ulogu odigrala primjena naprednih matematičkih modela za precizno određivanje optimalnih uvjeta procesa razgradnje, čime se znatno smanjuje potreba za dugotrajnim laboratorijskim pokusima metodom pokušaja i pogreške [23]. Cilj takvih istraživanja je sintetizirati inovativne nanokompozitne fotokatalizatore, poput CuWO_4/NiO (Slika 2), aktivni ugljen dobiven iz ljuski argana/ TiO_2 i grafen oksid/ TiO_2 , kako bi se postigla visoka učinkovitost razgradnje pod vidljivom svjetlošću uz minimalan utjecaj na okoliš.



Slika 2: Grafički prikaz fotokatalitičke razgradnje benzofenona nanokompozitom CuWO_4/NiO [23]

Metodološki, istraživanja se u velikoj mjeri oslanjaju na metodu odzivne površine i središnji kompozitni plan pokusa kao ključne alate za modeliranje i optimizaciju procesa uz minimalan broj pokusa. Dok rad na benzofenonu koristi programska podrška JMP Pro za analizu interakcija faktora, studija o amoksicilinu ide korak dalje uspoređujući RSM s umjetnim neuronskim mrežama i adaptivnim neuro-neizrazitim sustavima zaključivanja, tzv. modelima ANFIS (engl. *adaptive neuro-fuzzy inference system*), koji predstavljaju hibridne sustave gdje se kombiniraju prednosti umjetnih neuronskih mreža i neizrazite logike [23, 24]. Utvrđeno je da metoda odzivne površine i ANN pružaju izvrsnu prediktivnu sposobnost s koeficijentima determinacije koji često dosegnu 0,99, dok se ANFIS pokazao nešto manje točnim u predviđanju nelinearnih odnosa u fotokatalizi [25]. Rezultati potvrđuju da opisani pristup nije tek metodološki napredak, već da on donosi i mjerljive, visoke učinkovitosti u praksi. Učinkovitost razgradnje u idealnim uvjetima iznosi oko 91,93 % za benzofenon te 91,01 % za amoksicilin. Ključni čimbenici koji utječu na proces su pH-vrijednost medija, količina katalizatora i vrijeme razgradnje. Alkalni uvjeti (pH 11) pogoduju razgradnji benzofenona, dok je za amoksicilin najučinkovitiji pH-raspon od 2,7 do 6,5 zbog elektrostatskog privlačenja. Studija o karbamazepinu dodatno naglašava ulogu otopljenog kisika i temperature, pokazujući da zasićenje kisikom značajno poboljšava učinkovitost fotokatalize, smanjujući rekombinaciju parova elektron-šupljina.

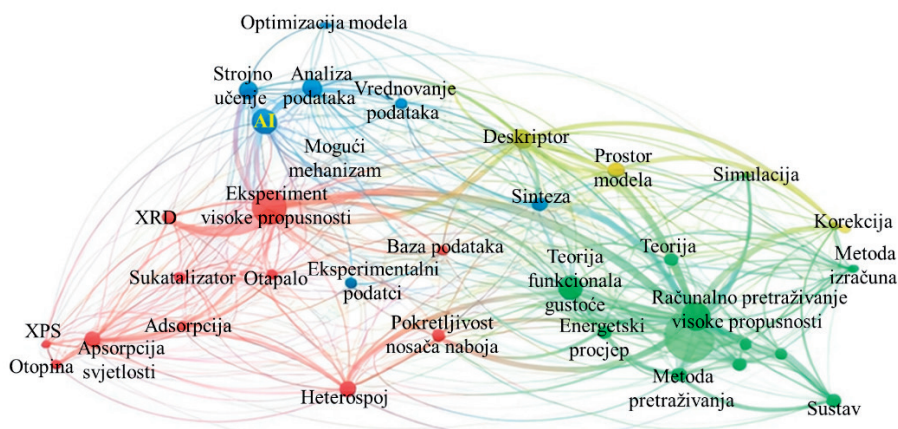
Sve to odražava pomak u fotokatalizi prema preciznijoj inženjerskoj disciplini, što je posebno izraženo uvođenjem koncepta kvalitete ugrađene u dizajn (engl. *quality by design*, QbD) i koncepta dizajna u prostoru (engl. *design space*, DS) [25]. QbD je sustavni, znanstveno utemeljen pristup razvoju procesa koji se usredotočuje na razumijevanje svih varijabli koje utječu na konačni rezultat, dok se DS definira kao višedimenzionalna kombinacija i interakcija ulaznih varijabli (npr. temperature i pH), unutar koje je dokazano da će proces zadržati traženu kvalitetu. Ti okviri omogućuju definiranje robusnih uvjeta rada unutar kojih sustav zadržava visoku učinkovitost unatoč manjim varijacijama parametara, što je presudan preduvjet za buduće industrijsko skaliranje. Tomu u prilog ide i dokazana stabilnost i mogućnost višekratne uporabe katalizatora kroz više radnih ciklusa, što potvrđuje ekonomsku održivost tih tehnologija kao realnih alata zaštite okoliša.

2.3 Arhitektura i algoritmi učenja umjetnih neuronskih mreža

Budući da na učinkovitost fotokatalizatora utječe velik broj međusobno povezanih čimbenika (Slika 3), precizno određivanje težinskih faktora pojedinih ulaznih parametara tijekom oblikovanja AI-modela predstavlja značajan izazov, zbog čega dizajn modela fotokatalizatora često nalikuje “crnoj kutiji” [26]. Ovaj se izraz u literaturi koristi kao metafora za sustave čiji su unutarnji mehanizmi toliko složeni ili netransparentni da ih je teško izravno razumjeti ili predvidjeti. Zato bi strategija visokoučinkovitog računalnog probira trebala biti što je moguće više usklađena s ek-

sperimentalnim podacima. Stalna prilagodba strategije računalnog probira, temeljena na eksperimentalnim rezultatima, omogućuje dublji uvid u složene fotokatalitičke procese, u kojima brojni parametri, poput intenziteta zračenja, pH-vrijednosti i koncentracije katalizatora, ostvaruju međudjelovanja koja je teško egzaktno modelirati. Primjena strojnog učenja i računalnog probira, koji se neprestano revidiraju na temelju laboratorijskih rezultata, stoga predstavlja učinkovitiji put prema razjašnjavanju tih složenih i nedovoljno istraženih mehanizama te prema pouzdanijem oblikovanju prediktivnih modela fotokatalizatora.

Usporedna analiza četiriju modela strojnog učenja za predviđanje, umjetnih neuronskih mreža (ANN), metode potpornih vektora (engl. *support vector machines*, SVM), slučajnih šuma (engl. *random forests*, RF) i k-najbližih susjeda (engl. *k-nearest-neighbours*, KNN), pokazala je da model ANN postiže najveću točnost predviđanja [22]. Model ANN, u usporedbi s modelima SVM, RF i KNN, ima značajnu prednost u predviđanju složenog nelinearnog ponašanja procesa zahvaljujući svojoj fleksibilnoj građi. Takvi rezultati dodatno potvrđuju da arhitektura neuronske mreže nije jedini čimbenik koji određuje učinkovitost modela, već je jednako važan i odabir optimizacijskog algoritma kojim se mreža uči. U tom smjeru razvijeni su hibridni pristupi koji nadograđuju klasičnu ANN arhitekturu suvremenim metaheurističkim algoritmima optimizacije. Jedan od njih je DBO-ANN, napredni hibridni model strojnog učenja koji kombinira umjetnu neuronsku mrežu (ANN) s algoritmom optimizacije balegara (engl. *dung beetle optimization*, DBO). Algoritam je razvijen po uzoru na ponašanje balegara, uključujući kotrljanje kuglice, orijentaciju u prostoru, potragu za hranom, krađu od drugih jedinki i reprodukciju. U tom hibridnom modelu, algoritam DBO optimizira težine i pragove (engl. *thresholds*) unutar neuronske mreže kako bi se poboljšala njezina struktura. U navedenom istraživanju uklanjanja norfloksacina, dobiveni model DBO-ANN pokazao je dodatno poboljšanje točnosti i učinkovitosti neuronske mreže, ponajprije kroz smanjenje pogrešaka u predviđanju.



Slika 3: Strategija računalnog pretraživanja visoke propusnosti temeljena na strojnom učenju [26]

Većina fotokatalitičkih studija o razgradnji organskih mikrozaagađivala temelji se na optimizaciji jednog parametra, što rezultira nelinearnim odnosom između ukupnih parametara i učinkovitosti fotokatalitičke razgradnje [27]. Optimalni rezultati za postizanje visoke učinkovitosti razgradnje potvrđeni su eksperimentalnim studijama i ocijenjeni kao vrlo prihvatljivi. Levenberg-Marquardtov algoritam korišten je za učenje umjetne neuronske mreže s povratnim rasprostiranjem pogreške, varirajući broj neurona u skrivenom sloju od 4 do 15, kako bi se dobila optimalna struktura neuronske mreže [28]. Ravnoteža između točnosti predviđanja i složenosti modela, izbjegavajući pritom problem preučenosti, utvrđena je za građu od 12 skrivenih neurona. Osim toga, utvrđeno je da koncentracija bojila, količina katalizatora i vrijeme razgradnje imaju najvišu razinu važnosti za fotokatalitičku razgradnju organskih onečišćivala.

Neuronskim mrežama i strojnim učenjem uspješno je ostvaren cilj predviđanja učinkovitosti uklanjanja bojila i Gibbsove slobodne energije u procesu adsorpcije. Model ANN u tom je kontekstu postigao iznimno visoku razinu točnosti s koeficijentom determinacije od 0,999455 [29]. Među različitim ispitivanim algoritmima, model *Histogram-based Gradient Boosting* (HGB), tj. model gradijentnog pojačavanja temeljenog na histogramima, pokazao je vrlo dobro uravnotežene rezultate predviđanja na skupu za testiranje [30]. HGB je napredni model strojnog učenja temeljen na stablima odlučivanja (engl. *tree-based model*), koji je dio biblioteke Scikit-learn u programskom jeziku Python. Taj model spada u skupinu ansambl metoda (engl. *ensemble methods*) i gradijentnih algoritama koji su razvijeni kako bi se ubrzalo učenje i poboljšala sposobnost predviđanja modela temeljenih na stablima. Izvrсни rezultati koje je model postigao na skupu za testiranje ukazuju na njegovu izvrsnu sposobnost generalizacije na nove, prethodno neviđene podatke. Modeliranje razgradnje bojila metilenskog modrila, koje je u svom izvornom obliku izrazito toksično i karcinogeno, sa specifičnom topologijom uspješno je potvrdilo podudaranje teorijskih i eksperimentalnih podataka [31]. Konačno, analiza toksičnosti potvrdila je da se obradom onečišćene vode naprednim oksidacijskim procesima stvaraju znatno manje toksični metaboliti kroz niz kemijskih reakcija: deaminaciju, aminaciju, metilaciju, oksidaciju/redukciju te, ključno, cijepanje aromatskih prstenova. Da bi se potvrdilo da su novi degradacijski produkti doista manje opasni za žive organizme, proveden je antibakterijski test na bakterijama *Escherichia coli* i *Bacillus subtilis*, koji je pokazao da je zona inhibicije (područja gdje bakterije nisu mogle rasti) znatno manja kod obrađene otpadne vode nego kod izvorne vodene otopine bojila.

3. Izazovi i perspektive primjene umjetne inteligencije u fotokatalizi

Unatoč izvrsnim postignućima u primjeni umjetne inteligencije i umjetnih neuronskih mreža u inženjerstvu materijala i okoliša, nekoliko ključnih izazova ostaje otvoreno. Razvoj većih i standardiziranih baza podataka s područja fotokatalitičke razgradnje, zajedno s primjenom metoda prijenosa znanja (engl. *transfer learning*), mogao bi

značajno poboljšati sposobnost modela za generalizaciju i omogućiti njihovu primjenu na sustave s ograničenim brojem eksperimentalnih podataka. U tom kontekstu, najnovija istraživanja pokazuju da pohrana kalibracijskog znanja unutar strukture ANN-a omogućuje rekalkulaciju modela nakon promjene uvjeta, uz smanjenje računalnog vremena od oko 60 % i broja potrebnih iteracija sa 160 na 40 generacija [32].

Osobito su obećavajući hibridni, fizikalno-informirani modeli umjetnih neuronskih mreža (engl. *physics-informed neural networks*, PINN). Za razliku od klasičnih neuronskih mreža koje uče isključivo iz podataka, PINN-ovi u matematički okvir učenja (funkciju gubitka) ugrađuju poznate zakone kemijske kinetike izražene diferencijalnim jednadžbama, čime modeli nužno poštuju temeljna načela očuvanja tvari i energije [33]. Novi znanstveni radovi pokazuju da PINN, temeljen na X-TFC metodi (engl. *extreme theory of functional connections*), uspješno modelira krutu kemijsku kinetiku i predviđa koncentracije vrsta koje nisu bile uključene u skup za učenje. To je posebno relevantno za fotokatalitičke sustave, u kojima analitičke metode ne omogućuju mjerenje svih prisutnih intermedijera. Autori navode trajanje učenja od svega nekoliko sekundi do nekoliko minuta, što takve modele čini potencijalno primjenjivima u sustavima za praćenje kvalitete vode u stvarnom vremenu.

Napredak u ovom području ostvaren je uvođenjem hijerarhijske fizikalno-informirane neuronske mreže (engl. *hierarchical physics-informed neural network*, HPINN). U ovom pristupu globalni model uči na prosječnim parametrima sustava, a stečeno znanje potom prenosi na modele specifične za pojedinačne cjevovode. Učinkovitost takve arhitekture potvrđena je na primjeru predviđanja rezidualnog klora pri dezinfekciji vode, gdje je postignuta pogreška predviđanja (MAPE) ispod 0,31 %, uz visoku točnost čak i u uvjetima gubitka 90 % podataka na pojedinim senzorima [34]. Za usporedbu, standardni ANN model s povratnim rasprostranjem pogreške imao je znatno veći MAPE od 1,27 %. Robusnost modela koji koristi prethodno stečeno znanje o sustavu posebno je relevantna za fotokatalizu, gdje se jednom naučene zakonitosti kinetike razgradnje mogu primijeniti na nova organska mikrozaagađivala ili izmijenjene reakcijske uvjete bez potrebe za ponovnim učenjem procesa iz početka.

Proširenje navedenog koncepta uvedeno je razvojem nove prostorno-vremenske grafovske fizikalno-informirane neuronske mreže (engl. *spatio-temporal graph physics-informed neural network*, ST-GPINN), koja integrira fizikalna ograničenja s grafovskim neuronskim mrežama, čime se istovremeno modeliraju prostorne zavisnosti između čvorova mreže i vremenski razvoj, npr. kvalitete vode [35]. U objavljenom istraživanju, primjerice, postignut je koeficijent determinacije od 98,91 % na stvarnoj vodoopskrbnoj mreži s više od 900 čvorova i 1000 cijevi. Analogna primjena u fotokatalizi podrazumijevala bi ugradnju kinetičkih jednadžbi razgradnje organskog mikrozaagađivala, primjerice Langmuir-Hinshelwoodovog modela, kao fizikalnog ograničenja u PINN strukturu, čime bi se smanjila ovisnost o opsežnim eksperimentalnim skupovima podataka. Hibridizacija kinetičkih modela s pristupima umjetne inteligencije već je pokazala potencijal za preciznije predviđanje u složenim realnim uvjetima fotokatalize [36].

Komplementaran pristup u modelima umjetne inteligencije (između ostalih, npr. u umjetne neuronske mreže, metodu k-najbližih susjeda, regresijska stabla i druge) uvodi bezdimenzijske fizikalne veličine, poput Péceletovog i Damköhlerovog broja, kao informirane ulazne varijable, čime se poboljšava sposobnost generalizacije modela na sustave izvan domene učenja [37]. To istraživanje naglašava da čak i bez potpunog ugrađivanja diferencijalnih jednadžbi, selektivno korištenje fizikalnih spoznaja može značajno povećati primjenjivost modela u različitim eksperimentalnim konfiguracijama.

