

doktorat-tea.pdf

 Singidunum University

Document Details

Submission ID

trn:oid:::3117:634314511

Submission Date

Oct 5, 2026, 8:26 AM GMT+2

Download Date

Oct 20, 2026, 3:03 PM GMT+2

File Name

doktorat-tea.pdf

File Size

11.0 MB

123 Pages

33,397 Words

205,037 Characters

18% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

Filtered from the Report

- Bibliography
- Quoted Text
- Cited Text

Top Sources

- 8%  Internet sources
- 17%  Publications
- 0%  Submitted works (Student Papers)

Integrity Flags

1 Integrity Flag for Review

-  **Replaced Characters**
52 suspect characters on 5 pages
Letters are swapped with similar characters from another alphabet.

Our system's algorithms look deeply at a document for any inconsistencies that would set it apart from a normal submission. If we notice something strange, we flag it for you to review.

A Flag is not necessarily an indicator of a problem. However, we'd recommend you focus your attention there for further review.

Top Sources

8%  Internet sources
17%  Publications
0%  Submitted works (Student Papers)

Top Sources

The sources with the highest number of matches within the submission. Overlapping sources will not be displayed.

1	Publication	Tea Dogandzic, Miodrag Zivkovic, Luka Jovanovic, Jasmina Perisic et al. "Classifyin...	9%
2	Publication	Tea Dogandzic, Nebojsa Bacanin, Srdjan Vukmirovic, Aleksandar Selakov et al. "T...	1%
3	Internet	www.mdpi.com	1%
4	Publication	Ana Toskovic, Stanislava Kozakijevic, Luka Jovanovic, Miodrag Zivkovic, Nebojsa B...	<1%
5	Publication	Nebojsa Bacanin, Aleksandar Petrovic, Luka Jovanovic, Miodrag Zivkovic, Tamara ...	<1%
6	Publication	Aleksandar Petrovic, Robertas Damaševičius, Luka Jovanovic, Ana Toskovic et al. "...	<1%
7	Publication	"Information Systems for Intelligent Systems", Springer Science and Business Me...	<1%
8	Publication	Safet Purkovic, Luka Jovanovic, Miodrag Zivkovic, Milos Antonijevic et al. "Audio a...	<1%
9	Publication	Nebojsa Bacanin, Miodrag Zivkovic, Milica Djuric Jovicic, Milos Antonijevic et al. "T...	<1%
10	Internet	arxiv.org	<1%
11	Internet	nardus.mpn.gov.rs	<1%

12	Internet	www.preprints.org	<1%
13	Publication	Miodrag Zivkovic, Luka Jovanovic, Vladimir Jocovic, Bosko Nikolic et al. "Addressin...	<1%
14	Internet	www.ijprems.com	<1%
15	Publication	"Proceedings of International Conference on Paradigms of Communication, Com...	<1%
16	Internet	www.singipedia.singidunum.ac.rs	<1%
17	Internet	hrcak.srce.hr	<1%
18	Publication	Aleksandar Jokic, Miodrag Zivkovic, Luka Jovanovic, Milos Mravik et al. "A convolu...	<1%
19	Publication	Vladimir Markovic, Luka Jovanovic, Miodrag Zivkovic, Branislav Radomirovic et al....	<1%
20	Internet	peerj.com	<1%
21	Publication	Čarapić, Marija R.. "Razvoj Hromatografskih Metoda za Određivanje Sadržaja, Ste...	<1%
22	Internet	patents.google.com	<1%
23	Internet	journals.uran.ua	<1%
24	Internet	scholar.archive.org	<1%
25	Internet	www.zoores.ac.cn	<1%

26	Publication	Gojić, Gorana. "Metodologija određivanja robusnosti metoda dubokog mašinskog...	<1%
27	Publication	Jacob Levman, Emi Takahashi. "Multivariate analyses applied to fetal, neonatal a...	<1%
28	Internet	doaj.org	<1%
29	Internet	link.springer.com	<1%
30	Internet	repository.e-ssbm.com	<1%
31	Internet	www.ru-birds.ru	<1%
32	Publication	Radonjić, Aleksandar N.. "Prilog Istraživanju Analitičkih Metoda za Proračun Tehn...	<1%
33	Internet	ejurnal.untan.ac.id	<1%
34	Internet	fedorabg.bg.ac.rs	<1%
35	Internet	jurcon.ums.edu.my	<1%
36	Internet	revistas.tec.ac.cr	<1%
37	Publication	Guangmao Li. "Fault Diagnosis of Automotive Transmission Bearings Based on a ...	<1%
38	Internet	www.cs.tut.fi	<1%
39	Internet	www.ijmmm.org	<1%

40	Publication	Lukić, Nikola. "Adaptivno Spajanje Delova u Tehnologiji Robotizovane Montaže Pr...	<1%
41	Internet	dokumen.pub	<1%
42	Internet	www.nature.com	<1%
43	Internet	www.osaka-kyoiku.ac.jp	<1%
44	Publication	Hiranya Jeet Malla, Milad Bazli, Mehrdad Arashpour. "Prompt-stable knowledge d...	<1%
45	Publication	Luka Anicin, Svetlana Andjelic, Marija Markovic Blagojevic, Dejan Bulaja et al. "Me...	<1%
46	Publication	Pesic, Sasa. "An Advanced Resource Management and Indoor Positioning Edge Co...	<1%
47	Internet	demostore.ijisrt.com	<1%
48	Internet	www.ppf.edu.rs	<1%
49	Internet	ijsrem.com	<1%
50	Internet	rsisinternational.org	<1%
51	Internet	www.biodiversity-science.net	<1%
52	Internet	www.cris.uns.ac.rs	<1%
53	Publication	Dong, Jiahong. "Estimating Genotype-Tissue Specific Gene Expression via Promot...	<1%

54	Publication	Nebojsa Bacanin, Vladimir Simic, Miodrag Zivkovic, Melfi Alrasheedi, Aleksandar ...	<1%
55	Publication	Soner Çelikdemir, Aynur Egel, Dursun Öztrük. "A Proposed Metaheuristic Propo...	<1%
56	Internet	becejski-mozaik.co.rs	<1%
57	Internet	bil.eecs.yorku.ca	<1%
58	Internet	cp-srb.com	<1%
59	Internet	dspace.uevora.pt	<1%
60	Internet	gmd.copernicus.org	<1%
61	Internet	mdpi-res.com	<1%
62	Internet	repozitorij.unios.hr	<1%
63	Internet	tel.archives-ouvertes.fr	<1%
64	Internet	www.aimspress.com	<1%
65	Internet	www.ijmems.in	<1%
66	Publication	Bajić, Vojana. "Модел За Рано Откривање Неусаглашености Процесних Пара...	<1%
67	Publication	Gvoic, Vesna. "Ispitivanje mogucnosti primene Fenton-procesa u tretmanu oboje...	<1%

68	Internet	blog.csdn.net	<1%
69	Internet	core.ac.uk	<1%
70	Internet	deepai.org	<1%
71	Internet	eijmhs.com	<1%
72	Internet	fedorani.ni.ac.rs	<1%
73	Internet	symopis2021.matf.bg.ac.rs	<1%
74	Internet	theses.hal.science	<1%
75	Internet	www.itu.dk	<1%
76	Internet	www.kombeg.org.rs	<1%
77	Publication	Farnaz Hoseini, Masume Kheyri, Milad Ahmadi-Gharehtoragh, Shohreh Shamlou. ...	<1%
78	Publication	Knezevic, Ivan. "Analiza dinamickog ponasanja kuglicnih lezaja Primenom vestac...	<1%
79	Publication	Petrović-Bulatović, Katarina. "Razvoj visoko automatizovanih mikrotitarskih testo...	<1%
80	Publication	Duraskovic, Jasmina. "Unapredenje modela efektivnog komuniciranja elektronsk...	<1%
81	Publication	Geoffrey E. Hinton, Simon Osindero, Yee-Whye Teh. "A Fast Learning Algorithm fo...	<1%



69

Univerzitet Singidunum
Departman za poslediplomske studije

Doktorska disertacija

**Unapređenje optimizacije neuronskih mreža
korišćenjem modifikovanih metaheuristika: primene
na analizu audio i vremenskih serija**

Tea Dogandžić

Beograd, 2026.



Univerzitet Singidunum
Departman za poslediplomske studije

Doktorski akademski program
Inteligentno softversko inženjerstvo

Doktorska disertacija
Unapređenje optimizacije neuronskih mreža
korišćenjem modifikovanih metaheuristika: primene
na analizu audio i vremenskih serija

Mentor:
prof. dr Miodrag Živković

Student:
Tea Dogandžić, 480170/2022

Beograd, 2026. godine

Apstrakt

Automatska klasifikacija složenih signalnih podataka, zova ptica u bioakustičkom nadzoru biodiverziteta i EEG zapisa u neurodijagnostici, predstavlja izazovan zadatak zbog visoke dimenzionalnosti, prisustva šuma i neuravnoteženosti po klasama, što otežava pouzdano izdvajanje obeležja i preciznu klasifikaciju, dok tradicionalne metode ostaju spore i podložne subjektivnoj proceni. Postojeći pristupi zasnovani na konvolucionim i rekurentnim neuronskim mrežama zavise od iscrpnog podešavanja hiperparametara, što predstavlja NP-težak problem, dok standardne metaheuristike imaju ograničenja. Algoritam pretrage promenljivog susedstva (VNS) gubi sposobnost eksploatacije u kasnijim iteracijama, dok optimizacija rojem čestica (PSO) pati od prevremene konvergencije usled gubitka raznovrsnosti populacije, što ograničava pouzdanost na neuravnoteženim podacima. U ovoj disertaciji predlažu se dva okvira zasnovana na dubokom učenju, optimizovana modifikovanim metaheurističkim algoritmima. Prvi okvir je dvoslojni hibridni model koji kombinuje CNN kao ekstraktor obeležja sa CatBoost i LightGBM klasifikatorima, za klasifikaciju zova šest vrsta južnoameričkih ptica, čiji se hiperparametri podešavaju modifikovanim IAVNS algoritmom, koji integriše Firefly pretragu, čiji se udeo postepeno povećava tokom iteracija u odnosu na VNS pretragu. Drugi okvir je GRU model za detekciju anomalija i epileptičnih napada u EEG signalima, čiji se hiperparametri podešavaju modifikovanim DADPSO algoritmom, koji dinamički kontroliše raznovrsnost populacije putem L_1 norme, obezbeđujući ravnotežu eksploracije i eksploatacije bez dodatnog opterećenja. Metodologija za prvi okvir obuhvata izdvajanje MFCC obeležja iz audio zapisa i analizu objašnjivosti modela primenom SHAP metode, dok se za oba okvira sprovodi definisanje prostora pretrage hiperparametara i poređenje sa savremenim metaheuristikama kroz 30 (CNN, GRU) odnosno 15 (CatBoost, LightGBM) nezavisnih izvršavanja, kao i statistička validacija Shapiro-Wilk i Wilcoxon testovima. Predloženi CNN-LightGBM model, optimizovan IAVNS algoritmom, ostvario je tačnost klasifikacije od 76,5% (MCC 0,722) za šest vrsta ptica, dok je GRU model, optimizovan DADPSO algoritmom, postigao gotovo savršenu binarnu detekciju anomalija u EEG signalima (MCC do 0,995) i visoku tačnost prepoznavanja napada u troklasnom scenariju, uz statistički značajnu superiornost u odnosu na većinu poređenih algoritama u oba istraživanja.