Integracija poznatih metoda umjetne inteligencije s platformama za optimizaciju procesa u stvarnom vremenu otvara put prema adaptivnim fotokatalitičkim sustavima sposobnima autonomno prilagođavati uvjete rada ovisno o trenutnom sastavu otpadnih voda, što predstavlja ključni korak prema industrijskoj primjeni tih tehnologija.

4. Zaključak

Pregled dosadašnjih istraživanja jasno potvrđuje da je primjena metoda umjetne inteligencije u fotokatalitičkoj razgradnji organskih mikrozagađivala prešla razinu puke metodološke inovacije i postala nezaobilazan alat suvremenog inženjerstva okoliša. Integracijom algoritama strojnog učenja, ponajprije umjetnih neuronskih mreža, s klasičnim eksperimentalnim pristupima postiže se značajno poboljšanje u predviđanju i optimizaciji procesa razgradnje složenih organskih mikrozagađivala poput antibiotika, industrijskih bojila i farmaceutika, uz znatno manji broj potrebnih laboratorijskih pokusa.

Usporedna analiza primijenjenih modela pokazuje da pojedine arhitekture neuronskih mreža, osobito hibridni modeli, dosljedno nadmašuju klasičnije pristupe poput metode odzivne površine, metode potpornih vektora i k-najbližih susjeda, osobito u uvjetima izražene nelinearnosti i višestruke međuzavisnosti procesnih parametara. Pri tome su pH-vrijednost medija, količina katalizatora, početna koncentracija organskog mikrozagađivala, vrijeme razgradnje i intenzitet zračenja prepoznati kao ključni ulazni parametri koji najviše određuju učinkovitost procesa. Koeficijenti determinacije, koji redovito premašuju 0,95, a u pojedinim slučajevima dosežu i 0,999, potvrđuju pouzdanost tih modela kao praktičnih inženjerskih alata.

Budući razvoj upućuje na sve veću ulogu fizikalno-informiranih neuronskih mreža, koje zakone kemijske kinetike integriraju izravno u strukturu modela, čime se smanjuje ovisnost o opsežnim eksperimentalnim skupovima podataka i povećava sposobnost generalizacije na nove sustave. Razvoj prostorno-vremenskih i hijerarhijskih fizikalno-informiranih neuronskih mreža, uz primjenu metoda prijenosa znanja i bezdimenzijskih fizikalnih veličina kao ulaznih parametara, otvara put prema adaptivnim fotokatalitičkim sustavima sposobnima za autonomnu prilagodbu uvjetima rada u stvarnom vremenu.

Ipak, nekoliko važnih izazova i dalje ostaje otvoreno: standardizacija eksperimentalnih baza podataka, razumijevanje unutarnje logike algoritamskih modela te industrijsko skaliranje razvijenih rješenja. Budući napredak u ovom području zahtijevat će blisku suradnju između kemijskih inženjera, stručnjaka za materijale i znanstvenika u području računalne inteligencije, uz naglasak na razvoj robusnih, fizikalno utemeljenih i interpretabilnih modela koji će fotokatalizu pozicionirati kao pouzdanu tehnologiju zaštite okoliša.

Zahvala

Ovaj rad izrađen je uz financijsku potporu Hrvatske zaklade za znanost projektom HRZZ-IP-2022-10-4400 pod nazivom *Razvoj polimera s otiskom molekula za primjenu u analizi farmaceutika i tijekom naprednih postupaka obrade voda (MIPdePharma)*.

5. Literatura

- [1] Sumpter, B.G.; Noid, D.W.: On the Design, Analysis, and Characterization of Materials Using Computational Neural Networks, *Annual Review of Materials Science*, **26** (1996) 223-277
- [2] Tarng, Y.S.; Wang, T.C., Chen, W.N., Lee, B.Y.: The Use of Neural Networks in Predicting Turning Forces, *Journal of Materials Processing Technology*, **47** (1995) 3-4, 273-289, [https://doi.org/10.1016/0924-0136\(95\)85004-X](https://doi.org/10.1016/0924-0136(95)85004-X)
- [3] El-Din, A.G.; Smith, D.W., El-Din, M.G.: Application of Artificial Neural Networks in Wastewater Treatment, *Journal of Environmental Engineering and Science*, **3** (2004) Supplement 1, S81-S95, <https://doi.org/10.1139/s03-067>
- [4] Çinar, Ö.: New Tool for Evaluation of Performance of Wastewater Treatment Plant: Artificial Neural Network, *Process Biochemistry*, **40** (2005) 9, 2980-2984, <https://doi.org/10.1016/j.procbio.2005.01.012>
- [5] Yetilmezsoy, K.; Demirel, S.: Artificial Neural Network (ANN) Approach for Modeling of Pb(II) Adsorption from Aqueous Solution by Antep pistachio (*Pistacia vera* L.) Shells, *Journal of Hazardous Materials*, **153** (2008) 3, 1288-1300, <https://doi.org/10.1016/j.jhazmat.2007.09.092>
- [6] Sadrzadeh, M.; Mohammadi, T., Ivakpour, J., Kasiri, N.: Neural Network Modeling of Pb²⁺ Removal from Wastewater Using Electrodialysis, *Chemical Engineering and Processing: Process Intensification*, **48** (2009) 8, 1371-1381, <https://doi.org/10.1016/j.cep.2009.07.001>
- [7] Elmolla, E.S.; Chaudhuri, M., Eltoukhy, M.M.: The Use of Artificial Neural Network (ANN) for Modeling of COD Removal from Antibiotic Aqueous Solution by the Fenton Process, *Journal of Hazardous Materials*, **179** (2010) 1-3, 127-134, <https://doi.org/10.1016/j.jhazmat.2010.02.068>
- [8] Juretić, D.; Lučić, B., Trinajstić, N.: Predicting Membrane-Protein Secondary Structure - Preference Functions Method for Finding Optimal Conformational Parameters, *Croatica Chemica Acta*, **66** (1993) 1, 201-208

- [9] Juretić, D.; Lee, B., Trinajstić, N., Williams, R.W.: Conformational Preference Functions for Predicting Helices in Membrane Proteins, *Biopolymers*, **33** (1993) 2, 255-273, <https://doi.org/10.1002/bip.360330208>
- [10] Ilakovac, T.: Adaptation of Neural Networks Using Genetic Algorithms, *Croatica Chemica Acta*, **68** (1995) 1, 29-38
- [11] Kurtanjek, Ž.: Principal Component ANN for Modelling and Control of Baker's Yeast Production, *Journal of Biotechnology*, **65** (1998) 1, 23-35, [https://doi.org/10.1016/S0168-1656\(98\)00119-9](https://doi.org/10.1016/S0168-1656(98)00119-9)
- [12] Žmak, I.: *Modeliranje strukture i svojstava nodularnog lijeva neuronskim mrežama*, disertacija, Fakultet strojarstva i brodogradnje, Zagreb, (2009).
- [13] Živko-Babić, J.; Lisjak, D., Ćurković, L., Jakovac, M.: Estimation of Chemical Resistance of Dental Ceramics by Neural Network, *Dental Materials*, **24** (2008) 1, 18-27, <https://doi.org/10.1016/j.dental.2007.01.008>
- [14] Novak, D.: *Definiranje parametara toplinske obrade metala genetičkim algoritmima*, magistrski rad, Fakultet strojarstva i brodogradnje, Zagreb, (2003).
- [15] Žmak, I.: *Predviđanje svojstava materijala neuronskim mrežama*, magistrski rad, Fakultet strojarstva i brodogradnje, Zagreb, (2003).
- [16] Filetin, T.; Žmak, I., Novak, D.: Nitriding Parameters Analyzed by Neural Network and Genetic Algorithm, *Journal de Physique IV*, **120** (2004) 355-362, <https://doi.org/10.1051/jp4:2004120040>
- [17] Lisjak, D.: *Primjena metoda umjetne inteligencije pri izboru materijala*, disertacija, Fakultet strojarstva i brodogradnje, Zagreb, (2004).
- [18] Švagelj, Z.; Mandić, V., Ćurković, L., Biošić, M., Žmak, I., Gaborardi, M.: Titania-Coated Alumina Foam Photocatalyst for Memantine Degradation Derived by Replica Method and Sol-Gel Reaction, *Materials*, **13** (2020) 1, 227, <https://doi.org/10.3390/ma13010227>
- [19] Rehman, A.; Iqbal, M.A., Haider, M.T., Majeed, A.: Artificial Intelligence-Guided Supervised Learning Models for Photocatalysis in Wastewater Treatment, *AI*, **6** (2025) 10, 258, <https://doi.org/10.3390/ai6100258>
- [20] Das, S.; Moon, S., Kaur, R., Sharma, G., Kumar, P., Lavrenčić Štangar, U.: Artificial Neural Network Modeling of Photocatalytic Degradation of Pollutants: A Review of Photocatalyst, Optimum Parameters and Model Topology, *Catalysis Reviews*, **67** (2025) 3, 544-578, <https://doi.org/10.1080/01614940.2024.2338131>
- [21] Mohammed, N.; Palaniandy, P., Shaik, F., Mewada, H., Balakrishnan, D.: Comparative Studies of RSM Box-Behnken and ANN-Anfis Fuzzy Statistical Analysis for Seawater Biodegradability Using TiO₂ Photocatalyst, *Chemosphere*, **314** (2023) 1-11, <https://doi.org/10.1016/j.chemosphere.2022.137665>
- [22] Shen, Q.-X.; Bao, J., Liu, Y., Wang, X., Cui, L.: Machine Learning-Driven Prediction and Optimization of Norfloxacin Removal Efficiency and Energy Consumption in Plasma Process System, *Chemical Engineering Research and Design*, **224** (2025) 91-101, <https://doi.org/10.1016/j.cherd.2025.11.001>

- [23] Rajesh, C.; Rajashekara, R., Nagaraju, P.: Response Surface Methodology (RSM) Modelling for the Photocatalytic Optimization Study of Benzophenone Removal Using CuWO_4/NiO Nanocomposite, *Journal of Environmental Health Science and Engineering*, **21** (2023) 1, 187-199, <https://doi.org/10.1007/s40201-023-00852-3>
- [24] Rezvannasab, S.G.; Safari, N., Ghaedi, A.M.: Optimizing Amoxicillin Photodegradation with GO/TiO_2 Nanocomposites Via RSM, ANN, and ANFIS, *Carbon Trends*, **21** (2025) 100571, <https://doi.org/10.1016/j.cartre.2025.100571>
- [25] El Mouchtari, E.M.; Claeys-Bruno, M., Rafqah, S., Manzon, D., Anane, H., Lebarillier, S., Piram, A., Briche, S., Wong-Wah-Chung, P.: Optimisation of a Photocatalytic Water Treatment Using Response Surface Methodology and Quality by Design Approach, *International Journal of Environmental Analytical Chemistry*, **103** (2023) 20, 9466-9482, <https://doi.org/10.1080/03067319.2021.2012171>
- [26] Zhao, Y.; Gao, J., Bian, X., Tang, H., Zhang, T.: From the Perspective of Experimental Practice: High-Throughput Computational Screening in Photocatalysis, *Green Energy & Environment*, **9** (2024) 1, 1-6, <https://doi.org/10.1016/j.gee.2023.05.008>
- [27] Chandrika, K.C.; Prabhu, T.N., Kiran, R.R.S., Krishna, R.H.: Applications of Artificial Neural Network and Box-Behnken Design for Modelling Malachite Green Dye Degradation from Textile Effluents Using TiO_2 Photocatalyst, *Environmental Engineering Research*, **27** (2021) 1, 1-9, <https://doi.org/10.4491/eer.2020.553>
- [28] Ayodele, B.V.; Alsaffar, M.A., Mustapa, S.I., Vo, D.N.: Backpropagation Neural Networks Modelling of Photocatalytic Degradation of Organic Pollutants Using TiO_2 -Based Photocatalysts, *Journal of Chemical Technology & Biotechnology*, **95** (2020) 10, 2739-2749, <https://doi.org/10.1002/jctb.6407>
- [29] Zaferani, S.P.G.; Amiri, M.K., Amooey, A.A.: Computational AI to Predict and Optimize the Relationship Between Dye Removal Efficiency and Gibbs Free Energy in the Adsorption Process Utilizing $\text{TiO}_2/\text{Chitosan-Polyacrylamide}$ Composite, *International Journal of Biological Macromolecules*, **264** (2024) 1-15, <https://doi.org/10.1016/j.ijbiomac.2024.130738>
- [30] Ahmed, Y.; Dutta, K.R., Nepu, S.N.C., Prima, M., AlMohamadi, H., Akhtar, P.: Optimizing Photocatalytic Dye Degradation: A Machine Learning and Metaheuristic Approach for Predicting Methylene Blue in Contaminated Water, *Results in Engineering*, **25** (2025) 1-14, <https://doi.org/10.1016/j.rineng.2024.103538>
- [31] Rashtbari, S.; Dehghan, G., Marefat, A., Khataee, S., Khataee, A.: Proficient Sonophotocatalytic Degradation of Organic Pollutants Using $\text{Co}_3\text{O}_4/\text{TiO}_2$ Nanocomposite Immobilized on Zeolite: Optimization, and Artificial Neural Network Modeling, *Ultrasonics Sonochemistry*, **102** (2024) 1-13, <https://doi.org/10.1016/j.ultsonch.2023.106740>
- [32] Gomez, C.; Solon, K., Haest, P.J., Morley, M., Nopens, I., Torfs, E.: Enhancing Accuracy and Efficiency in Calibration of Drinking Water Distribution Networks Through Evolutionary Artificial Neural Networks and Expert Systems, *Journal of Hydroinformatics*, **27** (2025) 10, 1554-1578, <https://doi.org/10.2166/hydro.2025.061>
- [33] Frankel, M.; De Florio, M., Schiassi, E., Katz, L.E., Kinney, K., Werth, C.J., Zigler, C., Sela, L.: Enhancing Drinking Water Quality Modeling: Leveraging Physics Informed Neural Networks for Learning with Imperfect Reaction Models and Partial Data, *Environmental Science: Water Research & Technology*, **11** (2025) 11, 2684-2697, <https://doi.org/10.1039/D5EW00682A>

- [34] Duan, F.; Mu, T., Zhou, B., Ning, B., Tan, H.: Hierarchical Physics-Informed Neural Networks for Water Contamination Prediction in Water Distribution Systems: Integrating Physics-Based Modeling and AI Transfer Learning, *Urban Water Journal*, (2026) 1-14, <https://doi.org/10.1080/1573062X.2026.2613113>
- [35] Mu, T.; Duan, F., Ning, B., Zhou, B., Liu, J., Huang, M.: ST-GPINN: A Spatio-Temporal Graph Physics-Informed Neural Network for Enhanced Water Quality Prediction in Water Distribution Systems, *npj Clean Water*, **8** (2025) 1, 74, <https://doi.org/10.1038/s41545-025-00499-7>
- [36] El Messaoudi, N.; Miyah, Y., Benjelloun, M., Georjin, J., Franco, D.S.P., Kaur, P., Lim, V., Knani, S.: The Role of Artificial Intelligence in Optimizing Photocatalytic Degradation Technologies of Dyes in Textile Wastewater: Recent Advances, Challenges, and Prospects, *Journal of Water Process Engineering*, **77** (2025) 108457, <https://doi.org/10.1016/j.jwpe.2025.108457>
- [37] Moeini, M.; Abokifa, A.A.: Physics-Informed Ensemble Machine Learning for Dynamic Water Quality Prediction in Water Distribution Systems, *Journal of Water Process Engineering*, **79** (2025) 108841, <https://doi.org/10.1016/j.jwpe.2025.108841>

Usporedba postupka klasifikacije tekstilija primjenom *Weka* i *Orange Data Mining* programskih paketa

Selma Imamagić¹, Tomislav Rolich¹, Željko Penava¹

¹Sveučilište u Zagrebu Tekstilno-tehnološki fakultet, Prilaz baruna Filipovića 28a, 10000 Zagreb

Sažetak: Rad se temelji na usporedbi postupka klasifikacije digitalnih slika tekstilnih plošnih proizvoda u programskim paketima *Weka* i *Orange Data Mining*. Za navedenu svrhu su provedena dva pokusa. U prvom pokusu su relevantne značajke izdvojene metodom filtracije (CLF, EHF, FCTHF, GF i SCHF filteri) dok su u drugom pokusu za te svrhe korištene konvolucijske neuronske mreže (Google Inception v3, SqueezeNet). U oba pokusa su primijenjeni isti klasifikatori (Tree, SVM, Random Forest, Naive Bayes, Logistic Regression i Neural Network). Rezultati provedenih pokusa praćeni su kroz postotak ispravno klasificiranih digitalnih slika. Veći postotak ispravno klasificiranih digitalnih prikaza postignut je u drugom pokusu za sve klasifikacijske modele što ukazuje na superiornost metode dubokog učenja prilikom izdvajanja relevantnih značajki. Najbolji rezultat klasifikacije (95,52 %) postignut je kombinacijom Inception v3 mreže i Neural Network klasifikatora.

Ključne riječi: klasifikacija, *Weka*, *Orange Data Mining*, filtracija, konvolucijske neuronske mreže

1. Uvod

Strojno učenje je grana umjetne inteligencije usmjerena na razvoj algoritama sposobnih za “učenje” obrazaca ponašanja određene skupine podataka. Cilj spomenutog “učenja” jest izgradnja modela kojim će se na temelju naučenih obrazaca ponašanja moći donositi predviđanja i zaključci o novom, algoritmu nepoznatom skupu podataka.

Jedno od područja primjene strojnog učenja jest klasifikacija podataka. Cilj je izgraditi prediktivni model, tzv. klasifikator kojim se predviđaju diskretne vrijednosti, tj. pripadnost podatka određenoj klasi [1, 2]. Budući da svaki podatak ima unaprijed poznatu klasu kojoj pripada, problem klasifikacije spada u nadzirano učenje (engl. *Supervised Learning*). S tim u vezi, ulazni podaci prilikom izgradnje klasifikatora


podijeljeni su u dva skupa podataka. Prvi skup namijenjen je “učenju algoritma” (engl. *learning step*) na skupu podataka za učenje (engl. *training set*) gdje se algoritam “uči” pridruživanju primjera podataka pripadajućim klasama [3-5]. Pritom se gradi predikcijski model – klasifikator [3, 5]. Drugi skup naziva se ispitnim skupom (engl. *test set*) i koristi se isključivo za provjeru točnosti izgrađenog klasifikatora, ne i za njegovo učenje [3-5]. Na temelju rezultata ispitnog skupa vrednuje se generalizacijska sposobnost modela, primarno kroz parametar točnosti klasifikacije (engl. *accuracy*), ali i kroz preciznost (engl. *precision*), odaziv (engl. *recall*) i F1-vrijednost. Cilj ovog rada je usporediti učinkovitost dviju metoda izdvajanja značajki – filtracije i konvolucijskih neuronskih mreža – u postupku klasifikacije digitalnih slika tekstilnih plošnih proizvoda primjenom programskih paketa Weka i Orange Data Mining.

2. Odabir relevantnih značajki primjera podataka

U prostoru primjera podataka svaki podatak predstavljen je ugradbenim vektorom (engl. *embedding*) u latentnom prostoru, Slika 1 [1]. Broj dimenzija latentnog prostora odgovara broju značajki primjera podatka (engl. *features*) koje ga karakteriziraju. Pritom svaka točka ugradbenog vektora odgovara numeričkoj vrijednosti određene značajke [1]. Cilj je prije postupka klasifikacije odrediti i izdvojiti one značajke primjera kojima će se postići što veća generalizacijska sposobnost klasifikatora. Dodatno, postupkom selekcije značajki smanjuje se: prenaučenosť klasifikatora na podacima za učenje (engl. *overfitting*), vrijeme učenja algoritma, potrebna memorija za pohranu podataka te pojednostavljuje način rada klasifikatora [6].

Slika 1 prikazuje primjer vizualizacije latentnog prostora. Iako se prikazani primjer temelji na zvučnim podacima, on jasno ilustrira princip rada strojnog učenja prema kojem se podaci sličnih značajki u latentnom prostoru nalaze u međusobnoj blizini, što je temelj za klasifikaciju digitalnih slika tekstilnih plošnih proizvoda analiziranih u ovom radu.


POBOLJŠANJE GENERALIZACIJE KLASIFIKATORA ODJEĆE SELEKCIJOM ZNAČAJKI IZ 3D LATENTNOG PROSTORA



Slika 1: Vizualizacija latentnog prostora podataka [7]

2.1. Filtri

Selektiranje značajki primjera uporabom filtera temelji se na rangiranju značajki s obzirom na njihov utjecaj na uspješnost klasifikacije. Rangiranje se odvija primjenom različitih statističkih metoda, primjerice mjera raspršenosti (varijanca, standardna devijacija, raspon), Hi-kvadrat testa, korelacijske analize ili ANOVA metode [8]. Značajke koje se procjene da sadrže važnije informacije prema statističkoj metodi za dani klasifikacijski problem bit će izdvojene kao korisne, dok će one s najmanjom biti eliminirane i neće se koristiti kod izgradnje latentnog prostora. Postupak odabira značajki filtriranjem primjenjuje se u fazi predobrade podataka, prije izgradnje klasifikatora [9]. Neovisnost o postupku izgradnje klasifikatora i oslanjanje isključivo na svojstva značajki smanjuje vjerojatnost prenaučivosti klasifikatora na podacima za učenje te čini ovu metodu brzim i efikasnim načinom uklanjanja nepotrebnih značajki primjera, posebice pogodnu za velike skupine primjera podataka.



GF

[10.420364,0.039542,10.423867,0.039555,10.423867,0.039555,10.420364,0.039542,10.423867,0.039555,10.423867,0.039555,10.768928,0.040865,10.772548,0.040878,10.772548,0.040878,10.768928,0.040865,10.772548,0.040878,10.772548,0.040878,10.758971,0.040827,10.762587,0.04084,10.762587,0.04084,10.758971,0.040827,10.762587,0.04084,10.762587,0.04084,10.730758,0.04072,10.734365,0.040733,10.734365,0.040733,10.730758,0.04072,10.734365,0.040733,10.734365,0.040733,10.650555,0.040415,10.654135,0.040429,10.654135,0.040429,10.650555,0.040415,10.654135,0.040429,10.654135,0.040429,knitwear]

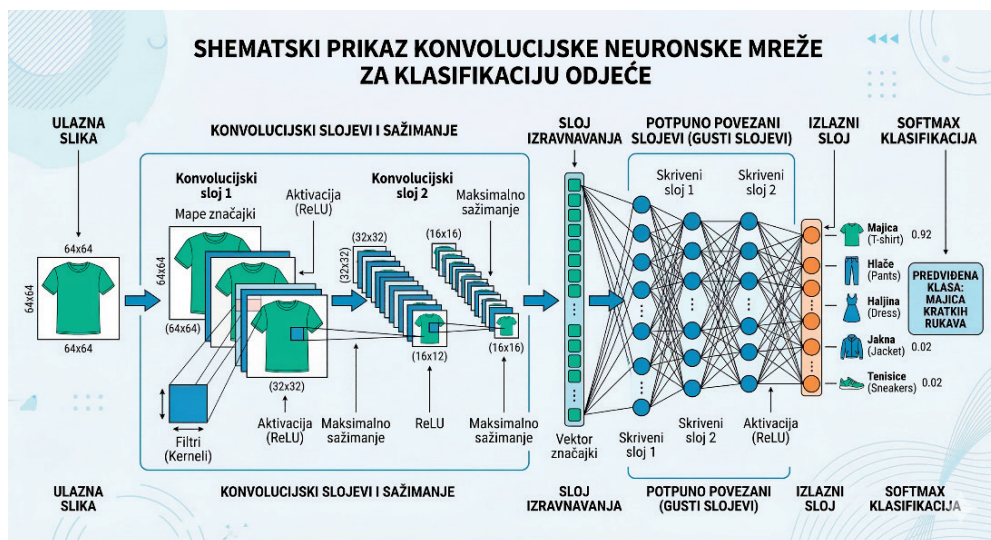
Slika 2: Prikaz pletiva nakon selektiranja značajki *GaborFilter*-om [4]

Ograničenje ove metode jest zanemarivanje međusobne ovisnosti i interakcije značajki, što može rezultirati zadržavanjem redundantnih informacija koje ne doprinose diskriminativnoj moći modela.

2.2. Konvolucijske neuronske mreže

Neuronske mreže pripadaju algoritmima strojnog učenja inspiriranim kompleksnom strukturom ljudskog mozga [10, 11]. Sastoje se od više uzastopnih slojeva međusobno povezanih čvorova ili neurona koji provode nelinearne transformacije podataka velikih dimenzionalnosti. Svaki sloj izvodi jednostavnu matematičku operaciju na svom ulazu i proslijeđuje rezultat sljedećem sloju [10]. Jedan od modela neuronskih mreža su konvolucijske neuronske mreže (engl. *Convolutional Neural Network*, CNN) namijenjene klasifikaciji podataka i računalnom vidu [12].

Konvolucijske neuronske mreže sastoje se od konvolucijskog sloja, sloja sažimanja i izlaznog sloja, Slika 3.



Slika 3: Način rada konvolucijske neuronske mreže na primjeru klasifikacije odjeće [7]

Konvolucijski sloj (engl. *convolutional layer*) obrađuje ulazne podatke i izdvaja značajke istih. Sastoji se od niza filtera (nazvanih jezgrom) kojima se postupkom konvolucije, tj. unakrsnom korelacijom djeluje na ulazne podatke te stvaraju mape značajki ključne za danju obradu. Konvolucijom ostaju sačuvani prostorni odnosi između piksela slike, a veličina mapa značajki odgovara veličini korištenih jezgri [10].

Sloj sažimanja (engl. *pooling layer*) smanjuje prostornu veličinu mapa značajki na ulazu u jednu značajku na izlazu iz sloja [13]. Sažimanje se odvija primjenom statističkih pokazatelja, primjerice odabirom maksimalne ili prosječne vrijednosti značajke. Navedenim se smanjuje potrebna memorija za pohranu te sprječava prenaučenosť modela na podatke za učenje [13].


Izlazni sloj (engl. *fully connected layer*) služi kao posljednji sloj sažimanja u neuronskoj mreži. On preuzima izdvojene značajke primjera i prosljeđuje ih klasifikatoru [11].

3. Materijali i metodologija

3.1. Materijali

Istraživanje je provedeno na skupu digitalnih slika tekstilnih plošnih proizvoda dobivenih skeniranjem stvarnih uzoraka iz tekstilne industrije. Skeniranje tekstilnih uzoraka provedeno je pomoću plošnog skenera Canon CanoScan LiDE 400 pri razlučivosti od 300 dpi. Svi tekstilni uzorci skenirani su u kontroliranim uvjetima, čime je osigurana standardizacija ulaznih podataka.

Skup podataka obuhvatio je ukupno 5173 skenirana uzoraka, koji su podijeljeni u pet osnovnih klasa prema vrsti tekstilne strukture: čipke, netkani tekstil, pletivo, tepisi i tkanine, Slika 4.



Slika 4: Primjeri skeniranih pet klasa tekstilnih plošnih proizvoda: a. čipka, b. netkani tekstil, c. pletivo, d. tepih, e. tkanina

U skupu podataka korištenom u istraživanju analizirano je 421 uzorak čipki, 2207 uzoraka netkanog tekstila, 524 uzorka pletiva, 644 uzorka tepiha te 1377 uzoraka tkanina, Tablica 1.

S obzirom da je uzet neravnomjeran broj slika tekstilnih plošnih proizvoda po klasama, u analizu rezultata bit će uvedene metričke vrijednosti preciznosti, odaziva i F1-vrijednosti. Time će se spriječiti moguća pojava pristranosti klasifikatora.

Tablica 1: Tekstilni plošni proizvodi korišteni u istraživanju, njihov opis i broj slika primjera [14]

Tekstilni plošni proizvod	Opis	Broj slika
čipka	Čipke predstavljaju rupičaste tekstilne plošne proizvode namijenjene ukrašavanju odjeće, posteljnog i stolnog rublja te za unutrašnje uređenje prostora stanovanja.	421
netkani tekstil	Netkani tekstil predstavlja posebnu skupinu tekstilnih plošnih proizvoda koji se mogu izrađivati različitim proizvodnim tehnikama, najčešće sjedinjavanjem tekstilnih vlakana u funkcionalnu plošnu tvorevinu. Karakterizira ih relativno velika nejednolikost strukture iz koje proizlazi nejednolikost raznih svojstava, naročito debljine, površinske mase i čvrstoće.	2207
pletivo	Pletiva su tekstilni plošni proizvodi načinjeni od očica nastalih od jedne ili više niti, odnosno više sustava niti, prema pravilima određene vrste prepleta. Strukturu pletiva čine uzdužni nizovi i poprečni redovi očica, čime se formira karakteristična elastična plošna tvorevina.	524
tepih	Tepisi, odnosno podni prostirači, predstavljaju tekstilne plošne proizvode namijenjene oblaganju podova. Pojavljuju se kao metražna roba ili komadni proizvodi. Njihova se struktura u pravilu sastoji od vlasaste površine (flora) po kojem se hoda tijekom upotrebe te podloge koja osigurava mehaničku stabilnost, dimenzijsku postojanost i potrebnu čvrstoću proizvoda.	644
tkanina	Tkanine su tekstilni plošni proizvodi dobiveni postupkom tkanja, pri čemu se odlikuju plošnim oblikom s izraženim dimenzijama duljine i širine, dok je debljina u odnosu na njih znatno manja. Struktura tkanina sastoji se od dvaju sustava niti – osnove i potke – koje se međusobno isprepliću pod pravim kutom prema unaprijed definiranim pravilima tkanja. Ovakav način povezivanja niti ostvaruje se procesom tkanja na tkalačkom stanu te rezultira pravilnom i ponavljajućom strukturom površine.	1377
Σ:		5173

3.2. Metodologija

Rad se temelji na usporedbi uspješnosti klasifikacije slika tekstilnih plošnih proizvoda nakon izdvajanja relevantnih značajki metodom filtracije i primjenom konvolucijskih neuronskih mreža. Provedena su dva različita pokusa u dva koraka: izdvajanje relevantnih značajki te klasifikacija digitalnih slika, Tablica 2.

Tablica 2: Provedba pokusa

	Prvi pokus	Drugi pokus
programski paket	Weka	Orange Data Mining
broj ulaznih podataka (slika)	5173	5173
broj klasa	5	5
postupak izdvajanja značajki	filtracija (CLF, EHF, FCTHF, GF, SCHF)	konvolucijske neuronske mreže (Google Inception v3, SqueezeNet)
prediktivni model	klasifikator (Tree, SVM, Random Forest, Naive Bayes, Logistic Regression, Neural Network)	klasifikator (Tree, SVM, Random Forest, Naive Bayes, Logistic Regression, Neural Network)

3.2.1. Izdvajanje značajki

Izdvajanje značajki metodom filtracije

U programskom paketu *Weka* odabrano je 5 različitih filtara za izdvajanje relevantnih značajki slika kojima se želi postići čim uspješnija klasifikacija. Pritom se broj izdvojenih značajki skeniranih prikaza razlikuje s obzirom na korišteni filtar. Odabrani su sljedeći filtri:

1. ***ColorLayoutFilter (CLF)***: izdvaja značajke prostorne raspodjele boja na slici
2. ***EdgeHistogramFilter (EHF)***: izdvaja značajke položaja rubova, linija i diskontinuiteta slike
3. ***FuzzyColorAndTextureHistogramFilter (FCTHF)***: izdvaja značajke boje i teksture slike
4. ***GaborFilter (GF)***: specijaliziran za analizu i izdvajanje teksturnih značajki slike
5. ***SimpleColorHistogramFilter (SCHF)***: izdvaja značajke učestalosti pojavljivanja određene boje na slici [4, 15-17].
6. ***Izdvajanje značajki primjenom konvolucijskih neuronskih mreža***

U programskom paketu *Orange Data Mining* odabrane su 2 konvolucijske neuronske mreže za odabir relevantnih značajki ulaznog skupa digitalnih slika. Radi se o *Google Inception v3* i *SqueezeNet* konvolucijskim neuronskim mrežama.