Ključne reči: Duboko učenje, Metaheuristička optimizacija, Klasifikacija signala, Bioakustika, EEG analiza

Abstract

Automated classification of complex signal data, bird calls for bioacoustic biodiversity monitoring and EEG recordings for neurodiagnostics, is challenging due to high dimensionality, noise, and class imbalance, complicating feature extraction and classification, while traditional methods remain slow and prone to subjective assessment. Existing approaches based on convolutional and recurrent neural networks depend on exhaustive hyperparameter tuning, an NP-hard problem, while standard metaheuristics have limitations. Variable neighborhood search (VNS) loses exploitation capability in later iterations, whereas particle swarm optimization (PSO) suffers from premature convergence caused by declining population diversity, limiting reliability on imbalanced data. This dissertation proposes two deep learning based frameworks, optimized using modified metaheuristic algorithms. The first framework is a two-tier hybrid model combining a CNN feature extractor with CatBoost and LightGBM classifiers to classify the calls of six South American bird species, tuned using the modified IAVNS algorithm, which integrates a firefly search whose share gradually increases across iterations relative to VNS. The second framework is a GRU model for detecting anomalies and epileptic seizures in EEG signals, tuned using the modified DADPSO algorithm, which dynamically controls population diversity via the L_1 norm, balancing exploration and exploitation without additional overhead. The first framework's methodology includes MFCC feature extraction and SHAP explainability analysis, while both frameworks involve defining the hyperparameter search space, comparison with state-of-the-art metaheuristics across 30 (CNN, GRU) or 15 (CatBoost, LightGBM) independent runs, and statistical validation using Shapiro-Wilk and Wilcoxon tests. The proposed CNN-LightGBM model, optimized with the IAVNS algorithm, achieved a classification accuracy of 76.5% (MCC 0.722) for six bird species, while the GRU model, optimized with the DADPSO algorithm, achieved near-perfect binary anomaly detection in EEG signals (MCC up to 0.995) and high seizure-recognition accuracy in the three-class scenario, with statistically significant superiority over most algorithms in both studies.

Keywords: Deep learning, Metaheuristic optimization, Signal classification, Bioacoustics, EEG analysis

Sadržaj

16

11

1. UVOD	5
1.1. Metodološko-hipotetički okviri istraživanja	5
1.1.1. Problem istraživanja	6
1.1.2. Ciljevi i zadaci istraživanja	6
1.1.3. Hipoteze u istraživanju	7
1.1.4. Metode istraživanja	8
1.1.5. Naučna i društvena opravdanost istraživanja	8
1.2. Struktura rada	8
2. OPIS NAUČNE OBLASTI	10
2.1. Digitalna obrada signala i izdvajanje obeležja iz audio zapisa	10
2.2. Veštačke neuronske mreže i duboko učenje	11
2.3. Konvolucione neuronske mreže	12
2.4. Rekurentne neuronske mreže i GRU arhitektura	14
2.5. Ansambl učenje i algoritmi pojačavanja gradijenta	16
2.6. Metaheuristička optimizacija: teorijski okvir	19
2.7. Pregled metaheurističkih algoritama primenjenih u istraživanju	22
2.7.1. Algoritam pretrage promenljivog susedstva	22
2.7.2. Optimizacija rojem čestica	23
2.7.3. Pregled ostalih algoritama	25
2.8. Bioakustika i automatska klasifikacija vrsta ptica na osnovu zova	26
2.9. Elektroencefalografija i neurodijagnostika epilepsije	27
2.10. Metrike za evaluaciju klasifikacionih modela	28
2.11. Statistička validacija rezultata stohastičkih optimizacionih algoritama	29
2.12. Objašnjivost modela veštačke inteligencije	30
3. PREGLED POSTOJEĆIH ISTRAŽIVANJA	31
3.1. Istraživanja u oblasti bioakustičke klasifikacije i obrade audio signala	32
3.2. Istraživanja u oblasti EEG analize i neurodijagnostike epilepsije	35
3.3. Istraživanja u oblasti primene metaheurističke optimizacije na modele dubokog učenja	36

3.4.	Kritički osvrt na postojeća istraživanja	38
4.	METODOLOGIJA NAUČNOG DOPRINOSA RADA	39
4.1.	Predloženi dvoslojni hibridni okvir za klasifikaciju zova ptica	39
4.2.	Modifikovani algoritam pretrage promenljivog susedstva (IAVNS)	40
4.3.	Predloženi GRU okvir za detekciju anomalija u EEG signalima	42
4.4.	Modifikovani algoritam optimizacije rojem čestica svestan raznovrsnosti populacije (DADPSO)	43
5.	METODOLOGIJA ISTRAŽIVANJA	45
5.1.	Eksperimentalna provera okvira za klasifikaciju vrsta ptica	45
5.1.1.	Opis skupa podataka i priprema podataka	45
5.1.2.	Eksperimentalno okruženje i podešavanje hiperparametara	46
5.1.3.	Rezultati simulacije CNN-a prvog sloja	48
5.1.4.	Rezultati simulacije CatBoost algoritma drugog sloja	57
5.1.5.	Rezultati simulacije LightGBM algoritma drugog sloja	65
5.1.6.	Analiza performansi	73
5.1.7.	Statistička validacija rezultata	74
5.1.8.	Interpretacija najboljeg modela	76
5.2.	Eksperimentalna provera GRU modela za detekciju EEG anomalija	78
5.2.1.	Opis skupa podataka i priprema podataka	78
5.2.2.	Eksperimentalno okruženje	81
5.2.3.	Rezultati prvog eksperimenta	82
5.2.4.	Rezultati drugog eksperimenta	85
5.2.5.	Rezultati trećeg eksperimenta	89
5.2.6.	Diskusija rezultata	93
5.2.7.	Statistička validacija rezultata	100
6.	ZAKLJUČAK	103
6.1.	Kritički osvrt na urađeno istraživanje	103
6.2.	Pravci budućih istraživanja	104
	LITERATURA	105
	POPIS AKRONIMA	113
	PRILOZI	116

1. Uvod

Poslednjih godina, veštačka inteligencija je postala nezaobilazan alat u analizi kompleksnih vremenskih i audio signala, pri čemu duboko učenje omogućava automatsko izdvajanje obeležja iz podataka koji su tradicionalno zahtevali stručnu, ručnu interpretaciju. Dve oblasti u kojima ovaj pristup dobija sve veći značaj jesu bioakustički nadzor biodiverziteta i neurodijagnostika. Prepoznavanje vrsta ptica na osnovu njihovog zova omogućava neinvazivno praćenje ekosistema i blagovremeno uočavanje promena u populacijama, dok analiza elektroencefalografskih (EEG) signala predstavlja ključni dijagnostički postupak u otkrivanju epilepsije i drugih neuroloških poremećaja. U oba slučaja, podaci su visoko dimenzionalni, često zašumljeni i neuravnoteženi po klasama, što otežava primenu klasičnih metoda klasifikacije i zahteva primenu naprednih arhitektura dubokog učenja.

Modeli dubokog učenja, poput konvolucionih neuronskih mreža (*Convolutional Neural Network, CNN*) i GRU (*Gated Recurrent Unit*) mreža, pokazuju izuzetnu sposobnost učenja složenih obrazaca u podacima. Konvolucione mreže uče kroz hijerarhijsko izdvajanje prostornih obeležja, a GRU mreže kroz modelovanje vremenskih zavisnosti u sekvencijalnim podacima, ali njihova efikasnost u velikoj meri zavisi od pravilnog izbora hiperparametara. Podešavanje hiperparametara predstavlja NP-težak optimizacioni problem, usled čega se u poslednje vreme sve više koriste metaheuristički algoritmi, poput algoritma pretrage promenljivog susedstva (*Variable Neighborhood Search, VNS*) i optimizacije rojem čestica (*Particle Swarm Optimization, PSO*). Iako ovi algoritmi poseduju snažne osobine u pogledu istraživanja prostora rešenja, brojna istraživanja ukazuju na njihova ograničenja u kasnijim fazama optimizacije, kada je neophodna intenzivnija eksploatacija već pronađenih dobrih rešenja. Ova disertacija se bavi upravo prevazilaženjem navedenih ograničenja, kroz predlaganje modifikovanih metaheurističkih algoritama i njihovu primenu na dva različita, ali metodološki srodna problema: klasifikaciju zova šest vrsta južnoameričkih ptica i detekciju anomalija i epileptičnih napada u EEG signalima.

Ova disertacija u velikoj meri zasnovana je na dva rada autorke (Dogandzic, Bacanin, et al., 2026; Dogandzic, Zivkovic, et al., 2026), čiji su teorijski okvir, metodologija i rezultati integrisani, prilagođeni i prošireni kroz ceo tekst disertacije.

U nastavku uvodnog poglavlja predstavljen je metodološko-hipotetički okvir istraživanja, u okviru kog se definišu predmet, ciljevi, hipoteze, metode, kao i naučna i društvena opravdanost sprovedenog istraživanja. Takođe, u posebnom potpoglavlju je navedena i struktura rada, gde su detaljno objašnjena poglavlja ove disertacije.

1.1. Metodološko-hipotetički okviri istraživanja

Istraživanje sprovedeno u ovoj disertaciji polazi od nekoliko istraživačkih pitanja:

1. Da li se tačnost klasifikacije zova ptica može značajno unaprediti zamenom završnog, potpuno povezanog sloja konvolucione neuronske mreže klasifikatorima zasnovanim na pojačavanju gradijenta?

2. Da li modifikovani metaheuristički algoritam, koji kombinuje mehanizme VNS algoritma i FA algoritma (*Firefly Algorithm*), obezbeđuje bolje i stabilnije podešavanje hiperparametara u odnosu na standardne metaheuristike?
3. Da li se GRU mreže mogu pouzdano primeniti za detekciju anomalne moždane aktivnosti u EEG signalima?
4. Da li modifikovani PSO algoritam, koji dinamički kontroliše raznovrsnost populacije, prevazilazi poznato ograničenje baznog algoritma, odnosno prevremenu konvergenciju usled gubitka raznovrsnosti populacije?

Na osnovu ovih pitanja formulisane su hipoteze istraživanja, koje su predstavljene u nastavku ovog poglavlja, zajedno sa predmetom, ciljevima i metodama istraživanja.