Google Inception v3 evaluira slike na lokalnom ili udaljenom serveru [18]. Treniran je na skupu podataka *ImageNet* te generira vektor od 2048 značajki. Struktura konvolucijske mreže ima četiri komponente: tri konvolucijska sloja (1x1, 3x3, 5x5) i sloj

sažimanja (3x3) [19]. Izdvajanjem značajki preko više konvolucijskih slojeva različitih veličina te njihovim spajanjem u mapu značajki u sloju sažimanja teži se postizanju boljeg prikaza slike [19]. Također, razdvajanjem višestrukog konvolucijskog sloja u više manjih slojeva različitih veličina smanjuje se potreban broj parametara te se omogućuje istovremeno izdvajanje više relevantnih prostornih značajki [19].

SqueezeNet je jednostavna neuronska mreža također trenirana na skupu podataka ImageNet, ali za razliku od neuronske mreže *GoogleInception v3*, generira vektor od 1000 značajki. Temelj ove mreže čini tzv. "Fire modul", odnosno jedan konvolucijski sloj filtara dimenzija 1x1 te drugi konvolucijski sloj koji kombinira filtre dimenzija 1x1 i 3x3 [20]. *SqueezeNet* nastaje slaganjem opisanih osnovnih "Fire-modula" [20]. Sama neuronska mreža je pogodna za primjenu u ograničenim računalnim resursima ili pak u slučajevima gdje je naglasak na brzini obrade velikih skupova podataka.

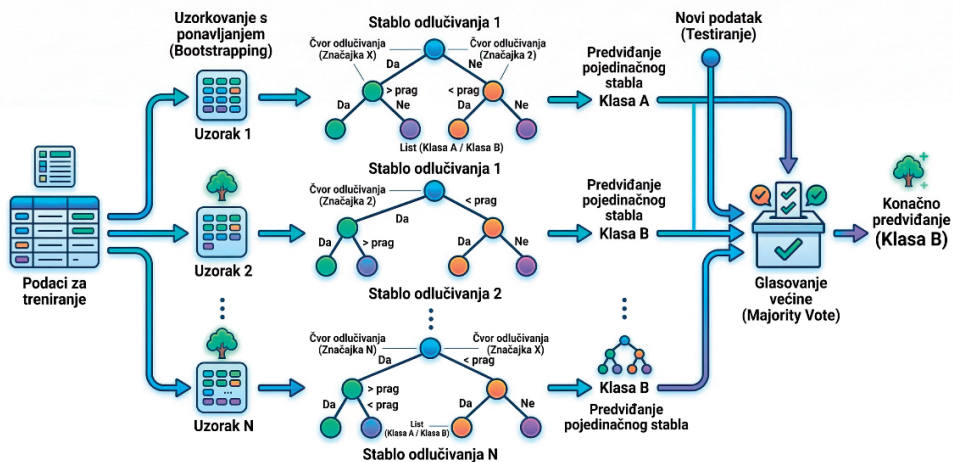
3.2.2. Postupak klasifikacije

Za potrebe klasifikacije digitalnih slika odabrano je 6 klasifikatora dostupnih u oba korištena programska paketa.

Klasifikator *Tree* koristi metodu stabla odlučivanja prilikom klasifikacije podataka. Klasifikator na svakom čvoru odluke stabla dijeli skup primjera sukladno informacijskoj dobiti (engl. *information gain*). Prvo se odabire značajka s najvećom informacijskom dobiti na temelju koje će se izvesti podjela primjera u određenom čvoru odluke [4]. Informacijska dobit značajke ukazuje na "dobit" ukoliko se izvede podjela primjera po toj značajki u određenom čvoru stabla odlučivanja [4, 18]. Glavne prednosti ovog klasifikatora su njegova jednostavnost i lakoća razumijevanja. Ipak, ovaj klasifikator uzima u obzir sve značajke primjera što dovodi do nestabilnosti stabla odlučivanja, ali i prenaučivosti modela na podatke za treniranje.


Klasifikator *Random Forest* (Slika 5) temelji se na predviđanjima više stabala odlučivanja kako bi se spriječila korelacija između značajki ulaznih podataka [21]. Na početku slučajnim odabirom uzimaju se podskupovi podataka iz skupa podataka za učenje te se svako stablo trenira na drugom podskupu [18, 21]. Dodatno, ne uzimaju se u obzir sve značajke ulaznog skupa podataka koje će se koristiti za podjelu primjera u određenom čvoru odluke, nego su iste nasumično odabrane [18, 21]. Time se sprječava prenaučivost modela na podatke za treniranje, ali i povećava generalizacijska sposobnost klasifikatora [21]. Glavni nedostatak jest velik broj stabala odlučivanja koji zahtijevaju duže vrijeme učenja klasifikacijskog modela i sporije dobivanje rezultata nakon postupka učenja [21].

Shematski prikaz klasifikatora Slučajna šuma (Random Forest Classifier)



Slika 5: Random Forest klasifikator [7]

Metoda potpornih vektora (*SVM*), Slika 6, nalazi hiper-ravninu, tj. plohu koja ima najveću marginu, odnosno udaljenost između primjera različitih klasa [18]. Kritične točke, odnosno primjeri podataka najbliži toj plohi nazivaju se potpornim vektorima. Cilj metode potpornih vektora jest maksimizirati marginu s obzirom da je pretpostavka da generalizacijska sposobnost klasifikatora raste s porastom vrijednosti margine [22]. SVM klasifikatori prema Srivastava i Bhambhu [23] daju bolje rezultate klasifikacije u odnosu na druge metode nadziranog učenja, ali su jako osjetljivi na definiranje parametara klasifikacije. Često korisnici moraju provoditi više unakrsnih provjera (engl. *cross-validation*) što zahtjeva veće vrijeme odabira i postavki modela.




Slika 6: Metoda potpornih vektora (SVM) na primjeru klasifikacije odjeće [7]

Logistička regresija je statistička metoda korištena u klasifikaciji binarnog rješenja, primjerice “da” ili “ne” razreda [24]. S tim u vezi, **Logistic Regression** klasifikator upotrebnom logističke funkcije, poznate još i kao sigmoidna funkcija, stvara odnos između zavisne (klasa) i jedne ili više nezavisnih varijabli i daje rješenje u vidu vjerojatnosti pripadanja primjera određenoj klasi (vrijednost između 0 i 1) [24]. Način rada klasifikatora je lako razumljiv i jednostavan, učinkovit po pitanju vremena rada i memorije, što ga čini pogodnim za rad s većim skupovima podataka i broja značajki [24]. Glavni nedostatak primjene ove metode jest ograničenost na binarne rezultate, osjetljivost na stršće vrijednosti (engl. *outliers*), osjetljivost na prenaučenos modela na podatke za učenje posebice ako je broj značajki primjera veći od broja samih primjera [25]. Iako je *Logistic Regression* primarno binarni klasifikator, u ovom istraživanju se koristi njegova multinomijalna varijanta prilagođena za klasifikaciju u pet različitih klasa tekstilnih plošnih proizvoda.

Naive Bayes je brz i jednostavan probabilistički klasifikator koji se temelji na Bayesovom teoremu uz pretpostavku o jednakosti utjecaja značajki primjera na pridruživanje oznake klase primjeru te njihovoj međusobnoj neovisnosti [4, 18]. U praktičnoj primjeni ovakve “naivne” pretpostavke često nisu slučaj što dovodi do smanjenja točnosti klasifikacije.

Neural Network je višeslojna neuronska mreža (engl. *Multi-layer perceptron, MLP*) kod koje se učenje odvija pomoću algoritma s povratnom propagacijom pogreške (engl. *back-propagation*) [18], Slika 7. Povratna propagacija pogreške obuhvaća širenje kroz mrežu od ulaznog do izlaznog sloja, određivanje pogreške i njenu propagaciju unazad do ulaznog sloja čime se ista ugrađuje u “formulu” za učenje [26]. MLP mreže imaju jedan ulazni, jedan izlazni i jedan ili više skrivenih slojeva neurona.



Slika 7: MLP mreža s jednim ulaznim, jednim skrivenim i jednim izlaznim slojem

Glavna prednost uporabe neuronskih mreža u odnosu na druge konvencionalne metode klasificiranja jest njihova vođenost podacima tako da se lako mogu prilagoditi bilo kojem ulaznom skupu primjera [25]. Nadalje, radi se o nelinearnim modelima što im daje fleksibilnost u kompleksnim odnosima podataka [25]. Iako daju odlične prediktivne rezultate na velikim skupovima ulaznih podataka, nedovoljan broj podataka može dovesti do prenaučivosti na podacima za učenje [26]. Za svoj rad zahtijevaju značajne računalne resurse. Često se smatraju “crnim kutijama” s obzirom da zbog postojanja skrivenih neurona, daju slab uvid u način donošenja odluka klasifikacije [26].

4. Rezultati s raspravom

U radu je klasifikacija provedena u dva pokusa. U prvom pokusu provedeno je trideset mjerenja, a u drugom dvanaest. Rezultati svakog pokusa praćeni su postotkom ispravno klasificiranih primjera, odnosno preko generalizacijske sposobnosti klasifikatora. Rezultati su prikazani tablično (Tablice 3 i 4).

Tablica 3: Rezultati prvog eksperimenta u programskom paketu Weka

Filtar	Broj značajki	<i>Tree</i>	SVM	<i>Random Forest</i>	<i>Naive Bayes</i>	<i>Logistic Regression</i>	<i>Neural Network</i>
CLF	33	79,43	82,93	82,00	54,09	46,32	69,46
EHF	80	58,09	75,45	69,69	45,68	60,35	66,85
FCTHF	192	87,92	84,59	91,13	57,76	82,47	66,89
GF	60	68,43	44,52	69,63	42,80	55,92	59,64
SCHF	64	87,61	71,89	91,69	38,57	68,03	82,49

Najbolji i najlošiji rezultat klasifikacije digitalnih slika postignut je primjenom *SCHF*-filtra. Činjenica da ovaj filtar s *Random Forest* klasifikatorom postiže 91,69 % ispravno klasificiranih primjera sugerira da su boje unutar klasa u ovom specifičnom skupu podataka vrlo diskriminativne, tj. da se učestalost pojavljivanja određenih boja na skeniranim prikazima jasno razlikuje po klasama (npr. možda su tepisi specifičnih boja u odnosu na čipku). Primjena *Random Forest* klasifikatora su se u ovom eksperimentu u prosjeku i postigli najbolji rezultati klasifikacije (raspon između 69,63 % i 91,69 %). Navedeno se može pripisati načinu rada ovog klasifikatora koji kombinira rad višestrukih, nekoreliranih stabala odlučivanja, koji su trenirani na nasumično odabranim skupovima podataka za učenje. Prilikom podjele čvorova u stablu, klasifikator ne uzima u obzir sve značajke već samo nasumični podskup značajki. Time smanjuje korelaciju između stabala i sprječava da jedno dominantno obilježje prevlada, povećavajući raznolikost modela [27].

Kombinacija *SCH*-filtra s *Naive Bayes* klasifikatorom daje najlošiji rezultat klasifikacije od 38,57 %. Ovako nizak postotak ispravno klasificiranih primjera može se povezati s njegovim “naivnim” pretpostavkama o jednakosti utjecaja značajki primjera na pridruživanje oznake klase primjeru te njihovoj međusobnoj neovisnosti. Utjecaj ovih “naivnih” pretpostavki moguće je vidjeti i u kombinaciji s ostalim filtrima gdje je postotak ispravno klasificiranih primjera dostignuo najviše 57,76 % (u kombinaciji s filtrom *FCTHF*).

Tablica 4: Rezultati drugog eksperimenta u programskom paketu Orange Data Mining

CNN	Broj značajki	<i>Tree</i>	SVM	<i>Random Forest</i>	<i>Naive Bayes</i>	<i>Logistic Regression</i>	<i>Neural Network</i>
Google Inception v3	2048	85,42	93,21	92,44	86,29	95,42	95,52
SqueezeNet	1000	86,35	84,88	91,84	73,36	91,46	94,63

U drugom pokusu najslabiji rezultat klasifikacije od 73,36 % postignut je izdvajanjem značajki *SqueezeNet* konvolucijskom neuronskom mrežom u kombinaciji s *Naive Bayes* klasifikatorom. U odnosu na *Google Inception v3*, ova CNN mreža izdvaja vektor s manjim brojem značajki što dovodi do pada preciznosti klasifikacije, posebice u kombinaciji s klasifikatorom koji se temelji na pretpostavkama koje su često “naivne” na praktičnim primjerima. Najbolji rezultat (95,52 %) dobiven je izdvajanjem značajki *Google Inception v3* i primjenom *Neural Network* klasifikatora što ukazuje na dominantnost primjene neuronskih mreža u postupku klasifikacije.

Nadalje, uspoređujući Tablice 3 i 4, može se uočiti kako je primjena konvolucijskih neuronskih mreža prilikom izdvajanja relevantnih značajki dovela do puno većeg postotka ispravno klasificiranih primjera u odnosu na izdvajanje metodom filtracije čak i za jednostavne klasifikatore kao što je *Logistic Regression*. Dok filtri u programskom paketu *Weka* izdvajaju značajke na temelju fiksno definiranih matematičkih formula (npr. histogrami boja ili rubova), konvolucijske neuronske mreže u programskom paketu *Orange Data Mining* automatski uče hijerarhijske prikaze podataka, što rezultira znatno većom diskriminativnom moći modela.

S tehničkog aspekta, tijekom provedbe pokusa uočena je korelacija između preciznosti i računalne zahtjevnosti. Naime, *Google Inception v3* je dao najveću točnost klasifikacije, ali s druge strane zahtijevao je i više vremena za izdvajanje 2048 značajki. *SqueezeNet* se s te strane pokazao kao optimalno rješenje za brzu obradu uz neznatan pad ispravnosti klasifikacije. Nasuprot tome, metoda filtracije u programskom paketu *Weka* pokazala se računalno manje zahtjevnom, ali uz značajno slabiju generalizacijsku moć klasifikatora.

S obzirom da ukupna točnost klasifikacije može biti varljiva kod skupova podataka s neravnomjernim brojem uzoraka po klasama, provedena je dodatna evaluacija oba pokusa primjenom metrike preciznosti, odaziva i F1-vrijednosti. U Tablici 5 prikazane su samo metričke vrijednosti najbolje postignutih rezultata iz oba pokusa.

Tablica 5: Sažeti prikaz ponderiranih metrika za najbolje modele po metodama izdvajanja značajki

Metoda izdvajanja značajki	Klasifikator	Točnost klasifikacije [%]	Preciznost	Odaziv	F1-mjera	F1-mjera (čipka)
SCHF	<i>Random Forest</i>	91,69	0,916	0,917	0,916	0,994
Google Inception v3	<i>Neural Network</i>	95,52	0,955	0,955	0,955	0,996
<i>SqueezeNet</i>	<i>Neural Network</i>	94,63	0,945	0,946	0,946	0,989

Za najuspješniji model (*Google Inception v3 + Neural Network*) F1-mjera iznosi 0,955. Posebno je značajno kako za najmalobrojniju klasu “čipka” postignut rezultat F1-mjere od 0,996 što potvrđuje da metoda dubokog učenja iznimno precizno identificira specifične tekstilne strukture čak i uz manji broj uzoraka.

5. Zaključak

U ovom istraživanju provedena je usporedba klasifikacije tekstilnih plošnih proizvoda primjenom *Weka* i *Orange Data Mining* programskih paketa. Klasifikacija je provedena na skupu od 5173 digitalnih slika tekstilnih materijala podijeljenih u pet klasa: čipke (421), netkani tekstil (2207), pletiva (524), tepisi (644) i tkanine (1377). Analizirana je učinkovitost spomenuta dva programska paketa korištenjem različitih metoda izdvajanja relevantnih značajki. U programu *Weka* korišteni su vizualni filtri (CLF, EHF, FCTHF, GF, SCHF) dok su u programu *Orange Data Mining* korištene konvolucijske neuronske mreže (*Google Inception v3*, *SqueezeNet*). Rezultati nedvojbeno pokazuju superiornost metoda dubokog učenja, pri čemu kombinacija *Inception v3* konvolucijske neuronske mreže i *Neural Network* klasifikatora postiže najvišu točnost od 95,52%. Konvolucijska neuronska mreža *SqueezeNet* je tek neznatno slabija od *Google Inception v3*, ali i dalje superiorna u odnosu na filtracijske metode u programu *Weka* čime se još jednom potvrđuje dominacija pristupa dubokog učenja u izdvajanju relevantnih značajki ulaznog skupa primjera.

Zahvala

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta "Održivi razvoj odjeće dodane vrijednosti: Digitalno prototipiranje, primjena umjetne inteligencije i biomaterijala", AI3D-BioWear, šifra projekta: TTF-IIP-02, koji financira Europska unija – NextGenerationEU.

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta "Transformacija i recikliranje otpadnog asortimana u sekundarni hit", TRASH, šifra projekta: TTF-IIP-03, koji financira Europska unija – NextGenerationEU.

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta "Istraživanje i razvoj održivih, funkcionalnih tekstilnih komponenti za kompozite nove generacije", FUNK-TEX, šifra projekta: TTF-IIP-06, koji financira Europska unija – NextGenerationEU.

6. Literatura

- [1] Bergmann, D.: What is machine learning?, *Dostupan na* <https://www.ibm.com/think/topics/machine-learning>, *Pristupljeno*: 2026-02-01
- [2] Nasteski, V.: An overview of the supervised machine learning methods, *Horizons*, **4** (2015) 51-62, <https://doi.org/10.20544/HORIZONS.B.04.1.17.P05>
- [3] Han J.; Kamber M., Pei, J.: *Data Mining: concepts and techniques 3rd edition*, Morgan Kaufmann Publishers, 978-0-12-381479-1, USA (2012)
- [4] Imamagić, S.; Rolich, T., Penava, Ž.: Primjena algoritama strojnog učenja u svrhu klasifikacije tekstilnih plošnih proizvoda u programskom paketu *Weka, Koža & Obuća*, **73** (2024) 3, 8-13, <https://doi.org/10.34187/ko.73.3.2>
- [5] Nichols, J. A.; Herbert Cjan, H. S., Baker, M. A. B.: Machine learning: applications of artificial intelligence to imaging and diagnosis, *Biophysical Reviews*, **11** (2018) 1, 111-118, <https://doi.org/10.1007/s12551-018-0449-9>
- [6] Seetharaman, P.; Wichern, G., Venkataramani, S., Le Roux, J.: Class-conditional Embeddings for Music Source Separation, *Proceedings of ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 301-306, 978-1-4799-8131-1, Brighton, UK, May 2019, IEEE (2019)
- [7] Slike generirane pomoću modela Gemini 3 Flash Image (Nano Banana 2), Google Gemini 3.1 Pro, <https://gemini.google.com>, *Pristupljeno* 2026-03-12
- [8] <https://medium.com/@abhaysingh71711/filter-method-in-feature-selection-a-key-to-smarter-machine-learning-2e343e837fc7>, *Pristupljeno*: 2026-02-18
- [9] Sánchez-Marroño, N.; Alonso-Betanzos, A., Tombilla-Sanromán, M.: Filter Methods for Feature Selection – A Comparative Study, *Intelligent Data Engineering and Automated Learning - IDEAL 2007*, Yin, H.; Tino, P.; Corchado, E.; Byrne, W.; Yao, X. (Eds.), 178-187, 3540772251, Birmingham, UK, December 2007, Springer (2007)

- [10] Stojanović, A.; Kovačević, Ž., Ivošević, D.: Ansambl metode strojnog učenja, *Polytechnic & Design*, **11** (2023) 4, 245-252, <https://doi.org/10.19279/TVZ.PD.2023-11-4-04>
- [11] Mjahad, A.; Polo-Aguado, A., Llorens-Serrano, L., Rosado-Muñoz, A.: Optimizing Image Feature Extraction with Convolutional Neural Networks for Chicken Meat Detection Applications, *Applied Sciences*, **15** (2025) 2, 1-28, <https://doi.org/10.3390/app15020733>
- [12] <https://www.ibm.com/think/topics/convolutional-neural-networks>, *Pristupljeno*: 2026-02-18
- [13] Raj, R.; Kos, A.: An Extensive Study of Convolutional Neural Networks: Applications in Computer Vision for Improved Robotics Perceptions, *Sensors*, **5** (2025) 4, 1-19, <https://doi.org/10.3390/s25041033>
- [14] Čunko, R.; Pezelj, E.: Tekstilni materijali, *Zrinski d.d.*, 953-155-061-1, Čakovec (2002)
- [15] University of Waikato: Weka 3.8.6 programski paket
- [16] Abidin, D.: The Effect of Derived Features on Art Genre Classification with Machine Learning, *Sakarya University Journal of Science*, **25** (2021) 6, 1275-1286
- [17] Musleh, D.; Alotaibi, M., Alhaidari, F., Rahman, A., Mohammad, R. M.: Intrusion Detection System Using Feature Extraction with Machine Learning Algorithms in IoT, *Journal of Sensor and Actuator Networks*, **12** (2023) 29, 1-19
- [18] <https://orangedatamining.com/>, *Pristupljeno*: 2026-02-26
- [19] Zeng, Y.; Zhu, X.: Skin Cancer Detection Based on Hybrid Model by Means of Inception V3 and ResNet 50, *Proceedings of the 2022 3rd International Conference on Artificial Intelligence and Education*, Fox, B.; Zhao, C.; Anthony, M. T. (Eds.), 275-282, 978-94-6463-040-4, Chengdu, China, June 2022, Atlantis Press Zeger Karssen (2023)
- [20] Hao, M.; Sun, Q., Xuan, C., Zhang, X. Zhao, M.: SqueezeNet: An Improved Lightweight Neural Network for Sheep Facial Recognition, *Applied Sciences*, **14** (2024) 4, 1-13, <https://doi.org/10.3390/app14041399>
- [21] Salman, A. H.; Kalakech, A., Steiti, A.: Random Forest Algorithm Overview, *Babylonian Journal of Machine Learning*, **2024** (2024), 69-79, <https://doi.org/10.58496/BJML/2024/007>
- [22] Srivastava, D.; Bhambhu, L.: Data classification using support vector machine, *Journal of Theoretical and Applied Information Technology*, **12** (2010) 1, 1-7
- [23] Labhade-Kumar, N.: Study of Supervised Logistic Regression Algorithm, *Alochana Journal*, **13** (2024) 11, 227-230
- [24] <https://eris.foi.hr/11neuronske/nn-predavanje5.html>, *Pristupljeno*: 2026-03-05
- [25] Zhang, G. P.: Neural Networks for Classification: A Survey, *IEEE Transactions on Systems Man and Cybernetics Part C (Applications and Reviews)*, **30** (2000) 4, 451-462, <https://doi.org/10.1109/5326.897072>
- [26] https://www.researchgate.net/post/What_are_some_criticisms_of_Neural_Networks2, *Pristupljeno*: 2026-03-01
- [27] Baladram: Random Forest, Explained: A Visual Guide with Code Examples, <https://towardsdatascience.com/random-forest-explained-a-visual-guide-with-code-examples-9f736a6e1b3c/>, *Pristupljeno*: 2026-03-03

Primjena umjetne inteligencije za digitalizaciju tekstilnih materijala kod 3D simulacije odjeće

Slavenka Petrak¹, Maja Mahnić Naglič¹

¹Sveučilište u Zagrebu Tekstilno-tehnološki fakultet, Zavod za odjevnu tehnologiju, Prilaz baruna Filipovića 28a, Zagreb

Sažetak: U radu je prikazano istraživanje utjecaja metoda ispitivanja svojstava tekstilnih materijala na 3D simulaciju i razvoj digitalnih prototipova odjeće, s fokusom na primjenu UI tehnologije, kao pristupačnije i prihvatljivije metode u kontekstu održivosti razvojnog procesa. Digitalizacija tekstilnih materijala predstavlja značajan izazov u procesu razvoja 3D modela odjeće, o čemu ovise realističnost i procjena pristalosti u skladu sa željenim oblikom i zahtjevima za funkcionalnošću. U istraživanju je postavljena metodologija vrednovanja digitalnih prototipova odjeće, razvijenih primjenom podataka o mehaničkim svojstvima tkanina utvrđenih različitim metodama, koja omogućuje objektivnu evaluaciju na temelju komparativne analize parametara drapiranja. Istraživanje provedeno na šest tkanina, pokazalo je vrlo dobru korelaciju rezultata digitalnih prototipova razvijenih primjenom mehaničkih parametara KES-FB sustava i SEDDI Textura UI aplikacije, što podržava uporabu UI tehnologije za procjenu svojstava tkanina, potrebnih za 3D simulaciju.

Ključne riječi: digitalizacija svojstava tekstilnih materijala, umjetna inteligencija, 3D simulacija odjeće

1. Uvod

Transformacija odjevne i modne industrije posljednjih godina je značajno potaknuta primjenom računalnih alata i cjelovitih sustava za razvoj digitalnih proizvoda u virtualnom okruženju, simulacijskih tehnologija te novih metoda digitalizacije tekstilnih materijala. U fokusu je razvoj digitalnih blizanaca, koji dizajnerima i članovima razvojnih timova omogućuju evaluaciju i prilagodbu dizajna, analizu krojeva, pristalosti i funkcionalnosti modela te ciljane prilagodbe, bez potrebe za izradom velikog broja fizičkih prototipova [1, 2]. Pri tome je posebno važno da se u virtualnom okruženju može vjerodostojno reproducirati ponašanje stvarnih tekstilnih materijala, s obzirom na utjecaj

koji imaju na oblikovanje forme modela i nabora, kao i funkcionalnost modela koja se procjenjuje s aspekta analize deformacija tekstilnih materijala, po pojedinim zonama digitalnog prototipa odjevnog predmeta [3-5]. Metode 3D simulacije odjeće uključuju fizikalnu simulaciju spajanja 2D krojnih dijelova oko 3D modela tijela, simulaciju kontakta između 3D modela tijela i tekstilnog materijala pridruženog krojnim dijelovima digitalnog odjevnog predmeta, kao i interakciju između slojeva tekstilnog materijala, sve pod utjecajem vanjskih čimbenika poput gravitacije [6]. Stoga je precizno određivanje mehaničkih svojstava tekstilnih materijala ključno za razvoj digitalnih prototipova odjeće, koji mogu pouzdano simulirati stvarno ponašanje i omogućiti odabir tekstilnih materijala od kojih će se određeni model u konačnici izrađivati. Tradicionalni pristupi određivanju vrijednosti parametara mehaničkih svojstava tekstilnih materijala temelje se na laboratorijskim ispitivanjima uzoraka, primjenom specijalizirane mjerne opreme. Jedan od najpoznatijih sustava za objektivno vrednovanje tekstilnih materijala je Kawabata Evaluation System (KES-FB), sastavljen od četiri mjerna uređaja za mjerenje parametara vlačnih, savojnih, smičnih, kompresijskih i površinskih svojstava [7]. Iako primjena ovakvog mjernog sustava omogućuje utvrđivanje točnih i pouzdanih vrijednosti, njegova primjena je ograničena uglavnom na znanstveno-istraživački rad jer zahtijeva visoku razinu stručnosti, posebno u interpretaciji rezultata mjerenja, cijena opreme zahtijeva značajna financijska ulaganja, a sam proces je dugotrajan te zahtijeva pripremu i kondicioniranje veće količine stvarnih uzoraka, u laboratorijskim uvjetima prije samog procesa mjerenja. Svi navedeni uvjeti utjecali su na slabu zastupljenost i primjenu ovakvog sustava u industrijskim uvjetima te se paralelno s razvojem pojedinog CAD sustava za razvoj digitalnih prototipova odjeće postupno razvijaju i mjerni sustavi za vrednovanje svojstava [8-10].

Razvoj alata umjetne inteligencije u posljednjih nekoliko godina potaknuo je razvoj novih pristupa i metoda digitalizacije svojstava tekstilnih materijala, koji proces čine znatno bržim, jednostavnijim i financijski pristupačnim istraživačima i razvojnim timovima u tvrtkama. Metode temeljene na primjeni alata umjetne inteligencije koriste algoritme strojnog učenja za procjenu vrijednosti parametara mehaničkih svojstava tekstilnih materijala na temelju dostupnih podataka o materijalu, čime se smanjuje potreba za složenim laboratorijskim ispitivanjima i skupom opremom. Među takvim alatima ističe se aplikacija SEDDI Textura, koja omogućuje procjenu vrijednosti parametara mehaničkih svojstava potrebnih za 3D simulaciju, analizu i vrednovanje deformacija tekstilnih materijala na digitalnom prototipu modela tijekom njegovog razvoja [11]. Unatoč istaknutim prednostima koje ovakav pristup nudi, pitanje točnosti i pouzdanosti u odnosu na tradicionalna laboratorijska mjerenja još uvijek nije dovoljno istraženo. U tom smislu, ističe se potreba za sustavnom procjenom točnosti digitalizacije svojstava tekstilnih materijala primjenom alata umjetne inteligencije, odnosno komparacijom procijenjenih vrijednosti s vrijednostima utvrđenim laboratorijskim ispitivanjima i mjerenjima. Sukladno navedenom, cilj ovog istraživanja je ispitati primjenu parametara mehaničkih svojstava utvrđenih SEDDI Textura UI aplikacijom na odabranom setu uzoraka tekstilnih materijala u odnosu na primjenu

vrijednosti utvrđenih laboratorijskim mjerenjima na istom setu uzoraka primjenom KES-FB mjernog sustava. Rezultati prikazanog istraživanja doprinose boljem razumijevanju pouzdanosti alata umjetne inteligencije za procjenu mehaničkih svojstava tekstilnih materijala, njihovoj digitalizaciji i primjeni rezultata u procesu digitalnog razvoja odjeće i drugih tekstilnih proizvoda.

Digitalna transformacija u procesu dizajna i razvoja novih kolekcija odjeće ima iznimno važnu ulogu jer ima značajan utjecaj na održivost, posebno s aspekta smanjenja troškova povezanih s tekstilnim materijalima i izvorima energije koji proizlaze iz tradicionalnog proizvodnog procesa i izrade višestrukih stvarnih prototipova [12-14]. Unatoč sve većoj digitalizaciji cjelokupnog procesa, dizajn i konstrukcija modela i dalje se provjeravaju izradom stvarnih prototipova te se ovisno o složenosti modela, korekcije krojeva i izrada prototipova provode u više iteracija, čime se povećava količina tekstilnog otpada i stvaraju dodatni troškovi vezani uz prekomjerno trošenje materijala i transport između brendova i dislociranih dobavljača koji proizvode uzorke modela, što posljedično pridonosi onečišćenju okoliša i narušavanju ekosustava [14, 15]. Brendovi koji primjenjuju digitalno prototipiranje izvještavaju o smanjenju troškova uzorkovanja i do 80 %, te do 50 % kraćem vremenu izlaska proizvoda na tržište [16-18]. Iz tog razloga se na globalnoj razini uspostavlja sve veći broj inicijativa i direktiva usmjerenih na smanjenje negativnog utjecaja ove industrije putem digitalne transformacije, inovacija u proizvodnji i novih poslovnih modela koji osiguravaju konkurentnost, smanjenje troškova i povećanje učinkovitosti [19-21].

2. Pregled dosadašnjih istraživanja

Digitalne i tehnološke inovacije značajno mijenjaju pristup razvoju kolekcija odjeće. Od procesa dizajna u koji se sve više integriraju digitalni alati za izradu skica, koji omogućuju brži i kvalitetniji razvoj i prezentaciju dizajnerskih ideja, do razvoja krojeva primjenom specijaliziranih 2D/3D CAD sustava za proizvodnju odjeće, koji također omogućuju digitalnu komunikaciju s poslovnim partnerima te prezentaciju i prodaju digitalnih ili stvarnih modnih proizvoda kupcima putem računalnih platformi. Digitalni 3D dizajn odjeće omogućuje brže i preciznije digitalno prototipiranje umjesto izrade više stvarnih prototipova, čime se štede resursi, smanjuju troškovi i posljedično smanjuje negativan utjecaj na okoliš [22-24].