1.1.1. Problem istraživanja

Predmet istraživanja jeste razvoj, implementacija i eksperimentalna evaluacija hibridnih modela dubokog učenja, čiji su hiperparametri optimizovani modifikovanim metaheurističkim algoritmima, u kontekstu klasifikacije kompleksnih signalnih podataka. Istraživanje obuhvata dve konkretne primene. Prva se odnosi na automatsku klasifikaciju zova šest vrsta ptica koje nastanjuju isto stanište u Južnoj Americi, primenom dvoslojnog okvira koji kombinuje konvolucionu neuronsku mrežu i klasifikatore zasnovane na pojačavanju gradijenta (CatBoost i LightGBM), dok se druga odnosi na detekciju anomalija i epileptičnih napada u EEG signalima primenom GRU mreže. U oba slučaja, poseban predmet istraživanja predstavlja projektovanje modifikovanih metaheurističkih algoritama, iteraciono svesnog VNS algoritma (*Iteration Aware VNS*, IAVNS) i dinamički prilagodljivog PSO algoritma svesnog raznovrsnosti populacije (*Diversity Aware Dynamic PSO*, DADPSO), namenjenih efikasnijem podešavanju hiperparametara pomenutih modela.

1.1.2. Ciljevi i zadaci istraživanja

Naučni cilj istraživanja jeste naučno objašnjenje uticaja modifikovanih metaheurističkih algoritama na performanse i stabilnost hibridnih modela dubokog učenja, kao i naučno predviđanje ponašanja ovih algoritama u zavisnosti od stepena neuravnoteženosti podataka po klasama i broja klasa u klasifikacionom problemu.

Društveni cilj istraživanja ogleda se u konkretnom doprinosu razvoju alata za neinvazivno, automatizovano praćenje biodiverziteta, kao osnove za očuvanje ekosistema, kao i alata za podršku kliničkom skriningu epilepsije, koji bi mogao da olakša i ubrza rad neurologa prilikom analize dugotrajnih EEG zapisa.

Zadaci istraživanja obuhvataju sledeće:

1. Pregled i sistematizaciju relevantne literature iz oblasti dubokog učenja, bioakustike, neurodijagnostike i metaheurističke optimizacije.

2. Izdvajanje relevantnih obeležja iz audio zapisa primenom Mel-kepstralnih koeficijenata (*Mel Frequency Cepstral Coefficients*, MFCC).
3. Projektovanje i implementaciju hibridnih arhitektura dubokog učenja.
4. Razvoj i implementaciju modifikovanih metaheurističkih algoritama IAVNS i DADPSO.
5. Sprovođenje komparativne eksperimentalne analize u odnosu na više savremenih metaheurističkih algoritama.
6. Statističku validaciju dobijenih rezultata.
7. Analizu objašnjivosti najuspešnijeg modela za klasifikaciju zova ptica primenom SHAP metode.

1.1.3. Hipoteze u istraživanju

Na osnovu definisanog problema i ciljeva istraživanja, formulisane su sledeće hipoteze.

H1: Zamena završnog, potpuno povezanog sloja konvolucione neuronske mreže klasifikatorima zasnovanim na pojačavanju gradijenta statistički značajno poboljšava tačnost klasifikacije zova ptica u odnosu na samostalni CNN model.

H2: Modifikovani IAVNS algoritam, koji kombinuje mehanizme promenljivog susedstva i FA pretrage, ostvaruje statistički značajno bolje rezultate prilikom podešavanja hiperparametara u odnosu na baznu verziju VNS algoritma i druge metaheurističke algoritme korišćene u eksperimentalnom poređenju za klasifikaciju zova ptica (GA, PSO, COA, ChOA, SCHO i COLSHADE).

H3: GRU neuronska mreža, čiji su hiperparametri optimizovani metaheurističkim algoritmom, može sa visokom pouzdanošću da razlikuje normalnu od anomalne moždane aktivnosti na osnovu EEG vremenskih serija.

H4: Modifikovani DADPSO algoritam, koji dinamički reguliše raznovrsnost populacije na osnovu L_1 norme, ostvaruje statistički značajno bolje rezultate u pogledu stabilnosti konvergencije i kvaliteta pronađenih rešenja u odnosu na standardnu verziju PSO algoritma i druge metaheurističke algoritme korišćene u eksperimentalnom poređenju za detekciju anomalija u EEG signalima (VNS, GA, FA, BSO, RSA, SASS i COLSHADE), naročito u zadacima sa podacima neuravnoteženim po klasama.

H5: Efikasnost DADPSO algoritma opada sa porastom složenosti klasifikacionog problema u zadatku detekcije anomalija u EEG signalima, odnosno prelaskom sa binarne (Eksperimenti 1 i 2) na troklasnu klasifikaciju (Eksperiment 3), što ukazuje na ograničenja generalizacije postignutih poboljšanja.

1.1.4. Metode istraživanja

U izradi disertacije primenjene su osnovne metode analize i sinteze, koje su korišćene prilikom pregleda i sistematizacije literature iz oblasti dubokog učenja i metaheurističke optimizacije. Od opštenaučnih metoda, primenjena je hipotetičko-deduktivna metoda, kroz formulisanje istraživačkih hipoteza koje su potom proverene eksperimentalnim putem, zatim komparativna metoda, primenjena prilikom poređenja predloženih modifikovanih algoritama sa više savremenih metaheurističkih algoritama (VNS, PSO, GA, FA i drugi), kao i statistička metoda, primenjena kroz analizu deskriptivnih pokazatelja (srednja vrednost, medijana, standardna devijacija) i kroz testove statističke značajnosti (Shapiro-Wilk test normalnosti i Wilcoxon signed-rank test).

U pogledu metoda i tehnika prikupljanja podataka, korišćena je analiza sadržaja sekundarnih izvora, odnosno javno dostupnih skupova podataka (audio zapisi zova ptica i EEG vremenske serije), zatim eksperimentalna metoda, sprovedena kroz simulacije treniranja i optimizacije modela u više nezavisnih izvršavanja, kao i kvantitativne metode obrade podataka, primenjene prilikom statističke obrade dobijenih rezultata i izrade uporednih tabela i grafičkih prikaza.

1.1.5. Naučna i društvena opravdanost istraživanja

Naučna opravdanost istraživanja proizilazi iz uočenog nedostatka u dosadašnjoj literaturi, u kojoj je kombinacija MFCC obeležja, konvolucionih neuronskih mreža i metaheurističke optimizacije retko primenjivana u oblasti bioakustičke klasifikacije, dok je primena GRU mreža optimizovanih metaheurističkim algoritmima u analizi EEG signala takođe nedovoljno istražena. Predloženi modifikovani algoritmi, IAVNS i DADPSO, predstavljaju originalan naučni doprinos u domenu metaheurističke optimizacije, budući da uvode mehanizme koji eksplicitno regulišu odnos između eksploracije i eksploatacije prostora rešenja tokom izvršavanja algoritma, bez dodatnog računskog opterećenja.

Društvena opravdanost istraživanja ogleda se u praktičnoj primenljivosti dobijenih rezultata. Automatizovana klasifikacija zova ptica doprinosi razvoju neinvazivnih alata za praćenje biodiverziteta i ranu identifikaciju promena u ekosistemu, dok predloženi model za detekciju anomalija u EEG signalima ima potencijal da posluži kao alat za podršku prioritizaciji i skriningu prilikom analize dugotrajnih EEG zapisa, čime bi se rasteretio rad neurologa i ubrzalo otkrivanje kliničkih odstupanja. Na ovaj način, istraživanje sprovedeno u ovoj disertaciji povezuje naučni doprinos u oblasti veštačke inteligencije sa konkretnom društvenom korišću u oblasti zaštite životne sredine i zdravstvene zaštite.

1.2. Struktura rada

Disertacija je organizovana u šest poglavlja, praćenih spiskom literature, popisom akronima i priložima.

U prvom poglavlju, Uvod, ukratko je predstavljena problematika kojom se rad bavi, odnosno automatska klasifikacija zova ptica i detekcija anomalija u EEG signalima primenom modela dubokog učenja optimizovanih modifikovanim metaheurističkim algoritmima. Pored

11 uvodnog dela, u okviru istog poglavlja definisan je metodološko-hipotetički okvir istraživanja, u kome su navedeni predmet, ciljevi i zadaci, hipoteze, metode istraživanja, kao i naučna i društvena opravdanost sprovedenog istraživanja.

Drugo poglavlje, Opis naučne oblasti, posvećeno je teorijskim osnovama na kojima počiva istraživanje. U ovom poglavlju objašnjeni su osnovni pojmovi iz oblasti obrade signala, izdvajanja MFCC obeležja, konvolucionih i rekurentnih neuronskih mreža, ansambl klasifikatora zasnovanih na pojačavanju gradijenta (CatBoost i LightGBM), kao i teorijske osnove metaheurističkih algoritama, uključujući VNS, PSO i FA pretragu, sa posebnim osvrtom na NP-težak karakter problema podešavanja hiperparametara, teoremu o nepostojanju besplatnog ručka i koncept ravnoteže između eksploracije i eksploatacije prostora rešenja. Pored toga, u ovom poglavlju predstavljene su i teorijske osnove bioakustike i automatske klasifikacije vrsta ptica, elektroencefalografije i neurodijagnostike epilepsije, kao i teorijske osnove objašnjive veštačke inteligencije (SHAP metoda), čija je praktična primena u ovoj disertaciji ograničena na model za klasifikaciju zova ptica, kao što je detaljnije opisano u petom poglavlju. Takođe su objašnjene metrike korišćene za evaluaciju modela (MCC) i postupci statističke validacije rezultata (Shapiro-Wilk i Wilcoxon testovi).

Treće poglavlje, Pregled postojećih istraživanja, sadrži analizu relevantnih naučnih radova iz oblasti bioakustičke klasifikacije vrsta, automatske analize EEG signala i primene metaheurističke optimizacije za podešavanje hiperparametara modela dubokog učenja. Na osnovu sprovedenog pregleda, na kraju poglavlja kritički se sagledavaju ograničenja postojećih pristupa, čime se opravdava potreba za istraživanjem sprovedenim u ovoj disertaciji.

Četvrto poglavlje, Metodologija naučnog doprinosa rada, fokusira se na originalan doprinos rada. U ovom poglavlju detaljno su opisana dva predložena hibridna okvira, dvoslojni model koji kombinuje konvolucionu neuronsku mrežu sa CatBoost i LightGBM klasifikatorima za klasifikaciju zova ptica, i GRU model za detekciju anomalija u EEG signalima, kao i dva modifikovana metaheuristička algoritma razvijena u okviru istraživanja, IAVNS i DADPSO, uključujući njihovu matematičku formulu i obrazloženje uvedenih modifikacija.

Peto poglavlje, Metodologija istraživanja, opisuje eksperimentalnu proveru oba predložena rešenja. Navedeni su korišćeni skupovi podataka, postupak pripreme podataka, definisani prostori pretrage hiperparametara, kao i tok sprovedenih eksperimenata za oba okvira. Dobijeni rezultati upoređeni su sa rezultatima više savremenih metaheurističkih algoritama, uz statističku validaciju značajnosti razlika Shapiro-Wilk i Wilcoxon testovima za oba istraživanja. Za okvir namenjen klasifikaciji zova ptica dodatno je sprovedena i analiza objašnjivosti najuspešnijih modela primenom SHAP metode.

Šesto poglavlje, Zaključna razmatranja, sadrži kritički osvrt na sprovedeno istraživanje, sa naglaskom na prednosti i ograničenja predloženih pristupa, i predlaže pravce budućeg istraživanja u oblasti bioakustičke klasifikacije i analize EEG signala.

76 Na kraju rada nalazi se spisak korišćene literature, popis akronima korišćenih u tekstu, kao i prilozi sa dodatnim vizuelnim materijalima koji nisu uključeni u osnovni tekst rada, radi preglednosti izlaganja.

2. Opis naučne oblasti

Ovo poglavlje predstavlja teorijski i pojmovni okvir disertacije. Cilj poglavlja je da čitaocu, pre izlaganja pregleda dosadašnjih istraživanja i sopstvenog naučnog doprinosa, pruži sistematičan uvod u ključne naučne oblasti na kojima počiva sprovedeno istraživanje. Ove oblasti obuhvataju digitalnu obradu signala, veštačke neuronske mreže i duboko učenje, ansambl metode zasnovane na pojačavanju gradijenta, metaheurističku optimizaciju, kao i domenska polja bioakustike i neurodijagnostike epilepsije, u okviru kojih su predložena rešenja eksperimentalno verifikovana. Poglavlje se zaključuje pregledom metrika za evaluaciju klasifikacionih modela, postupaka statističke validacije rezultata i metoda za objašnjivost veštačke inteligencije.

2.1. Digitalna obrada signala i izdvajanje obeležja iz audio zapisa

Digitalna obrada signala predstavlja disciplinu koja se bavi analizom, transformacijom i interpretacijom diskretnih vremenskih nizova dobijenih odmeravanjem kontinualnih fizičkih pojava, poput zvučnog pritiska ili bioelektričnih potencijala. U kontekstu automatske klasifikacije zvučnih zapisa, sirovi audio signal retko se koristi neposredno kao ulaz u model mašinskog učenja, budući da sadrži veliku količinu redundantne i perceptivno nerelevantne informacije. Zbog toga se u praksi primenjuju postupci izdvajanja obeležja (*feature extraction*), čiji je cilj da signal transformišu u kompaktniju, informativniju reprezentaciju, pogodniju za dalju klasifikaciju.

Jedna od najrasprostranjenijih tehnika izdvajanja obeležja iz audio zapisa jesu Mel-kepralni koeficijenti (Mel Frequency Cepstral Coefficients, MFCC), uvedeni u radu Dejvisa i Mermelštajna (Davis & Mermelstein, 1980), a čija je primena od tada prerasla u standard u oblasti prepoznavanja govora, muzičke analize i bioakustike (Abdul & Al-Talabani, 2022; Dhingra & others, 2019; Majeed et al., 2023). MFCC postupak oponaša nelinearnu percepciju ljudskog slušnog sistema, koji frekvencije ne razlikuje linearno, već po takozvanoj Mel skali, na kojoj su niže frekvencije percipirane sa većom rezolucijom nego više. Postupak izdvajanja MFCC obeležja sastoji se iz nekoliko uzastopnih koraka opisanih u nastavku.

Predpojačavanje (*pre-emphasis*): Ulazni audio signal se prethodno naglašava kako bi se pojačale više frekvencije i smanjio šum niskih frekvencija. Ovo se obično postiže primenom visokopropusnog filtera, opisanog jednačinom (1):

$$y(t) = x(t) - \alpha x(t - 1) \quad (1)$$

gde je $y(t)$ izlazni signal, $x(t)$ je ulazni signal, a α je *pre-emphasis* koeficijent (tipično 0,97).

Framing i Windowing: Signal se deli na preklapajuće okvire (*frames*) kako bi se zabeležile kratkotrajne varijacije. Svaki okvir se zatim prozorski oblikuje (*windowed*), najčešće koristeći Hamingov prozor, definisan u jednačini (2):

$$w(n) = 0.54 - 0.46 \cos\left(\frac{2\pi n}{N-1}\right) \quad (2)$$

gde je N dužina okvira, a n indeks uzorka.

Furijeova transformacija i spektar snage: Svaki prozorski okvir se transformiše u frekventni domen korišćenjem brze Furijeove transformacije (*Fast Fourier Transform*, FFT), proizvodeći spektar snage $P(k)$ kao što je prikazano u jednačini (3):

$$P(k) = |X(k)|^2 \quad (3)$$

gde je $X(k)$ Furijeov transformisani okvir.

Mel-skala banka filtera: Spektar snage se propušta kroz skup trougaonih filtera raspoređenih prema Mel-skali. Mel-frekventno mapiranje je dato u jednačini (4):

$$M(f) = 2595 \log_{10} \left(1 + \frac{f}{700} \right) \quad (4)$$

gde je f frekvencija u hercima, a $M(f)$ odgovarajuća Mel vrednost.

Diskretna kosinusna transformacija (*Discrete Cosine Transform*, DCT): Logaritamske energije Mel-skale se transformišu korišćenjem DCT-a da bi se generisali kepralni koeficijenti, koji formiraju MFCC-ove. Ovaj korak uklanja suvišne informacije i definisan je u jednačini (5):

$$c_i = \sum_{j=0}^{N-1} \log(S_j) \cos \left[\frac{\pi i}{N} (j + 0.5) \right] \quad (5)$$

gde su c_i kepralni koeficijenti, S_j je Mel-filtriran spektar snage, a N je broj filtera. Ovako dobijena reprezentacija ima oblik dvodimenzionalne matrice (vreme x frekvencija), analogne slici, što omogućava primenu arhitektura dubokog učenja razvijenih prvobitno za obradu slika, poput konvolucionih neuronskih mreža. Grafički prikaz opisanog postupka dat je u prilogu, radi lakšeg praćenja procesa za čitaoca koji žele vizuelni uvid u tok izdvajanja MFCC obeležja.

MFCC obeležja su se pokazala robusnim u širokom spektru primena, uključujući prepoznavanje govora u prisustvu šuma (Dhingra & others, 2019), prepoznavanje muzičkih žanrova i medicinsku dijagnostiku (Majeed et al., 2023), klasifikaciju vozila na osnovu zvuka motora (Farbod & Karthikeyan, 2023), kao i kombinovanu primenu sa konvolucionim i rekurentnim neuronskim mrežama radi poboljšanja otpornosti klasifikacionih modela na šum (Erdal Ozbek et al., 2024). Ova svestranost, uz nisku računsku složenost postupka izdvajanja, čini MFCC pogodnim izborom za predobradu bioakustičkih signala, poput zova ptica, pre njihove klasifikacije primenom dubokih neuronskih mreža.

2.2. Veštačke neuronske mreže i duboko učenje

Veštačke neuronske mreže (*artificial neural networks*) predstavljaju računске modele inspirisane strukturom i funkcionisanjem biološkog nervnog sistema, sastavljene od međusobno povezanih jedinica (neurona) organizovanih u slojeve. Svaki neuron prima ulazne vrednosti, izračunava njihovu ponderisanu sumu i primenjuje nelinearnu aktivacionu funkciju,

čime se mreži omogućava da modeluje kompleksne, nelinearne relacije između ulaznih i izlaznih podataka. Parametri mreže (*weights* i *bias*) prilagođavaju se tokom procesa obučavanja, najčešće algoritmom propagacije unazad (*backpropagation*), koji gradijent funkcije greške propagira od izlaznog ka ulaznom sloju, omogućavajući iterativno ažuriranje parametara u pravcu minimizacije greške. Vizuelni prikaz strukture veštačkog neurona, sa ulaznim signalima, ponderisanom sumom i aktivacionom funkcijom, dat je u prilogima ukoliko čitalac želi grafički da sagleda opisani proces.

Proces obučavanja mreže svodi se na iterativno prilagođavanje njenih parametara tako da se minimizuje unapred definisana funkcija gubitka (*loss function*), koja kvantifikuje razliku između predikcije mreže i stvarne, ciljne vrednosti. Minimizacija se najčešće sprovodi metodom gradijentnog spusta (*gradient descent*), u kojoj se parametri u svakoj iteraciji pomeraju u pravcu suprotnom od gradijenta funkcije gubitka. Sam gradijent, za sve parametre mreže istovremeno, efikasno se izračunava algoritmom propagacije unazad (*backpropagation*), koji, primenom pravila lanca (*chain rule*) iz diferencijalnog računa, propagira grešku sa izlaznog sloja unazad kroz mrežu, sloj po sloj, sve do ulaznog sloja. Jedan potpun prolazak kroz čitav skup podataka za obučavanje naziva se epoha (*epoch*), a podaci se po pravilu ne obrađuju odjednom, već u manjim grupama, mini-serijama (*mini-batches*), radi računске efikasnosti i stabilnijeg ažuriranja parametara.

Poseban izazov u obučavanju neuronskih mreža predstavlja prekomerno prilagođavanje (*overfitting*), pojava u kojoj mreža umesto opštih zakonitosti "pamti" specifičnosti i šum prisutan u skupu podataka za obučavanje, usled čega joj performanse na novim, do tada neviđenim podacima znatno opadaju. Radi ublažavanja ovog problema u praksi se primenjuju razne tehnike regularizacije (*regularization*), među kojima je posebno rasprostranjen *dropout*, postupak kojim se tokom svake iteracije obučavanja nasumično isključuje deo neurona iz mreže (Srivastava et al., 2014), čime se sprečava prekomerno oslanjanje na pojedinačne neurone i podstiče robusnije, distribuiranje učenje reprezentacija.

Termin duboko učenje (*deep learning*) odnosi se na primenu neuronskih mreža sa većim brojem skrivenih slojeva, čime se omogućava učenje hijerarhijskih reprezentacija podataka, od jednostavnih obrazaca nižeg reda u ranim slojevima, do apstraktnijih pojmova višeg reda u dubljim slojevima mreže (LeCun et al., 2015). Ova sposobnost automatskog, hijerarhijskog izdvajanja obeležja predstavlja suštinsku prednost dubokog učenja u odnosu na klasične pristupe mašinskog učenja, koji se u velikoj meri oslanjaju na ručno projektovana obeležja. Dve arhitekture dubokog učenja od posebnog značaja za ovo istraživanje jesu konvolucione neuronske mreže, pogodne za obradu podataka sa prostornom strukturom poput spektrograma, i rekurentne neuronske mreže, pogodne za obradu sekvencijalnih, vremenski zavisnih podataka poput EEG vremenskih serija.

2.3. Konvolucione neuronske mreže

Konvolucione neuronske mreže (*Convolutional Neural Network*, CNN) predstavljaju specijalizovanu klasu neuronskih mreža namenjenu obradi podataka sa mrežastom (*grid-like*) strukturom, poput slika ili spektrograma. Temeljni doprinos u formalizaciji ove arhitekture dali su LeCun i saradnici (LeCun et al., 1998), čiji je rad postavio osnove savremenih pristupa vizuelnom učenju obeležja, kasnije proširenih i na oblast obrade audio signala (Gu et al., 2018).