Digitalizacija tekstilnih materijala predstavlja ključni korak u procesu virtualnog dizajna odjeće jer omogućuje simulaciju mehaničkog ponašanja tkanina u 3D CAD okruženju. Različiti CAD sustavi za razvoj digitalnih prototipova odjevnih modela kod 3D simulacije primjenjuju podatke o fizikalnim i mehaničkim svojstvima tekstilnih materijala određene različitim sustavima za vrednovanje [1, 8-11], što predstavlja jedan od najistaknutijih problema u implementaciji digitalnog prototipiranja u proizvodni proces. Osim najpoznatijeg KES mjernog sustava [4, 7], razvijeni su i drugi, noviji sustavi,

od kojih su poznatiji CLO Fabric Kit [8] i Browzwear-ov Fabric Analyser (FAB) [9]. Ovakvi uređaji izravno mjere i analiziraju deformacijsko ponašanje ciljanog tekstilnog materijala iz čega se utvrđuju vrijednosti mehaničkih parametara, potrebni za primjenu kod 3D simulacije u CAD sustavu za razvoj digitalnih prototipova odjeće [25, 26]. Nedostaci primjene ovakvih uređaja su uglavnom visoka cijena te složen i dugotrajan proces mjerenja koji obično zahtijeva visoku razinu stručnosti i iskustva pri ispitivanju kako bi se osigurala pouzdanost utvrđenih rezultata. Dodatni problem predstavlja nedostatak standardiziranih metoda i setova podataka, što često dovodi do ograničene interoperabilnosti između različitih CAD sustava i mjernih uređaja [27, 28].

U novije vrijeme razvijaju se metode koje koriste metapodatke o materijalu ili vizualne informacije (poput fotografija ili videozapisa), uz primjenu umjetne inteligencije (UI) i algoritama strojnog učenja za procjenu njihovih mehaničkih karakteristika. Prednost ovih metoda je u tome što ne zahtijevaju specijaliziranu laboratorijsku opremu što ubrzava i pojednostavljuje postupak ispitivanja za krajnjeg korisnika i čime se povećava fleksibilnost i dostupnost postupka digitalizacije [22, 29, 30]. Prema dostupnoj literaturi razlikuju se dva osnovna pristupa. U prvom pristupu simulacije se koriste za iterativno prilagođavanje parametara tekstilnog materijala, dok se ne postigne odgovarajuća podudarnost između simuliranog i stvarnog ponašanja tkanine, pri čemu ulazni podaci mogu biti pojedinačne slike odjevnih predmeta ili video sekvence njihova kretanja [31]. U drugom pristupu, simulacije se koriste za generiranje velikih skupova podataka, koji služe za treniranje modela strojnog učenja, čime se omogućuje procjena vrijednosti mehaničkih parametara na temelju vizualnih informacija iz video ili slikovnih prikaza [32, 33]. Neki od pristupa digitalizaciji tkanina temelje se na primjeni dubinskih slika [34] i koeficijentata trenja [35], dok metode vođene podacima [36, 37] koriste deskriptore gibanja i 3D granične podatke za identifikaciju sličnih tkanina. Iako su ovi pristupi znanstveno zanimljivi i obećavajući, većina takvih metoda još uvijek nije pronašla širu primjenu izvan istraživačkih laboratorija.

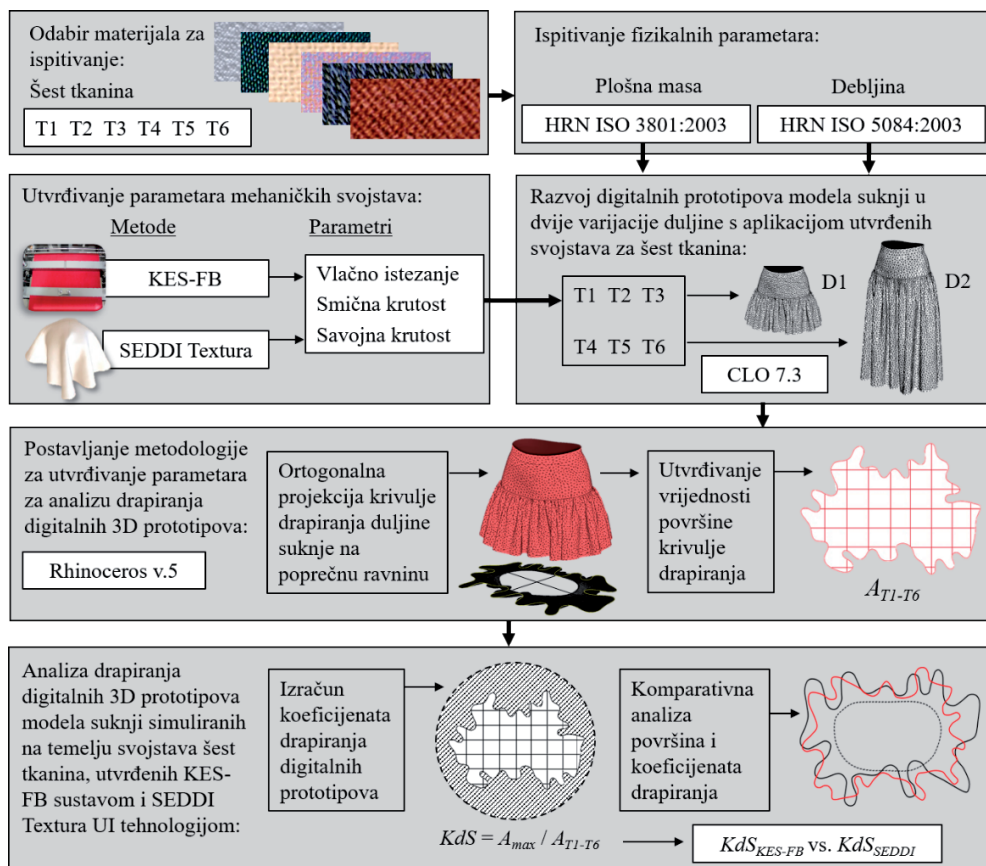
Najnoviji smjer razvoja u području digitalizacije tekstilnih materijala temelji se na korištenju metapodataka o tkaninama. Ove metode koriste algoritme strojnog učenja trenirane na velikim skupovima podataka koji sadrže informacije o strukturi, gustoći, sastavu i debljini tkanina, dok se kao izlazni podaci dobivaju procijenjene vrijednosti mehaničkih parametara materijala. Prema jednom od novijih pregleda literature, najučinkovitiji algoritmi za predviđanje složenih svojstava tekstilnih materijala i njihovu implementaciju u CAD sustave za digitalno prototipiranje odjeće jesu hibridni modeli koji kombiniraju umjetnu inteligenciju, strojno učenje i fizikalne simulacije [30, 38]. Simulacije temeljene na metodi konačnih elemenata te UI modeli koji uključuju umjetne i konvolucijske neuronske mreže postižu visoku preciznost u predviđanju mehaničkih svojstava tekstilnih materijala [37, 39], dok kombinacije s tehnikama neizravne logike dodatno povećavaju točnost predviđanja drapiranja tkanina [40, 41]. Zbog svoje jednostavnosti, brzine i relativno niskih troškova primjene, takvi pristupi sve se češće uvode u industrijsku praksu. U posljednje vrijeme razvijeno je nekoliko

komercijalnih rješenja koja omogućuju procjenu parametara tkanina upravo na temelju metapodataka, među kojima se ističu sustavi poput SEDDI Textura [11], CLO Fabric Creator [8] i Vizoo physX [42]. Budući da je postupak određivanja svojstava tekstilnih materijala i njihove implementacije u CAD sustave za digitalno 3D prototipiranje znatno pojednostavljen, takvi sustavi omogućuju dizajnerima jednostavno variranje modela s obzirom na različite tkanine, o čijim svojstvima u velikoj mjeri ovise konačni izgled, oblik i pristajanje modela, čime se znatno olakšava odabira odgovarajućeg materijala za određeni model. Osim parametara fizikalnih i mehaničkih svojstava uzorka tekstilnog materijala, sustavi generiraju i podatke o prozirnosti i hrapavosti površine koji kod simulacije osiguravaju visoku realističnost prikaza površine modela odjavnog predmeta, a također je moguće i generirati podatke o cijeni, dostupnosti zaliha kod proizvođača i/ili podrijetlu i utjecaju pojedinih materijala na okoliš, čime se dizajnerima i razvojnim inženjerima omogućuje donošenje odluka o odabiru ekološki prihvatljivih materijala [11, 22].

Procjena točnosti postupaka digitalizacije tkanina zahtijeva i jasno definirane metode za evaluaciju točnosti digitalnih modela materijala. Međutim, dostupna literatura koja se bavi industrijskim metodama evaluacije pada tkanina relativno je ograničena. U industriji odjeće često se koristi pojam evaluacije, koji podrazumijeva procjenu odstupanja između simuliranog i stvarnog ponašanja tkanine, unutar prihvatljivih granica pogreške. Jedan od rijetkih sustavnih pregleda metoda validacije digitalnih tkanina predstavila je organizacija 3D Retail Coalition, koja je analizirala različite pristupe koje koriste proizvođači 3D CAD sustava [43]. U praksi su razvijeni i specifični postupci za validaciju digitalnog pada tkanina [27, 44-46]. Primjerice, razvijen je postupak u kojem se kvadratni uzorak tkanine postavlja preko kugle te se dobiveni oblik fotografira pod kontroliranim uvjetima, iz više kutova promatranja. Takav se eksperimentalni postupak može replicirati i u digitalnom simulacijskom okruženju, što omogućuje izravnu usporedbu stvarnog i simuliranog rezultata. Točnost digitalnog modela procjenjuje se usporedbom širine najširih dijelova drapiranog uzorka tkanine u stvarnom i simuliranom prikazu, pri čemu se digitalni model smatra evaluiranim, ako odstupanje mjerenja ne prelazi određeni prag pogreške, do 20 % od stvarnog mjerenja tkanine. Na sličan način primjenjuje se i standardna Cusick Drape Meter metoda, korištena i u ovom istraživanju, kod koje se koriste kružni uzorci tkanina, postavljeni na kružni nosač manjih dimenzija, pri čemu rubovi uzorka slobodno padaju pod utjecajem vlastite težine. Metodu je također moguće reproducirati u digitalnim uvjetima, što omogućuje usporedbu realnih i simuliranih uzoraka tekstilnih materijala i evaluaciju procesa simulacije na temelju korelacije utvrđenih koeficijentata drapiranja (K_d), koji u području ispitivanja materijala predstavljaju standardni parametar za vrednovanje drapiranja [3, 45]. U kontekstu navedenih istraživanja posebno je važno sustavno procijeniti točnost novih pristupa digitalizaciji, temeljenih na umjetnoj inteligenciji, u usporedbi s tradicionalnim laboratorijskim metodama mjerenja mehaničkih svojstava tkanina, što predstavlja temelj za razumijevanje potencijala UI tehnologija u području digitalnog razvoja i simulacije odjavnih predmeta.

3. Eksperimentalni dio

Na Slici 1 prikazan je plan rada provedenog istraživanja utjecaja metoda ispitivanja svojstava tekstilnih materijala na 3D simulaciju i razvoj digitalnih prototipova odjeće.



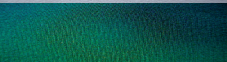





Slika 1: Plan istraživanja

3.1 Tekstilni materijali

U istraživanju je korišteno šest tkanina različitog sirovinskog sastava, veza i strukturalnih svojstava, Tablica 1.

Tablica 1: Vez tkanina i prikaz skenirane površine

Tkanina	Vez	Skenirana površina tkanine	Tkanina	Vez	Skenirana površina tkanine
T1	Platno 1/1		T4	Platno 1/1	
T2	Keper 3/1		T5	Keper 2/1	
T3	Keper 2/1		T6	Keper 2/1	

Tkanine T1 i T2 izrađene su od poliesterskih vlakana, tkanine T3 do T5 su mješavine poliesterskih i elastanskih vlakana s vunom, pamukom i viskozom u različitim omjerima, dok je tkanina T6 izrađena od mješavine poliesterskih vlakana s manjim udjelom elastanskih vlakana. Sve tkanine prikladne su za izradu ženske vanjske odjeće. Odabrani sirovinski sastavi i mješavine vlakana predstavljaju najčešće kombinacije u komercijalnoj proizvodnji te se primjenjuju u izradi širokog spektra odjevnih proizvoda. Gustoća niti po jedinici duljine, masa po jedinici površine te debljina uzoraka tkanina određeni su u skladu s važećim normama [47-49], Tablica 2.

Tablica 2: Karakterizacija tkanina

Tkanina	Sirovinski sastav	Gustoća niti [niti/cm]		Plošna masa [g/m ²]	Debljina [mm]
		osnova	potka		
T1(M2)	100 % poliestersko vlakno	72,8	36,3	83,66	0,25
T2 (M1)	100 % poliestersko vlakno	112,2	41,2	135,17	0,31
T3 (M3)	75 % vuna 15 % poliestersko vlakno 10 % elastansko vlakno	23,7	24,1	178,70	0,40
T4 (M5)	97 % poliestersko vlakno 3 % elastansko vlakno	60,3	31,7	242,00	0,56
T5 (M6)	65 % pamuk 31 % poliestersko vlakno 4 % elastansko vlakno	42,6	18,1	253,36	0,62
T6 (M4)	63 % poliestersko vlakno 33 % viskoza 4 % elastansko vlakno	35,7	28,2	286,13	0,61

3.2 Ispitivanje parametara mehaničkih svojstava tekstilnih materijala primjenom KES-FB sustava

Za ispitivanje vlačnih, smičnih i savojnih svojstava odabranih tkanina korišten je Kawabata Evaluation System (KES-FB) mjerni sustav za objektivno vrednovanje tekstila i odjeće. Prema metodologiji sustava, korišteni su uzorci dimenzija 20x20

cm, koji su prethodno kondicionirani na standardne uvjete temperature od 21 ± 1 °C i 65 ± 1 % relativne vlažnosti. Za potrebe 3D simulacije i ispitivanje drapiranja modela suknje korištene su vrijednosti mehaničkih parametara vlačnog istežanja u smjeru osnove i potke pri maksimalnoj sili od 490,35 N/m (*EMT-1/osnova* i *EMT-2/potka*), smična krutost (*G*) te savojna krutost u smjeru osnove i potke (*B-1/osnova* i *B-2/potka*), prikazane u Tablici 3 [7].

Tablica 3: Utvrđene vrijednosti parametara mehaničkih svojstava primjenom KES-FB sustava

Tkanina	Vlačna svojstva		Smična svojstva	Savojna svojstva	
	<i>EMT-1</i> [%]	<i>EMT-2</i> [%]	<i>G</i> [cN/(cm ²)-1]	<i>B-1</i> [cNcm]	<i>B-2</i> [cNcm]
T1	3,90	31,28	0,46	0,0085	0,0033
T2	2,75	6,92	0,41	0,0195	0,0061
T3	9,05	11,49	0,50	0,0214	0,0200
T4	20,43	18,15	0,57	0,0322	0,3880
T5	3,48	21,15	1,26	0,0743	0,0370
T6	21,54	22,05	0,61	0,0297	0,0240

Za potrebe 3D simulacije u programu za razvoj digitalnih prototipova odjeće CLO, vrijednosti parametara utvrđene KES-FB sustavom su preračunate u mjerne jedinice naprežanja materijala koje podržava program, Tablica 4 [4, 50].