Osnovnu građevinsku jedinicu CNN arhitekture predstavlja konvolucioni sloj, u kome se preko ulaznog signala pomeraju filteri (kerneli) koji detektuju lokalne obrasce, poput ivica u slici ili karakterističnih spektralno-vremenskih obrazaca u spektrogramu, kao što je prikazano u jednačini (6). Rezultat konvolucione operacije naziva se mapa obeležja (*feature map*).

$$(f * x)(i, j) = \sum_m \sum_n x(i + m, j + n) \cdot f(m, n) \quad (6)$$

gde je f filter, x je ulazna mapa obeležja, a (i, j) označava prostorne pozicije. Nakon svakog konvolucionog sloja, po pravilu se primenjuje nelinearna aktivaciona funkcija, najčešće ReLU (*Rectified Linear Unit*), definisana u jednačini (7):

$$f(x) = \max(0, x) \quad (7)$$

koja povećava sposobnost mreže da uči složene obrasce uvođenjem nelinearnosti.

Slojevi objedinjavanja (*pooling layers*) smanjuju prostorne dimenzije mapa obeležja uz očuvanje suštinskih informacija. Najčešća operacija objedinjavanja je maksimalno objedinjavanje (*max pooling*), koje bira maksimalnu vrednost unutar određene oblasti, kao što je definisano u jednačini (8):

$$y(i, j) = \max x(m, n) \quad (8)$$

gde je $y(i, j)$ objedinjen izlaz (*pooled output*), a $x(m, n)$ predstavlja oblast koju pokriva prozor objedinjavanja (*pooling window*). Ovim procesom se smanjuje broj parametara mreže i unosi izvestan stepen invarijantnosti na male translacije ulaznog signala. Ponavljanjem naizmeničnih konvolucionih i slojeva objedinjavanja, mreža gradi hijerarhijsku reprezentaciju ulaznog signala, pri čemu se u dubljim slojevima formiraju sve apstraktnije reprezentacije.

Na kraju arhitekture, nakon ekstrakcije obeležja, po pravilu se nalazi jedan ili više potpuno povezanih (*fully connected*) slojeva, zaduženih za konačnu klasifikaciju na osnovu izdvojenih obeležja. Izlaz mreže se izračunava pomoću jednačine (9):

$$o = W \cdot a + b \quad (9)$$

gde je W matrica težina, a je aktivacija iz prethodnog sloja, a b je slobodan član (*bias term*). Vizuelni prikaz celokupnog toka CNN arhitekture, od ulaznog spektrograma preko konvolucionih, aktivacionih i *pooling* slojeva do potpuno povezanog sloja, dat je u prilogima ukoliko čitalac želi grafički da sagleda opisani proces.

Zahvaljujući ovim svojstvima, konvolucione neuronske mreže postigle su izuzetne rezultate u klasifikaciji zvukova iz okruženja (Piczak, 2015), prepoznavanju emocija u govoru (Nassif & others, 2019; Yin & others, 2019) i identifikaciji zvučnih događaja (Zhang et al., 2022), a njihova primena proširena je i na medicinsku dijagnostiku, poput klasifikacije tumora mozga na osnovu magnetne rezonance (Aljohani et al., 2024; Gómez-Guzmán et al., 2023), detekciju upada u računarske mreže (G. S. C. Kumar et al., 2024) i prepoznavanje emocija na osnovu izraza lica (Meena et al., 2024).

Uprkos snažnim performansama, CNN arhitekture zahtevaju pažljivo podešavanje značajnog broja hiperparametara, koji se generalno mogu podeliti na parametre vezane za proces obučavanja i parametre vezane za samu arhitekturu mreže. U prvu grupu spadaju stopa učenja (*learning rate*), koja određuje veličinu koraka prilikom ažuriranja parametara metodom gradijentnog spusta, broj epoha obučavanja (*epochs*), i stopa isključivanja neurona (*dropout*), kojom se reguliše intenzitet regularizacije. U drugu grupu spadaju strukturni parametri, poput broja konvolucionih slojeva (*CNN layers*), broja potpuno povezanih, gustih slojeva (*dense layers*) i broja neurona po sloju (*neurons per layer*), koji zajedno određuju kapacitet i dubinu mreže. Svaka od ovih vrednosti bira se iz unapred definisanog opsega pretrage, pri čemu izbor jedne vrednosti utiče na optimalan izbor ostalih, čineći prostor mogućih kombinacija hiperparametara ogromnim i međusobno zavisnim.

2.4. Rekurentne neuronske mreže i GRU arhitektura

Za razliku od konvolucionih mreža, koje su prilagođene podacima sa prostornom strukturom, rekurentne neuronske mreže (*Recurrent Neural Network*, RNN) namenjene su obradi sekvencijalnih podataka, kod kojih redosled i međusobna vremenska zavisnost uzoraka nose značajnu informaciju, poput tekstualnih nizova, govornih signala ili, u kontekstu ove disertacije, EEG vremenskih serija (Medsker & Jain, 1999). Osnovna ideja RNN arhitekture jeste postojanje skrivenog stanja koje se ažurira u svakom vremenskom koraku na osnovu trenutnog ulaza i prethodnog skrivenog stanja, čime mreža stiče svojevrsnu "memoriju" prethodnih koraka sekvence.

Iako teorijski elegantne, klasične RNN arhitekture u praksi su ograničene problemom iščezavajućeg ili eksplodirajućeg gradijenta (*vanishing/exploding gradient*), koji otežava učenje dugoročnih zavisnosti unutar sekvence (Pascanu et al., 2013). Ovaj problem doveo je do razvoja naprednijih, "kapijastih" (*gated*) arhitektura, među kojima su najznačajnije mreže sa dugom kratkoročnom memorijom (*Long Short-Term Memory*, LSTM) (Hochreiter & Schmidhuber, 1997) i, u kontekstu ove disertacije posebno relevantne, GRU (*Gated Recurrent Unit*) mreže. Osnovna inovacija GRU arhitekture leži u njenim kapijastim (*gating*) komponentama, koje regulišu na koji način se informacija prenosi dalje kroz sekvencu ili odbacuje, čime se ublažava problem iščezavajućeg gradijenta koji ograničava tradicionalne RNN arhitekture. Zahvaljujući ovom strukturnom mehanizmu, GRU mreže su naročito pogodne za zadatke prognoziranja nad vremenskim (temporalnim) podacima, a pokazale su se korisnim i u oblastima poput razumevanja prirodnog jezika i obrade govora, gde su uređeni nizovi podataka od suštinskog značaja.

U GRU modelu, skrivena reprezentacija u vremenskom koraku t , označena sa h_t izračunava se objedinjavanjem trenutnog ulaza X_t i skrivenog stanja iz prethodnog trenutka, h_{t-1} . Mreža svojim kapijastim mehanizmom upravlja time koliko se informacije zadržava, a koliko odbacuje prilikom obrade novih ulaza. Udeo prethodnog skrivenog stanja koji se prenosi u sadašnjost određen je kapijom ažuriranja (*update gate*) z_t , formalno izraženom jednačinom (10):

$$z_t = \sigma(W_z X_t + U_z h_{t-1} + b_z) \quad (10)$$

gde su matrice težina W_z i U_z primenjene na ulaz, odnosno na prethodno skriveno stanje, b_z predstavlja slobodan (*bias*) član, a σ je sigmoidalna funkcija koja ograničava opseg vrednosti na interval $[0, 1]$.

Naredna komponenta jeste r_t , kapija resetovanja (*reset gate*), čija je uloga da odredi u kojoj meri se prethodno skriveno stanje zanemaruje, odnosno "zaboravlja". Ovaj proces modelovan je jednačinom (11):

$$r_t = \sigma(W_r X_t + U_r h_{t-1} + b_r) \quad (11)$$

gde matrice težina W_r i U_r odgovaraju doprinosima trenutnog ulaza i prethodnog skrivenog stanja, redom, dok b_r označava odgovarajući slobodan član.

Moguća nova aktivacija data je kandidatom skrivenog stanja $\tilde{h}_t$, čije je izračunavanje pod uticajem kapije resetovanja r_t . Ova operacija izražena je jednačinom (12):

$$\tilde{h}_t = \tanh(W_h X_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (12)$$

gde matrice težina W_h i U_h odgovaraju doprinosima ulaza, odnosno *gated* skrivenog stanja. Simbol $\odot$ označava množenje elemenata po odgovarajućim pozicijama (Hadamardov proizvod), dok aktivacija hiperboličkog tangensa ($\tanh$) ograničava rezultujuće vrednosti na interval $[-1, 1]$.

Vektor h_t , koji predstavlja konačno skriveno stanje, formira se mešanjem prethodnog skrivenog stanja sa kandidatskim stanjem, pri čemu je njihov relativni uticaj regulisan kapijom ažuriranja (*update gate*) z_t :

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (13)$$

Vizuelni prikaz unutrašnje strukture GRU ćelije, sa kapijom resetovanja, kapijom ažuriranja i formiranjem konačnog skrivenog stanja, dat je u prilogima ukoliko čitalac želi grafički da sagleda opisani proces.

U odnosu na LSTM arhitekturu, GRU poseduje jednostavniju strukturu, sa manjim brojem kapija (samo kapija ažuriranja i kapija resetovanja, naspram tri kapije kod LSTM-a) i, samim tim, manjim brojem parametara koje je potrebno obučiti, što dovodi do bržeg treniranja i inferencije, uz zadržavanje sposobnosti modelovanja dugoročnih vremenskih relacija.

Zahvaljujući ovim svojstvima, GRU arhitektura, prvi put uvedena u kontekstu statističkog mašinskog prevođenja kao deo enkoder-dekoder modela (Cho et al., 2014), od tada je primenjena u širokom spektru problema modelovanja vremenskih serija i sekvencijalnih podataka. Uporedna empirijska analiza Čunga i saradnika (Chung et al., 2014) pokazala je da GRU mreže, uprkos jednostavnijoj strukturi u odnosu na LSTM, na više zadataka sekvencijalnog modelovanja ostvaruju uporedive, a ponekad i superiornije performanse, uz manju računsku i memorijsku zahtevnost. Arhitektura je potom uspešno primenjena i u drugim domenima, uključujući prognoziranje saobraćajnog toka (Fu et al., 2016), čime je potvrđena njena svestranost i pogodnost za zadatke modelovanja vremenskih fizioloških signala, poput onih razmatranih u ovoj disertaciji.

2.5. Ansambl učenje i algoritmi pojačavanja gradijenta

Ansambl učenje (*ensemble learning*) predstavlja pristup mašinskom učenju u kome se konačna predikcija formira kombinovanjem predikcija većeg broja pojedinačnih, takozvanih baznih modela (*base learners*), sa ciljem postizanja veće tačnosti, stabilnosti i otpornosti na prekomerno prilagođavanje u odnosu na bilo koji pojedinačni model. Teorijsko opravdanje za ovakav pristup leži u razlaganju greške predikcije na pristrasnost (*bias*) i varijansu (*variance*). Dok pojedinačni, slabi modeli (*weak learners*) često poseduju visoku pristrasnost ili visoku varijansu, njihovom pažljivom kombinacijom moguće je postići znatno bolji kompromis između ova dva izvora greške, nego što bi to bilo moguće postići bilo kojim pojedinačnim modelom.

U literaturi se razlikuju dve osnovne strategije ansambl učenja. Prva, agregacija *bootstrap* uzoraka (*bootstrap aggregating*, skraćeno *bagging*), podrazumeva paralelno obučavanje većeg broja modela nad različitim, nasumično uzorkovanim podskupovima podataka za obučavanje, nakon čega se njihove predikcije usrednjavaju ili se bira većinski glas, čime se prvenstveno smanjuje varijansa modela. Reprezentativan primer ovog pristupa jesu slučajne šume (*random forests*) (Breiman, 2001). Druga strategija, pojačavanje (*boosting*), za razliku od *bagginga*, gradi modele sekvencijalno, pri čemu se svaki naredni model fokusira na ispravljanje grešaka koje su prethodni modeli u ansamblu napravili, čime se prvenstveno smanjuje pristrasnost, uz istovremeno održavanje kontrolisane varijanse. Koncept je prvi formalizovan kroz algoritam AdaBoost (Freund & Schapire, 1997).

Pojačavanje gradijenta (*gradient boosting*), koje predstavlja generalizaciju osnovne ideje pojačavanja primenjenu na proizvoljnu, diferencijabilnu funkciju gubitka, formalizovao je Fridman (Friedman, 2001). Osnovna ideja sastoji se u iterativnoj izgradnji aditivnog modela, u kome se u svakoj iteraciji m postojećem ansamblu $F_{m-1}(x)$ dodaje novi bazni model $h_m(x)$, obučen tako da aproksimira negativan gradijent (takozvane *pseudo-rezidue*) funkcije gubitka L u odnosu na predikcije trenutnog ansambla. Aditivni model pojačavanja gradijenta prikazan je jednačinom (14):

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x) \quad (14)$$

pri čemu se novi bazni model $h_m(x)$ obučava da aproksimira *pseudo-rezidual* (negativan gradijent) prikazan jednačinom (15):

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F=F_{m-1}} \quad (15)$$

gde y_i predstavlja stvarnu, ciljnu vrednost za i -tu instancu, $F(x_i)$ predstavlja predikciju ansambla za tu instancu, r_{im} predstavlja *pseudo-rezidual*, odnosno negativan gradijent funkcije gubitka za i -tu instancu u m -toj iteraciji, dok v ($0 < v \leq 1$) predstavlja stopu učenja (*shrinkage*), parametar kojim se kontroliše doprinos svakog pojedinačnog novog baznog modela ukupnom ansamblu, radi sprečavanja prekomernog prilagođavanja. Iterativnim ponavljanjem ovog postupka kroz unapred definisan broj iteracija (ili do zadovoljenja kriterijuma zaustavljanja), ansambl postepeno umanjuje grešku predikcije, gradeći sve tačniji model. Vizuelni prikaz

iterativnog procesa izgradnje aditivnog modela, opisanog jednačinama (14) i (15), dat je u prilogima ukoliko čitalac želi grafički da sagleda opisani proces.

Kao bazni modeli u algoritmima pojačavanja gradijenta najčešće se koriste plitka stabla odlučivanja (*shallow decision trees*), a algoritmi CatBoost i LightGBM, korišćeni u ovoj disertaciji i detaljnije opisani u nastavku ovog potpoglavlja, predstavljaju dve savremene, visoko optimizovane implementacije ove opšte ideje, svaka sa sopstvenim inovacijama usmerenim ka poboljšanju tačnosti, brzine obučavanja i memorijske efikasnosti.

CatBoost (*Categorical Boosting*) (Prokhorenkova et al., 2018) predstavlja algoritam pojačavanja gradijenta dizajniran za efikasno rukovanje kategoričkim podacima, inkorporiranjem specijalizovanih tehnika kodiranja koje dovode do snažnih performansi na zadacima klasifikacije koji uključuju kategorička obeležja. Umesto uobičajenog kodiranja kategoričkih vrednosti na osnovu statistike izračunate nad čitavim skupom podataka, CatBoost primenjuje uređene ciljne statistike (*ordered target statistics*), kojima se svaka kategorička vrednost kodira isključivo na osnovu instanci koje joj prethode u nasumično definisanom poretku, čime se značajno smanjuje rizik od curenja informacije iz ciljne promenljive (*target leakage*). Ovaj postupak formalno je izražen jednačinom (16):

$$\text{Enc}(x_i) = \frac{\sum_{j=1}^{i-1} y_j}{i - 1 + \alpha} \quad (16)$$

gde $\text{Enc}(x_i)$ predstavlja kodiranu vrednost i -te instance, y_j predstavlja vrednost ciljne promenljive za j -tu instancu koja prethodi posmatranoj instanci u definisanom poretku, i predstavlja indeks posmatrane instance, dok α predstavlja parametar zaglađivanja (*smoothing parameter*), kojim se sprečavaju nestabilne procene u slučajevima kada je broj prethodnih instanci mali.

Pored ovog pristupa kodiranju, CatBoost gradi simetrična, uravnotežena stabla odlučivanja (*oblivious decision trees*), kod kojih se na svim čvorovima istog nivoa stabla primenjuje isti kriterijum podele, čime se smanjuje vreme predikcije i poboljšava memorijska efikasnost, uz očuvanje visokih prediktivnih performansi. Dodatno, prekomerno prilagođavanje (*overfitting*) ublažava se primenom uređene šeme pojačavanja (*ordered boosting scheme*), u kojoj se svako naredno stablo obučava nad dinamički generisanim podskupom podataka, različitim za svaku iteraciju, čime se smanjuje pristrasnost procene gradijenta. Ukupna funkcija gubitka koju CatBoost minimizuje, analogno opštoj formulaciji pojačavanja gradijenta predstavljenoj ranije u ovom potpoglavlju, ali proširena članom regularizacije, data je jednačinom (17):

$$L = \sum_{i=1}^n \ell(y_i, \hat{y}_i) + \Omega(f_k) \quad (17)$$

gde L predstavlja ukupnu funkciju gubitka, ℓ predstavlja funkciju cilja, odnosno pojedinačni gubitak izračunat između stvarne vrednosti y_i i predikcije modela $\hat{y}_i$ za i -tu instancu, dok $\Omega(f_k)$ predstavlja član regularizacije nad k -tim stablom u ansamblu, koncept sličan onom korišćenom u algoritmu XGBoost, čiji je cilj kontrola složenosti pojedinačnih stabala i dodatno sprečavanje prekomernog prilagođavanja. Vizuelni prikaz simetrične strukture *oblivious* stabla, u kojoj svi

čvorovi istog nivoa koriste isti kriterijum podele, dat je u prilogima ukoliko čitalac želi grafički da sagleda opisanu arhitekturu.

Zahvaljujući ovim mehanizmima, CatBoost je u poslednjih nekoliko godina prepoznat kao snažan klasifikator, sa uspešnim primenama u oblastima poput praćenja zagađenja vazduha (Z. Guo et al., 2023), predviđanja odliva korisnika (Rao et al., 2024) i medicinske dijagnostike, uključujući podršku dijagnostici Parkinsonove bolesti (Al-Sarem et al., 2021).

LightGBM (*Light Gradient Boosting Machine*) (Ke et al., 2017), razvijen i objavljen kao softver otvorenog koda (*open source*) od strane kompanije *Microsoft*, predstavlja okvir za pojačavanje gradijenta projektovan radi postizanja visokih performansi i efikasnosti nad velikim skupovima podataka. Njegova izražena efikasnost u najvećoj meri proizilazi iz dve tehnike. Prva, jednostrano gradijentno uzorkovanje (*Gradient-based One-Side Sampling*, *GOSS*), smanjuje broj instanci koje se koriste u proceni podele čvorova, zadržavajući pritom instance sa najvećim gradijentom greške, dok se preostale instance nasumično uzorkuju (*random sampling*), čime se broj instanci smanjuje bez značajnog narušavanja tačnosti modela. Druga tehnika, grupisanje uzajamno isključivih obeležja (*Exclusive Feature Bundling*, *EFB*), kombinuje retko popunjena, uzajamno isključiva obeležja (*sparse features*) u jedinstvena, kompozitna obeležja, smanjujući na taj način dimenzionalnost prostora obeležja. Zajedničkom primenom ove dve tehnike, LightGBM ostvaruje znatno kraće vreme obučavanja u odnosu na standardne algoritme pojačavanja gradijenta, uz sposobnost rada sa skupovima podataka koji sadrže i po nekoliko miliona instanci i obeležja. Vizuelni prikaz tehnika GOSS i EFB, na kojima se zasniva efikasnost LightGBM algoritma, dat je u prilogima ukoliko čitalac želi grafički da sagleda opisane mehanizme.

LightGBM je pokazao snažne performanse u zadacima klasifikacije, regresije i rangiranja, zbog čega je postao rasprostranjen izbor u brojnim primenama mašinskog učenja, uključujući medicinu (Sinha et al., 2023), klimatsku analizu (X. Guo et al., 2023), građevinarstvo (Li et al., 2023) i dijagnostiku kvarova (Lao et al., 2023). Njegov dizajn takođe podržava paralelno i distribuirano izvršavanje, omogućavajući efikasno skaliranje na više mašina istovremeno. Među hiperparametrima koji se najčešće podešavaju u cilju optimizacije LightGBM modela izdvajaju se broj listova po stablu (*number of leaves*), koji predstavlja glavni parametar kojim se kontroliše složenost stabla, zatim maksimalna dubina stabla (*maximum depth*) i stopa učenja (*learning rate*), pored ostalih parametara koji se mogu podešavati. Pravilan izbor vrednosti ovih hiperparametara od suštinskog je značaja za postizanje visokih performansi modela.

Konvolucione neuronske mreže, korišćene za ekstrakciju dubokih obeležja, mogu se kombinovati sa ansambl klasifikatorima zasnovanim na pojačavanju gradijenta, poput CatBoost i LightGBM, u okviru dvoslojnih hibridnih arhitektura, pokazalo se kao efikasna strategija za unapređenje klasifikacione tačnosti. Umesto da se konačna klasifikacija prepusti standardnom, potpuno povezanom izlaznom sloju CNN arhitekture, dublje, hijerarhijski izdvojena obeležja prosleđuju se robusnijim ansambl klasifikatorima, koji nad tako pripremljenim obeležjima često ostvaruju bolje rezultate nego sam CNN model sa sopstvenim izlaznim slojem. Na ovakav pristup ukazuju i srodna istraživanja iz oblasti predikcije softverskih defekata (J. P. Viloth et al., 2025).