Tablica 4: Vrijednosti mehaničkih parametara preračunati u jedinice za unos u program CLO

Tkanina	Vlačna svojstva		Smična svojstva	Savojna svojstva	
	Istežanje osnova [g/s ²]	Istežanje potka [g/s ²]	Smik [g/s ²]	Savoj osnova [gmm ² /s ²]	Savoj potka [gmm ² /s ²]
T1	471944	373515	46000	850	330
T2	477226	458614	41000	1950	610
T3	449656	439815	50000	2140	2000
T4	407166	415023	57000	3220	3880
T5	473860	404746	126000	7430	3700
T6	403447	401762	61000	2970	2400

3.3 Digitalizacija tekstilnih materijala primjenom UI tehnologije

Za digitalizaciju uzoraka tkanine primjenom UI tehnologije korištena je aplikacija SEDDI Textura [11]. Aplikacija koristi skenirane slike stvarnih uzoraka materijala,

Tablica 1, i ulazne podatke o sirovinskom sastavu, plošnoj masi i debljini tkanina, Tablica 2, na temelju čega procjenjuje vrijednosti mehaničkih parametara za vlačna, smična i savojna svojstva. Digitalni prikazi površine analiziraju se sloj po sloj, na temelju čega se generiraju 3D uzorci tkanina u formatima (U3M ili Zfab), prikladnima za direktnu implementaciju u CAD programe za razvoj digitalne odjeće CLO i Browzwear. Vrijednosti parametara mehaničkih svojstava utvrđeni SEDDI Textura aplikacijom, za šest odabranih tkanina, prikazani su u Tablici 5.


Tablica 5: Vrijednosti mehaničkih parametara utvrđene primjenom SEDDI Textura UI aplikacije

Tkanina	Vlačna svojstva		Smična svojstva	Savojna svojstva	
	Istezanje osnova [g/s ²]	Istezanje potka [g/s ²]	Smik [g/s ²]	Savoj osnova [gmm ² /s ²]	Savoj potka [gmm ² /s ²]
T1	685657	605199	53349	529	600
T2	775798	668222	66711	1568	2090
T3	590790	389397	46739	1687	1293
T4	664904	490003	59571	3234	2747
T5	666580	413367	114243	7119	2946
T6	647152	361808	75174	5231	2191

Jedna od istaknutih prednosti primjene UI tehnologije za utvrđivanje vrijednosti parametara mehaničkih svojstava za potrebe 3D simulacije je to što nema potrebe za pripremom uzoraka. To izravno ima pozitivan učinak s aspekta održivosti s obzirom da se smanjuju energetske i materijalne resursi vezani uz potrebno kondicioniranje uzoraka te se smanjuje količina otpada uzrokovana velikim brojem uzoraka koji se odbacuju nakon ispitivanja. Također je omogućena procjena svojstava materijala na već gotovom odjevnom predmetu bez potrebe za uništavanjem odjevnog predmeta u smislu izrezivanja uzorka tekstila za ispitivanje, što ima posebno značajan potencijal u području restauracije i konzervacije povijesnih tekstilnih materijala gdje destruktivne metode ispitivanja nisu primjenjive.


3.4 3D simulacija i računalna analiza drapiranja modela suknje

Računalna analiza drapiranja tkanina provedena je na digitalnim 3D prototipovima ženske suknje s volanom u dvije varijacije duljine: mini (D1) i maksimi (D2), razvijanim u CAD programu CLO v.2025 [50], Slika 2. Parametri površinske poligonalne mreže modela postavljeni su na visoku rezoluciju s duljinom stranice poligona od 4 mm, pri čemu su simulacije izvođene s pedeset iteracija i vremenskim razmakom od 0,033 sekunde.



Slika 2: Model suknje u dvije varijacije duljine: a) krojni dijelovi, b) digitalni prototipovi s prikazom projekcije drapiranja modela na duljini

Drapiranje tkanine se definira kao kompleksna deformacija koja nastaje pri slobodnom padu tkanine pod utjecajem vlastite težine te uvelike ovisi o vlačnim i smičnim svojstvima, kao i o površinskoj masi i debljini materijala. Drapiranje se standardno utvrđuje primjenom Cusick Drape Meter metode i izračunom koeficijenta drapiranja koji predstavlja omjer između nedrapirane površine kružnog uzorka tkanine i drapirane površine uzorka postavljenog na kružni nosač manjih dimenzija, pri čemu rubovi slobodno padaju pod utjecajem težine tkanine [51, 52]. Suknja kao odjevni predmet se na tijelu ponaša na sličan način, u području između struka i bokova priliježe uz tijelo, dok prema duljini slobodno pada pri čemu se oblikuju nabori koji definiraju drapiranje modela. U tom smislu, za računalnu analizu drapiranja digitalnih 3D prototipova modela suknji postavljena je metodologija utvrđivanja krivulja i izračuna koeficijenta drapiranja temeljena na Cusick Drape Meter metodi, Slika 3.



Slika 3: Postavljena metodologija izračuna koeficijenta drapiranja digitalnih prototipova modela suknji temeljena na Cusick Drape Meter metodi

Koeficijent drapiranja digitalnog prototipa modela suknje (KdS), definiran je kao omjer drapirane površine simuliranog modela suknje (A_{T1-Tn}) i maksimalne moguće površine unutar krivulje duljine modela (A_{max}) izražene u mm^2 , Slika 3, te se izračunava pomoću izraza (1):

$$KdS = \frac{A_{T1-Tn}}{A_{max}} [mm^2], \quad (1)$$

Maksimalna površina krivulje na duljini modela suknje (A_{max}) izvedena je iz opsega krivulje, koji je poznat na temelju duljine segmenata ruba suknje i izračunat preko izraza (2):

$$O_{length} = 2560 \text{ mm} \Rightarrow r = \frac{O_{length}}{2\pi} \Rightarrow A_{max} = \frac{O_{length}^2}{4\pi} = 521518.917 \text{ mm}^2, \quad (2)$$


Izvedene su 3D simulacije modela suknji u dvije varijacije duljine s primjenom utvrđenih mehaničkih parametara za šest odabranih tkanina. Digitalni prototipovi modela izvezeni su u standardnom .obj 3D formatu i uvezeni u Rhinoceros v.5 program, u kojem je provedena daljnja obrada modela i mjerenje parametara za izračun koeficijentata drapiranja. Na temelju digitalnih prototipova, nabori na suknjama su projicirani na poprečnu ravninu, te su pomoću ortogonalnih projekcija kreirane krivulje drapiranja. Krivulje drapiranja su zatvorene u površine, te su izmjerene vrijednosti površina potrebne za daljnju analizu i izračun koeficijentata drapiranja.

Na temelju predstavljene metodologije, provedena je komparativna analiza 3D simulacije drapiranja za šest različitih tkanina na temelju mehaničkih parametara svojstva određenih mjernim sustavom KES-FB i digitalizacijom pomoću SEDDI Textura UI aplikacije. Izvedeno je preklapanje digitalnih prototipova, pri čemu su analizirani oblici i vrijednosti površina unutar utvrđenih krivulja drapiranja na duljini simuliranih modela i razlike u vrijednostima izračunatih koeficijentata drapiranja, Tablica 6.


4. Rezultati

Analiza oblika krivulja drapiranja izvedena je preklapanjem modela simuliranih na temelju KES-FB i SEDDI Textura parametara. Na preklapljenim prikazima vidljive su razlike u oblicima krivulja ovisno o duljini, pri čemu su u usporedbi s malim i nepravilnim naborima na duljini D1, pravilniji i dublji nabori oblikovani na modelima veće duljine D2, Slika 4a. To pokazuje učinak ukupnog povećanja mase na drapiranje i formiranje nabora na duljini odjavnog predmeta. S povećanjem duljine, odnosno volana na suknji, povećava se i ukupna masa modela, što dodatno pojačava utjecaj savojnih svojstava na drapiranje i formiranje nabora. Stoga je i očekivano da će se na većoj duljini formirati pravilnije krivulje koja obuhvaćaju manju površinu, što znači da će i koeficijenti drapiranja biti manji u usporedbi s drapiranjem kraćih modela duljine D1, Slika 4b i 4c.


Vrijednosti utvrđenih površina i izračunati koeficijenti drapiranja digitalnih 3D prototipova modela suknji simuliranih na temelju KES-FB i SEDDI Textura parametara, u dvije varijacije duljine, prikazani su u Tablici 6. Na obje duljine suknji, veće razlike utvrđene su kod modela simuliranih na temelju uzoraka tkanina T1 i T2, Slika 5. Ako analiziramo vrijednosti ispitanih svojstava tkanina, Tablice 2 i 3, uočljivo je da uzorci tkanina T1 i T2 imaju značajno manju plošnu masu ($T1 = 83,6 \text{ g/m}^2$, $T2 = 135 \text{ g/m}^2$) u odnosu na ostale tkanine i niže izmjerene vrijednosti parametara savojne i smične krutosti ($G = 0,41 - 0,46 \text{ cN}/(\text{cm}^\circ)\text{-1}$, $B = 0,003 - 0,019 \text{ cN}/\text{cm}$), što ih čini izuzetno mekanim i deformabilnim tkaninama. Također, ako usporedimo vrijednosti parametara mehaničkih svojstava izmjerene primjenom KES-FB sustava i digitalizacijom pomoću SEDDI Textura UI aplikacije, kod uzoraka tkanina T1 i T2 mogu se uočiti veće razlike u vrijednostima parametara između dvije metode mjerenja, što ima značajan utjecaj na simulaciju i razlike u drapiranju digitalnih prototipova modela suknji.



Slika 4: Komparativna analiza krivulja i koeficijenata drapiranja digitalnih prototipova modela suknji u odnosu na duljinu modela: a) prikaz preklapljenih krivulja drapiranja u varijacijama duljine D1 i D2, b) komparativni dijagram vrijednosti utvrđenih koeficijenata drapiranja modela duljine D1 i D2 s primjenom parametara KES-FB sustava, c) komparativni dijagram vrijednosti utvrđenih koeficijenata drapiranja modela duljine D1 i D2 s primjenom parametara SEDDI Textura aplikacije



a)

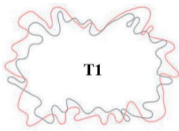
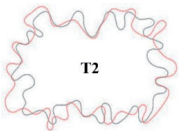
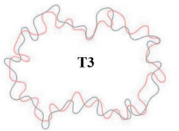
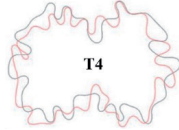
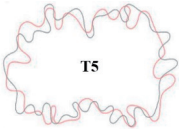
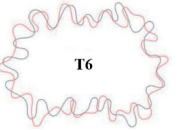
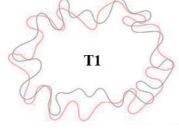
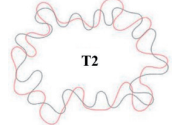
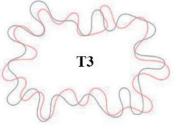
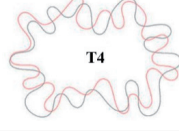
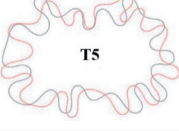
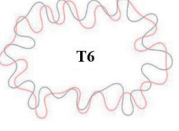


b)

Slika 5: Komparativna analiza vrijednosti utvrđenih koeficijenata drapiranja digitalnih prototipova simuliranih primjenom KES-FB i SEDDI Textura parametara: a) duljina D1, b) duljina D2

S obzirom na različite metodologije utvrđivanja parametara mehaničkih svojstava između dvije primijenjene metode ispitivanja tkanina, razlike u izmjerenim vrijednostima, Tablice 4 i 5, su očekivane. KES-FB sustav se temelji na ispitivanju svojstava kod niskih opterećenja ($F_{max} = 490,35$ N/m), što u F/ε dijagramu vlačnog ponašanja obuhvaća isključivo linearno područje, stoga preračunate vrijednosti kod unosa u CAD program za 3D simulaciju odjeće sustavno predviđaju veće vrijednosti deformacija u odnosu na vrijednosti procijenjene primjenom SEDDI Textura UI aplikacijom. UI tehnologija primjenjuje metode strojnog učenja koja su trenirane na velikim bazama podataka utvrđenih različitim metodama mjerenja, čime obuhvaćaju značajno širi raspon mjerenja u odnosu na linearno područje na kojem se bazira KES-FB sustav.


Tablica 6: Analiza oblika krivulja drapiranja, vrijednosti utvrđenih površina i izračunati koeficijenti drapiranja digitalnih 3D prototipova modela suknji simuliranih na temelju parametara šest tkanina ispitanih primjenom sustava KES-FB i SEDDI Textura UI aplikacije, u dvije varijacije duljine modela

Duljina		D1		
Preklopljene krivulje				
A [m ²]	KES-FB ■	0,131	0,134	0,142
	SEDDI ■	0,168	0,151	0,135
KdS	KES-FB ■	0,251	0,257	0,272
	SEDDI ■	0,321	0,290	0,258
Preklopljene krivulje				
A [m ²]	KES-FB ■	0,146	0,156	0,132
	SEDDI ■	0,144	0,153	0,139
KdS	KES-FB ■	0,280	0,299	0,254
	SEDDI ■	0,275	0,293	0,266
Duljina		D2		
Preklopljene krivulje				
A [m ²]	KES-FB ■	0,118	0,124	0,119
	SEDDI ■	0,130	0,132	0,114
KdS	KES-FB ■	0,227	0,237	0,228
	SEDDI ■	0,250	0,253	0,219
Preklopljene krivulje				
A [m ²]	KES-FB ■	0,118	0,125	0,121
	SEDDI ■	0,113	0,128	0,126
KdS	KES-FB ■	0,226	0,240	0,232
	SEDDI ■	0,217	0,245	0,241

* A [m²] - površina unutar krivulje drapiranja izražena u m², KdS - koeficijent drapiranja odjevnog predmeta, KES-FB - vrijednosti utvrđene na temelju modela simuliranih s parametrima Kawabata Evaluation sustava, SEDDI - vrijednosti utvrđene na temelju modela simuliranih s parametrima SEDDI Textura UI aplikacije, T1-T6 - krivulje modela simuliranih na temelju parametara ispitivanih tkanina T1 do T6

Procjene vrijednosti parametara primjenom UI tehnologije proizlaze iz učenja iz velikih skupova podataka, multimodalnog unosa i optimizacije prema ishodima simulacije, što se značajno razlikuje od pojedinačnih mjerenja primjenom standardnih metoda ispitivanja tkanina. Utvrđene razlike u vrijednostima parametara koje su posebno izražene kod tkanina male plošne mase i niskih vrijednosti savojne i smične krutosti, kao što je to slučaj kod tkanina T1 i T2, ukazuju na moguće nedovoljno širok raspon mjerenja deformacija primjenom KES-FB sustava za potrebe 3D simulacije.

Kod ostalih tkanina (T3 do T6), utvrđena je jaka pozitivna korelacija između koeficijenta drapiranja modela suknji simuliranih primjenom KES-FB i SEDDI Textura parametara, na obje duljine modela D1 i D2, Slika 6. S obzirom da vrijednosti plošne mase preostalih uzoraka (178,7 - 286,1 g/m²) pokrivaju širok raspon tkanih tkanina koje se uobičajeno koriste za proizvodnju različitih vrsta odjeće, utvrđeni rezultati predstavljaju značajan doprinos u smislu primjenjivosti UI tehnologije za ispitivanje mehaničkih svojstava potrebnih za 3D simulaciju i razvoj digitalnih prototipova odjeće.