2.6. Metaheuristička optimizacija: teorijski okvir

Metaheuristički algoritmi, zajedno sa svojom istaknutom podgrupom poznatom kao algoritmi inspirisani rojem (*swarm intelligence*), predstavljaju skup efikasnih stohastičkih metoda inspirisanih grupnim obrascima ponašanja i socijalnim interakcijama koje ispoljavaju jednostavni organizmi koji uspevaju u velikim populacijama, poput jata ptica, riba ili kolonija insekata. Metode iz ove porodice poznate su po sposobnosti da efikasno adresiraju NP-teške probleme. Većina ovih algoritama je populaciono zasnovana i sastoji se iz dve različite faze, eksploracije i eksploatacije. Tokom eksploracije, algoritam nastoji da pokrije što je moguće veći deo prostora pretrage kako bi identifikovao regione koji sadrže obećavajuća rešenja. Tokom eksploatacije, pretraga se usmerava unutar tih regiona radi lociranja najboljeg dostižnog rešenja. Iako ne postoji garancija da će algoritam dostići globalno optimalno rešenje, on tipično pronalazi rešenje zadovoljavajućeg kvaliteta u prihvatljivom vremenskom okviru. Glavni izazov povezan sa ovim algoritmima jeste postizanje odgovarajuće ravnoteže između eksploracije i eksploatacije, s obzirom na to da mnogi algoritmi imaju tendenciju da favorizuju jednu fazu na račun druge, tendenciju koja se može ublažiti primenom različitih raspoloživih mehanizama, poput onih predloženih u ovoj disertaciji. Vizuelni prikaz razlike između faze eksploracije i faze eksploatacije prostora pretrage dat je u prilogima ukoliko čitalac želi grafički da sagleda opisani koncept.

Podešavanje hiperparametara modela dubokog učenja i klasifikatora zasnovanih na pojačavanju gradijenta, u teoriji računarske složenosti, spada u kategoriju NP-teških (*NP-hard*) problema. Ovo znači da, prema trenutnom stanju znanja, ne postoji algoritam koji bi ovaj problem mogao rešiti egzaktno, pronalaženjem zagarantovano optimalnog rešenja, u vremenu koje raste polinomijalno sa veličinom ulaza, odnosno brojem hiperparametara i veličinom njihovih opsega pretrage. Prostor mogućih kombinacija hiperparametara raste eksponencijalno sa brojem parametara koje je potrebno podesiti, usled čega iscrpna pretraga (*grid search*) postaje računski neizvodljiva već za umeren broj parametara sa širokim opsezima vrednosti. Iz ovog razloga se u praksi pribegava heurističkim i metaheurističkim pristupima, koji ne garantuju pronalaženje globalno optimalnog rešenja, ali su u stanju da u razumnom vremenu pronađu rešenja visokog kvaliteta, dovoljno blizu optimuma za praktičnu primenu.

Izbor odgovarajuće metaheuristike za konkretan optimizacioni problem dodatno je otežan teoremom o nepostojanju besplatnog ručka (*No Free Lunch Theorem*, NFL), koju su formulisali i matematički dokazali Wolpert i Mckridi (Wolpert & Macready, 1997). Ova teorema tvrdi da, ukoliko se performanse optimizacionih algoritama usrednje preko svih mogućih optimizacionih problema, nijedan algoritam ne ostvaruje bolje rezultate od bilo kog drugog algoritma, uključujući i slučajnu pretragu. Drugim rečima, poboljšana performans nekog algoritma na jednoj klasi problema nužno se kompenzuje slabijom performansom na nekoj drugoj klasi problema, tako da ne postoji univerzalno superioran optimizacioni algoritam za sve moguće probleme. Praktična posledica ove teoreme jeste da izbor metaheuristike mora biti empirijski utemeljen za svaki konkretan problem, umesto oslanjanja na pretpostavku da je jedan algoritam a priori bolji od drugih, što opravdava komparativni eksperimentalni pristup usvojen u ovoj disertaciji, u kome se predložene modifikacije IAVNS i DADPSO algoritma porede sa po nekoliko alternativnih metaheuristika.

Među tradicionalnim metaheuristikama iz ove porodice izdvajaju se optimizacija rojem čestica (*Particle Swarm Optimization*, PSO) (Kennedy & Eberhart, 1995), genetski algoritam

(*Genetic Algorithm*, GA) (Mirjalili, 2019), algoritam veštačke pčelinje kolonije (*Artificial Bee Colony*, ABC) (Karaboga & Basturk, 2008), algoritam pretrage promenljivog susedstva (*Variable Neighborhood Search*, VNS) (Mladenović & Hansen, 1997) i algoritam svica (*Firefly Algorithm*, FA) (Yang & Slowik, 2020), koji su svi našli široku primenu u brojnim optimizacionim zadacima. Pored njih, u poslednjih nekoliko godina predloženo je i mnoštvo novijih algoritama, uključujući *Reptile Search Algorithm* (RSA) (Abualigah et al., 2022), *Whale Optimization Algorithm* (WOA) (Mirjalili & Lewis, 2016), *Red Fox Algorithm* (Polap & Woźniak, 2021), *Polar Bear Algorithm* (Polap & Woźniak, 2017), *Gray Wolf Optimizer* (GWO) (Faris et al., 2018), *Crayfish Optimization Algorithm* (COA) (Jia et al., 2023), *Chimp Optimization Algorithm* (ChOA) (Khishe & Mosavi, 2020) i *Elk Herd Optimization* (EHO) (Al-Betar et al., 2024). Druga grupa popularnih metaheurističkih algoritama crpi inspiraciju iz matematičkih funkcija, sa istaknutim primerima poput *Sine Cosine Algorithm* (SCA) (Mirjalili, 2016), *Sinh Cosh Optimizer* (SCHO) (Bai et al., 2023) i COLSHADE algoritma (Gurrola-Ramos et al., 2020). Ovako veliki broj raspoloživih metaheuristika u skladu je sa teoremom o nepostojanju besplatnog ručka, objašnjenom ranije u ovom poglavlju, koja implicira potrebu za eksperimentisanjem sa više algoritama za svaki konkretan problem, umesto oslanjanja na jedan, unapred izabran algoritam.

Metaheuristički algoritmi su nedavno primenjeni sa značajnim uspehom u širokom rasponu realnih problema. U oblasti bezbednosti 5G mreža, autorka (Ismail, 2025) predložila je adaptivni okvir zasnovan na mašinskom učenju koji kombinuje laki (*lightweight*) konvolucionni model sa 11 slojeva (CSO-2D-CNN) i optimizovani XGBoost klasifikator sa mehanizmom pažnje, pri čemu su hiperparametri oba modela podešeni algoritmom optimizacije rojem mačaka (*Cat Swarm Optimization*), s ciljem unapređenja sistema za detekciju upada u bežičnim 5G mrežama, postigavši tačnost do 99,99% za binarnu i 99,97% za višeklasnu klasifikaciju saobraćaja. U predviđanju kretanja kriptovaluta, Er i saradnici (Er et al., 2025) koristili su FA (*Firefly Algorithm*) algoritam za selekciju obeležja i podešavanje hiperparametara modela regresije potpornih vektora (*Support Vector Regression*, SVR), pri čemu su sopstveni parametri FA algoritma dodatno optimizovani algoritmom potpuno informisane pretrage (*Fully Informed Search Algorithm*, FISA), unapređenom, bezparametarskom varijantom Rao algoritma, radi prognožiranja cena Bitkoina, Etereuma, Binance koina, Solane i Ripla po satu. Slični pristupi primenjeni su i u energetici: sistematski pregled (Mumtahina et al., 2024) sumira primenu metaheurističke optimizacije hiperparametara modela za kratkoročno prognožiranje potrošnje električne energije, predlažući trodelni okvir koji obuhvata sloj dekompozicije podataka, sloj prognožiranja i sloj optimizacije, dok su autori (A. Jovanovic et al., 2024) primenili slične pristupe na prognožiranje cena goriva, prognožiranje proizvodnje solarne energije pomoću rekurentnih arhitektura sa mehanizmom pažnje optimizovanih adaptiranim VNS algoritmom (Markovic et al., 2026) i prognožiranje proizvodnje energije na fotonaponskim trafostanicama pomoću LSTM mreže optimizovane modifikovanom metaheuristikom (Stojkovic et al., 2025).

Dodatne primene obuhvataju infrastrukturu računarskih sistema, gde Hoseini Širvani i Kanan Salih (Hosseini Shirvani & Kanaan Salih, 2025) pružaju sveobuhvatan pregled metaheurističkih algoritama za raspoređivanje tokova posla na *cloud* platformama, uz dodatne primene u prognožiranju opterećenja u oblaku (*cloud-load forecasting*) (Predić et al., 2024), predikciju softverskih defekata pomoću dvoslojnog okvira koji kombinuje konvolucionu mrežu sa ansambl klasifikatorima (XGBoost, AdaBoost, CatBoost), optimizovanog modifikovanim

FA algoritmom (J. P. Villoth et al., 2025), kao i optimizaciju bežičnih senzorskih mreža (M. Zivkovic et al., 2020). U obradi prirodnog jezika, metaheuristike su korišćene za izbor obeležja i podešavanje klasifikatora u zadacima poput analize sentimenta, detekcije uznemiravanja na internetu (Dobrojevic et al., 2024; Saroja & Haseena, 2024) i detekcije internih pretnji na osnovu tekstualnih zapisa aktivnosti (Mladenovic et al., 2024; T. Zivkovic et al., 2026). Poljoprivreda je takođe imala koristi od ovih pristupa, kroz predviđanje prinosa useva (Bacanin, Jovanovic, Djordjevic, et al., 2024).

Širok spektar medicinskih primena danas se oslanja na metaheurističku optimizaciju, na šta ukazuje opsežan pregled Lamise i saradnika (Lameesa et al., 2024), koji obuhvata primene u kliničkoj dijagnostici, medicinskom oslikavanju, upravljanju zdravstvenim operacijama i javnom zdravlju. Konkretnije primere predstavljaju dvoslojni okviri koji kombinuju konvolucione mreže sa ansambl klasifikatorima, optimizovani modifikovanim metaheuristikama, za procenu rizika od kardiovaskularnih bolesti (S. J. Villoth et al., 2026), klasifikaciju stadijuma Alchajmerove bolesti (Anicin et al., 2026) i klasifikaciju prijema kardioloških pacijenata (Dabic et al., 2025), pored užih primena poput detekcije anomalija u EKG signalima (L. Jovanovic et al., 2023) i detekcije epizoda ukočenosti hoda kod Parkinsonove bolesti (Bacanin, Jovanovic, Radic, et al., 2024). Ovaj širok spektar primena potvrđuje upotrebu metaheuristika kao opštenamenskih alata za konfiguraciju modela i optimizaciju prostora obeležja u sistemima zasnovanim na podacima, uključujući i dva hibridna okvira razvijena u ovoj disertaciji (Dogandzic, Bacanin, et al., 2026; Dogandzic, Zivkovic, et al., 2026).

Perzistentan izazov u mašinskom učenju predstavlja efikasan izbor hiperparametara, s obzirom na to da ovi izbori značajno utiču na performanse modela, ali po pravilu zahtevaju znatan računski napor. Upravo teorema o nepostojanju besplatnog ručka, podstakla je opsežno istraživanje metaheurističkih pristupa za ovu namenu, budući da su prepoznati po snažnoj sposobnosti navigacije kroz obimne, kompleksne i nepravilne prostore pretrage, uz istovremeno smanjenje rizika od prevremene konvergencije ka suboptimalnim rešenjima.