Slika 6: Korelacija koeficijenata drapiranja između digitalnih 3D prototipova suknji simuliranih na temelju KES-FB i SEDDI Textura parametara (uzorci tkanine T3 do T6)

5. Zaključci

Iako je digitalizacija proizvodnih procesa jedan od značajnih pozitivnih elemenata s gledišta održivosti, implementacija i primjena suvremenih računalnih tehnologija i digitalnog prototipiranja u odjevnoj industriji još uvijek je značajno ograničena. Evaluacija digitalnih prototipova odjeće na temelju objektivnih parametara ključna je za napredak prijelaza s tradicionalnih metoda stvaranja fizičkih prototipova na održiviji pristup usmjeren na digitalni razvoj. Ovaj pomak značajno smanjuje negativan utjecaj na okoliš minimiziranjem otpada tkanine, očuvanjem resursa i smanjenjem potrošnje energije tijekom procesa dizajna i razvoja proizvoda. Stoga su studije evaluacije digi-

talnih 3D prototipova odjeće, poput istraživanja predstavljenog u ovom radu, od velike važnosti jer pružaju bolje razumijevanje i predviđanje ponašanja odjeće u odnosu na svojstva ciljane tkanine u procesu digitalnog prototipiranja. Potvrda primjenjivosti UI tehnologije za digitalizaciju uzoraka tekstilnih materijala i njezina upotreba u 3D simulaciji odjeće uvelike olakšava i ubrzava proces određivanja vrijednosti parametara u usporedbi sa standardnim metodama ispitivanja svojstava tekstilnih materijala. To ima značajan pozitivan utjecaj s ekološke perspektive, jer dovodi do znatnih ušteda energije i materijalnih resursa potrebnih za mjernu opremu, kao i sam proces ispitivanja. Pojednostavljenjem radnih procesa i uklanjanjem potrebe za opsežnom pripremom uzoraka, učinkovito se smanjuje tekstilni otpad koji nastaje zbog velikog broja mjerenja koje zahtijevaju standardne metode. Studija naglašava potencijal alata temeljenih na umjetnoj inteligenciji, kao zamjenu za tradicionalne metode vrednovanja svojstava tekstilnih materijala. Eksperimentalno je potvrđena primjenjivost UI tehnologije SEDDI Textura za procjenu mehaničkih svojstava odabranih tkanina na temelju strukturnih i vizualnih podataka, bez potrebe za klasičnim laboratorijskim mjerenjima. Prednost ove metode leži u skalabilnosti, korištenju velikih skupova podataka, multimodalnom pristupu i optimizaciji prema simulacijskim rezultatima. Buduća istraživanja trebaju obuhvatiti širi raspon tekstilnih materijala, odjevnih proizvoda i procesa dorade tekstilnih materijala, kao i analize podudarnosti sa stvarnim ponašanjem odjevnih predmeta.

ZAHVALA

Objava rada proizašla je iz provedbe institucionalnog istraživačkog projekta “Održivi razvoj odjeće dodane vrijednosti: Digitalno prototipiranje, primjena umjetne inteligencije i biomaterijala”, AI3D-BioWear, šifra projekta: TTF-IIP-02, koji financira Europska unija - NextGenerationEU.

6. Literatura

- [1] Sayem, A.S.M.: *Digital Fashion Innovations Advances in Design, Simulation, and Industry*, CRC Press, ISBN 978-1-032-20729-2, Boca Raton USA, (2023)
- [2] Gupta, D.: New directions in the field of anthropometry, sizing and clothing fit, U *Anthropometry, Apparel Sizing and Design*, Elsevier, ISBN 978-0-08-102605-2, Amsterdam The Netherlands, (2020), str. 3-27
- [3] Jevšnik, S.; Stjepanović, Z., Rudolf, A.: 3D Virtual prototyping of garments, approaches, developments and challenges, *Journal of Fibers Bioengineering and Informatics*, **10** (2017) 1, 51-63, <https://doi.org/10.3993/jfbim00253>
- [4] Mahnić Naglič, M.; Petrak, S., Tomljenović, A.: Analysis of Woven Fabric Mechanical Properties in the Context of Sustainable Clothing Development Process, *Polymers*, **17** (2025) 15, 2013, <https://doi.org/10.3390/polym17152013>

- [5] Kim, J.H.; Lee, J.S.: Investigating parameters affecting the real and virtual drapability of silk fabrics for traditional Hanbok, *Fashion and Textiles*, **11** (2024) 21, <https://doi.org/10.1186/s40691-024-00388-6>
- [6] Pandžić, S.; Pejša, T., Matković, K., Benko, H., Čereković, A., Matijašević, M.: *Virtualna okruženja: Interaktivna 3D grafika i njene primjene*, Element, ISBN 978-953-197-606-0, Zagreb Hrvatska, (2011)
- [7] Geršak, J.: *Coplex Fabric Deformations and Clothing Modelling in 3D*, LAP Lambert academic Publishing, ISBN 978-3-659-32809-1, Staarbrucken Germany, (2013)
- [8] Fabric Kit, <https://support.clo3d.com/hc/en-us/articles/360041074334-Fabric-Kit-Manual>, *Pristupljeno*: 2026-02-11
- [9] Browzwear, <https://browzwear.com/products/fabric-analyzer>, *Pristupljeno*: 2026-02-11
- [10] Optitex, <https://optitex.com/products/fabric-management/>, *Pristupljeno*: 2026-02-11
- [11] SEDDI Textura, <https://textura.ai/>, *Pristupljeno*: 2025-11-04
- [12] Wiegand, T.; Wynn, M.: Sustainability, the Circular Economy and Digitalisation in the German Textile and Clothing Industry, *Sustainability*, **15** (2023) 11, 9111, <https://doi.org/10.3390/su15119111>
- [13] Alexander, B.; Rutter, C.: Towards Transformation: Digitalization, Sustainability and Customer Experience, *Fashion Practice*, **14** (2022) 3, 319-328, <https://doi.org/10.1080/17569370.2022.2129468>
- [14] Singh, J.; Bansal, S.: The impact of the fashion industry on the climate and ecology, *World Journal of Advanced Research and Reviews*, **21** (2024) 1, 210-215, <https://doi.org/10.30574/wjarr.2024.21.1.2610>
- [15] Zekri, H.B.: Globalization and the fast fashion phenomenon: The impact upon labors, environment and the consumer behavior, *MAS Journal of Applied Sciences*, **6** (2021) 3, 651-660, <https://doi.org/10.52520/masjaps.102>
- [16] CLO Sustainability Hub, <https://www.clo3d.com/en/resources/esp>, *Pristupljeno*: 2024-10-15
- [17] Browzwear Success Stories, <https://browzwear.com/success-stories>, *Pristupljeno*: 2024-10-15
- [18] The Interline Sustainability Report 2024, <https://theinterline.com/The-Interline-Sustainability-Report-2024.pdf>, *Pristupljeno*: 2024-10-15
- [19] Akhtar, W.H.; Watanabe, C., Neittaanmäki, P.: A new perspective on the textile and apparel industry in the digital transformation era, *Textiles*, **2** (2022) 4, 633-656, <https://doi.org/10.3390/textiles2040037>
- [20] Casciani, D.; Chkanikova, O., Pal, R.: Exploring the nature of digital transformation in the fashion industry: Opportunities for supply chains, business models, and sustainability oriented innovations, *Sustainability: Science, Practice and Policy*, **18** (2022) 1, 773-795, <https://doi.org/10.1080/15487733.2022.2125640>
- [21] Arribas, V.; Alfaro, J.A.: 3D technology in fashion: From concept to consumer, *Journal of Fashion Marketing and Management*, **22** (2018) 2, 240-251, <https://doi.org/10.1108/JFMM-10-2017-0114>
- [22] Petrak, S.: Digital fashion innovation and sustainability, *Zbornik 14th International Scientific Conference on Manufacturing Engineering, Development and Modernization of Manufacturing RIM 2023*, Hodžić, A. i sur. (ur.), str. 251–266, ISSN 2566-3283, Sarajevo Bosna i Hercegovina, rujan 2023, Univerzitet u Bihaću Tehnički fakultet, Bihać, (2023)

- [23] Choi, C.: 3D dynamic fashion design development using digital technology and its potential in online platforms, *Fashion and Textiles*, **9** (2022) 9, <https://doi.org/10.1186/s40691-021-00286-1>
- [24] Ranjan, R.; Pandey, R., Kumar, V.: Integration of CAD technology for fast and customized production of apparels, *Journal of Education and Psychology*, **57** (2020) 4639–4645, <https://doi.org/10.17762/pae.v57i9.1817>
- [25] Volino, P.; Magnenat-Thalmann, N., Faure, F.: A simple approach to nonlinear tensile stiffness for accurate cloth simulation, *ACM Transactions on Graphics*, **28** (2009) 4, 1-16, <https://doi.org/10.1145/1559755.1559762>
- [26] Miguel, E.; Bradley, D., Thomaszewski, B., Bickel, B., Matusik, W., Otaduy, M.A., Marschner, S.: Data-driven estimation of cloth simulation models, *Computer Graphics Forum*, **31** (2012) 2pt2, 519-528, <https://doi.org/10.1111/j.1467-8659.2012.03031.x>
- [27] Kuijpers, S.; LuibleBär, C., Gong, H.: The Measurement of Fabric Properties for Virtual Simulation - A Critical Review, *IEEE Standards Association, Industry Connections Report*, (2020) 1-43
- [28] Maksimović, N.: Methods to digitizing physical properties of fabric for virtual simulation, *Tekstilna Industrija*, **68** (2020) 3, 36-43, <https://doi.org/10.5937/tekstind2003036M>
- [29] Youn, S.; West, A., Mathur, K.: Evaluation of a new artificial intelligence-based textile digitization using fabric drape, *Textile Research Journal*, **94** (2024) 17-18, 2001-2018, <https://doi.org/10.1177/00405175241236881>
- [30] Tu, Y.F.; Kwan, M.Y., Yick, K.L.: A systematic review of AI-driven prediction of fabric properties and handfeel, *Materials*, **17** (2024) 20, 5009, <https://doi.org/10.3390/ma17205009>
- [31] Yang, S.; Pan, Z., Amert, T., Wang, K., Yu, L., Berg, T., Lin, M.C.: Physics-inspired garment recovery from a single-view image, *ACM Transactions on Graphics*, **37** (2018) 5, 1-14, <https://doi.org/10.1145/3026479>
- [32] Bouman, K.L.; Xiao, B., Battaglia, P., Freeman, W.T.: Estimating the material properties of fabric from video, *Zbornik IEEE International Conference on Computer Vision*, , str. 1984-1991, Sydney Australija, prosinac 2013, IEEE Computer Society, (2013) <https://doi.org/10.1109/ICCV.2013.455>
- [33] Bi, W.; Jin, P., Nienborg, H., Xiao, B.: Estimating mechanical properties of cloth from videos using dense motion trajectories: Human psychophysics and machine learning, *Journal of Vision*, **18** (2018) 5, <https://doi.org/10.1167/18.5.12>
- [34] Zhang, H.; Dana, K., Nishino, K.: Friction from reflectance: Deep reflectance codes for predicting physical surface properties from oneshot in-field reflectance, *Zbornik European Conference on Computer Vision*, str. 808-824, Amsterdam Nizozemska, listopad 2016, Springer, (2016), doi 10.1007/978-3-319-46493-0_49
- [35] Rasheed, A.H.; Romero, V., Bertails-Descoubes, F., Wuhler, S., Franco, J.S., Lazarus, A.: Learning to measure the static friction coefficient in cloth contact, *Zbornik IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle SAD, srpanj 2020, IEEE Computer Society, (2020), <https://doi.org/10.1109/CVPR42600.2020.00993>

- [36] Rodriguez-Pardo, C.; Prieto-Martin, M., Casas, D., Garces, E.: How Will It Drape Like? Capturing Fabric Mechanics from Depth Images, *Computer Graphics Forum*, **2** (2023) 42, <https://doi.org/10.1111/cgf.14750>
- [37] Feng, X.; Huang, W., Xu, W., Wang, H.: Learning-Based Bending Stiffness Parameter Estimation by a Drape Tester, *ACM Transactions on Graphics*, **41** (2022) 6, 221, <https://doi.org/10.1145/3550454.3555464>
- [38] Koptelov, A.; Thompson, A., Hallett, S.R., El Said, B.: A deep learning approach for predicting the architecture of 3D textile fabrics, *Materials & Design*, **239** (2024) 112803, <https://doi.org/10.1016/j.matdes.2024.112803>
- [39] Hsu, M.K.; Chen, W., Huang, B.Y., Shen, L.H., Hsu, C.H., Chang, R.Y., Yu, C.H.: A deep learning empowered smart representative volume element method for long fiber woven composites, *Frontiers in Materials*, **10** (2023) 1179710, <https://doi.org/10.3389/fmats.2023.1179710>
- [40] Hamdi, T.; Ghith, A., Fayala, F.: A fuzzy logic method for predicting the drape behavior, *Zbornik International Conference on Engineering & MIS (ICEMIS)*, str. 1-5, svibanj 2017, Monastir Tunisia, University of Monastir and IEEE, (2017)
- [41] Lee, S.; Han, Y., Yun, C.: Development of a fabric classification system using drapability and tactile characteristics, *Fashion and Textiles*, **11** (2024) 2, <https://doi.org/10.1186/s40691-023-00368-2>
- [42] Vizoo, <https://www.vizoo3d.com/physx-platform/>, *Pristupljeno*: 2026-02-11
- [43] Digital Fabric Physics Interoperability 3DRC Innovation Sub Committee, chrome-extension://efaidnbmninnibpcjpcglefindmkaj/https://3drc.pi.tv/wp-content/uploads/2023/11/3DRC-Digital-Fabric-Physics-Interoperability-Findings_1.pdf, *Pristupljeno*: 2026-02-08
- [44] Kim, S.H.; Kim, S., Park, C.K.: Development of similarity evaluation method between virtual and actual clothing, *International Journal of Clothing Science and Technology*, **29** (2017) 5, 743-750, <https://doi.org/10.1108/IJCST-01-2017-0001>
- [45] Petrak, S.; Mahnić Naglič, M., Rogale, D., Geršak, J.: Analysis of Polygonal Computer Model Parameters and Influence on Fabric Drape Simulation, *Materials*, **14** (2021) 21, 6259, <https://doi.org/10.3390/ma14216259>
- [46] Shim, E.; Koo, D.S., An, J.S., Yoon, H.J.: Comparison of the Silhouette of Virtual Clothes by Fabric Characteristics of Nylon Fabric for the Utilization of Virtual Clothes, *ACS Omega*, **7** (2022) 47156-47164, <https://doi.org/10.1021/acsomega.2c06302>
- [47] HRN EN ISO 7211-2:2024; Tekstil – Metode analiza strukturnih parametara tkanina - 2. dio: Određivanje broja niti na jedinici duljine (ISO 7211-2:2024 ; EN ISO 7211-2:2024)
- [48] HRN ISO 3801:2003; Tekstil – Tkanine - Određivanje mase po jedinici duljine i mase po jedinici površine; (ISO 3801:1977)
- [49] HRN ISO 5084:2003; Tekstil - Određivanje debljine tekstila i tekstilnih proizvoda; (ISO 5084:1996; EN ISO 5084:1996)
- [50] Clo3D Software, <https://www.clo3d.com/en/>, *Pristupljeno*: 2025-05-11
- [51] Cusick, G.E.: 21—The Measurement of Fabric Drape, *Journal of Textile Institute*, **59** (1968) 253–260
- [52] Robson, D.; Long, C.C.: Drape analysis using Imaging Techniques, *Clothing and Textile Research Journal*, **18** (2000) 1, 1-8, <https://doi.org/10.1177/0887302X0001800101>

Autorski indeks

Bačić, M. 29

Bebek, N. 165

Bolf, N. 143

Bolanča, Z. 47

Bolanča Mirković, I. 47

Cviljušac, V. 89

Čarapina, M. 67

Ćurković, L. 259

Degiuli, N. 229

Divjak, A. 89

Galić, I. 193

Grlj, C. G. 229

Grobenski, P. 259

Habijan, M. 193

Hofman, D. 107

Imamagić, S. 275

Jurinjak Tušek, A. 165

Kovačević, M. S. 29

Krvavica, N. 9

- Kurtanjek, Ž. 185
- Lerga, J. 9
- Lisjak, D. 211
- Mahnić Naglič, M. 291
- Martić, I. 229
- Matijević, B. 211
- Mihel, A. M. 9
- Modrić, D. 89
- Mornar, V. 1
- Penava, Ž. 275
- Perčić, M. 243
- Petrak, S. 291
- Picek, S. 125
- Rolich, T. 275
- Šalić, A. 165
- Ujević Andrijić, Ž. 143
- Valčić, M. 229
- Vičević, R. 165
- Zelenika, S. 243
- Zelić, B. 5, 165
- Žagar, M. 107
- Žiljak Gršić, J. 67, 89
- Žmak, I. 259