Osim optimizacije rojem čestica, i drugi populaciono zasnovani metaheuristički algoritmi uspešno su primenjeni na kompleksne optimizacione probleme, kako u kontinualnim, tako i u diskretnim domenima (Viswanathan & Ravichandran, 2025). Algoritmi zasnovani na koloniji mrava (*Ant Colony Optimization*) tipično se koriste za probleme planiranja putanje i rutiranja, dok je kombinacija genetskog algoritma sa latentnom Dirihleovom alokacijom primenjena za modelovanje tema u tekstualnim podacima (Ozcalci & Kilic, 2025). Metode zasnovane na koloniji mrava mogu podržati široku eksploraciju kroz kolektivnu pretragu zasnovanu na feromonima, dok su genetski algoritmi fleksibilni u pogledu diskretnih, kontinualnih i mešovitih reprezentacija rešenja, i mogu očuvati raznovrsnost populacije kroz rekombinaciju i mutaciju. Ove prednosti, međutim, prate dodatni operatori i kontrolni parametri, poput stope isparavanja feromona, stope ukrštanja i stope mutacije, koji povećavaju složenost implementacije i podešavanja. Za razliku od njih, optimizacija rojem čestica koristi relativno jednostavno ažuriranje pozicije i brzine sa manjim brojem kontrolnih parametara, što je čini pogodnom za problem razmatran u ovoj disertaciji, u kome svaka pojedinačna evaluacija kandidata zahteva obučavanje GRU modela. Njeno glavno ograničenje jeste postepeni gubitak raznovrsnosti roja, koji može izazvati prevremenu konvergenciju, ograničenje koje neposredno motiviše modifikaciju svesnu raznovrsnosti predloženu u ovoj disertaciji.

2.7. Pregled metaheurističkih algoritama primenjenih u istraživanju

U okviru eksperimentalne evaluacije ove disertacije korišćen je širok spektar savremenih i klasičnih metaheurističkih algoritama, čije je poznavanje neophodno za razumevanje predloženih modifikacija.

2.7.1. Algoritam pretrage promenljivog susedstva

Algoritam pretrage promenljivog susedstva (*Variable Neighborhood Search*, VNS) (Hansen & Mladenović, 2001; Mladenović & Hansen, 1997) predstavlja metaheuristiku zasnovanu na sistematskoj promeni strukture susedstva tokom pretrage. Za razliku od metoda koje se oslanjaju na jednu, fiksnu strukturu susedstva, VNS sistematski istražuje više različitih struktura susedstva kako bi izbegao lokalne optimume i unapredio konvergenciju ka globalnom optimumu. Algoritam se sastoji iz tri komponente:

- protresanja (*shaking*) - u kojoj se iz trenutnog susedstva bira nasumično rešenje
- lokalne pretrage - kojom se iz odabranog rešenja traži lokalni optimum
- promene susedstva - kojom se, u zavisnosti od uspešnosti prethodnog koraka, prostor pretrage ili sužava (nakon uspešnog poboljšanja) ili proširuje (u suprotnom)

Formalno, algoritam počinje od početnog rešenja x i unapred definisanog skupa struktura susedstva $N_1, N_2, \dots, N_k$, gde k predstavlja maksimalan broj susedstava. Svaka struktura susedstva predstavlja poseban način izmene ili narušavanja (*perturbation*) trenutnog rešenja, pri čemu su susedstva po pravilu uređena po rastućoj snazi narušavanja, od najfinijih ka najgrubljim izmenama. U fazi protresanja, algoritam nasumično bira rešenje unutar trenutnog susedstva $N_k(x)$ radi diversifikacije pretrage i smanjenja rizika od zarobljavanja u lokalnom optimumu, kao što je prikazano jednačinom (18):

$$x' = \text{Random}(N_k(x)) \quad (18)$$

gde je x' nasumično izabran sused rešenja x unutar susedstva N_k . Nakon generisanja x' , VNS sprovodi lokalnu pretragu unutar tog susedstva kako bi identifikovao lokalni optimum x'' , koristeći postupke poput penjanja uz brdo (*hill climbing*) ili gradijentnog spusta (*gradient descent*), kao što je definisano jednačinom (19):

$$x'' = \text{LocalSearch}(x') \quad (19)$$

gde je x'' poboljšano rešenje u okviru lokalnog susedstva.

Ako je lokalni optimum x'' bolji od trenutnog rešenja x , algoritam ažurira rešenje $x = x''$ i vraća indeks susedstva na $k = 1$. U suprotnom, indeks susedstva se uvećava za 1 kako bi se pretraga nastavila u širem susedstvu, kao što je opisano jednačinom (20):

$$x = \begin{cases} x'', & \text{if } f(x'') < f(x) \\ x, & \text{suprotno} \end{cases} \quad (20)$$

gde je $f(x)$ funkcija cilja. Algoritam se zaustavlja kada je zadovoljen kriterijum zaustavljanja, poput maksimalnog broja iteracija ili iscrpljivanja svih raspoloživih susedstava.

VNS je posebno pogodan za optimizaciju hiperparametara modela mašinskog učenja, budući da omogućava efikasno istraživanje kompleksnih, visokodimenzionalnih prostora pretrage. Variranjem struktura susedstva, VNS održava ravnotežu između eksploracije i eksploatacije, omogućavajući dostizanje gotovo optimalnih konfiguracija bez oslanjanja na iscrpnu pretragu, što je posebno vredno pri podešavanju hiperparametara dubokih arhitektura i modela zasnovanih na gradijentnom pojačavanju, gde su tradicionalne strategije poput pretrage po mreži (*grid search*) ili nasumične pretrage (*random search*) računski neisplative.

Osnovna varijanta opisana u prethodnim jednačinama poznata je u literaturi kao osnovni VNS (*Basic VNS*, BVNS). Pored nje, (Hansen & Mladenović, 2001) uveli su i nekoliko srodnih varijanti koje su od značaja za razumevanje modifikacija predloženih u ovoj disertaciji. Pretraga promenljivog opadanja (*Variable Neighborhood Descent*, VND) predstavlja deterministički oblik VNS-a bez faze protresanja, u kome se sistematska promena susedstava koristi isključivo kao postupak lokalne pretrage, često kao ugrađena komponenta unutar opštijih VNS šema. Redukovani VNS (*Reduced VNS*, RVNS) izostavlja fazu lokalne pretrage i oslanja se samo na protresanje i poređenje rešenja, što ga čini pogodnim za probleme velikih razmera kod kojih je lokalna pretraga računski preskupa. Dekompozicioni VNS (*Variable Neighborhood Decomposition Search*, VNDS) (Hansen et al., 2001) dodatno uvodi dekompoziciju problema na manje potprobleme pre primene lokalne pretrage, čime se dodatno smanjuje računaska složenost kod velikih instanci.

Zajednička osobina svih ovih varijanti jeste da promena strukture susedstva, a ne slučajno ponovno pokretanje pretrage, predstavlja mehanizam kojim se sistematski proširuje prostor pretrage nakon neuspešnog poboljšanja, što VNS suštinski razlikuje od pristupa zasnovanih na čisto nasumičnom restartovanju. Upravo ova osobina, uzimajući u obzir da VNS u kasnijim fazama pretrage postepeno gubi sposobnost eksploatacije usled sve grubljih struktura susedstva, predstavlja polaznu tačku za modifikaciju predloženu u ovoj disertaciji, detaljnije opisanu u poglavlju posvećenom naučnom doprinosu rada.

2.7.2. Optimizacija rojem čestica

Optimizacija rojem čestica (*Particle Swarm Optimization*, PSO) (Kennedy & Eberhart, 1995) predstavlja populaciono zasnovanu, bezgradijentnu (*derivative-free*) optimizacionu strategiju, inspirisanu obrascima koordinisanog kretanja koji se u prirodi uočavaju kod jata ptica ili riba. Algoritam operiše nad fiksnim skupom agenata, odnosno čestica, od kojih svaka pamti svoju trenutnu poziciju, vektor brzine i najbolje rešenje koje je do tog trenutka samostalno pronašla, dok roj u celini pamti najbolje rešenje pronađeno među svim česticama. Pozicija i brzina svake čestice ažuriraju se u svakoj iteraciji na osnovu tri komponente:

- inercije - koja odražava prethodni pravac kretanja čestice i doprinosi stabilnosti putanje

- kognitivne komponente - koja česticu privlači ka njenom individualno najboljem pronađenom rešenju
- socijalne komponente - koja česticu privlači ka globalno najboljem rešenju pronađenom u čitavom roju

Budući da je namenjen optimizaciji kontinualnih funkcija cilja, PSO je posebno pogodan u situacijama u kojima gradijentna informacija nije dostupna, nije pouzdana, ili je njeno računanje suviše skupo, zbog čega dobro funkcioniše na problemima sa kompleksnim, višemodalnim ili nekontinualnim prostorima pretrage. Glavno ograničenje standardnog PSO algoritma jeste postepeni gubitak raznovrsnosti roja tokom izvršavanja, što može dovesti do prevremene konvergencije ka lokalnom optimumu, a upravo ovo ograničenje predstavlja polazište za modifikaciju predloženu u ovoj disertaciji.

Formalno, algoritam inicijalizuje roj čestica, pri čemu se svakoj čestici i nasumično dodeljuje početna pozicija $x_i(0) \in \mathbb{R}^n$ i odgovarajuća početna brzina $v_i(0)$. Tokom iteracija, brzina svake čestice ažurira se kombinovanjem tri uticaja: momenta iz prethodnih koraka, ličnog najboljeg iskustva čestice i kolektivnog znanja celog roja, prema jednačini (21):

$$v_i(t+1) = \omega v_i(t) + c_1 r_{1,i}(t)(p_i(t) - x_i(t)) + c_2 r_{2,i}(t)(g(t) - x_i(t)) \quad (21)$$

gde $p_i(t)$ označava najbolju poziciju koju je čestica i pronašla do iteracije t , a $g(t)$ predstavlja najbolje rešenje pronađeno u čitavom roju do te iteracije. Stohastički faktori $r_{1,i}$ i $r_{2,i}$ nezavisno se uzorkuju iz uniformne raspodele na intervalu $[0,1]$. Parametri ω , c_1 i c_2 predstavljaju koeficijente skaliranja: ω upravlja članom inercije kontrolišući moment kretanja, c_1 podešava individualni (kognitivni) uticaj čestice, dok c_2 upravlja privlačenjem ka kolektivnom iskustvu roja (socijalna komponenta). Međusobni odnos ovih težina određuje ravnotežu između široke eksploracije prostora pretrage i usmerene eksploatacije obećavajućih regiona. Nakon ažuriranja brzina, pozicije čestica se ažuriraju prema jednačini (22):

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (22)$$

Ova procedura ažuriranja pomera svaku česticu kroz prostor pretrage. Nakon evaluacije funkcije cilja na novim pozicijama, najbolje lične pozicije p_i i najbolja globalna pozicija g ažuriraju se kad god se pronađe bolje rešenje. Postupak se ponavlja iterativno sve dok se ne ispuni kriterijum zaustavljanja, obično unapred definisan maksimalan broj iteracija.

Vredi napomenuti da originalna verzija algoritma, koju su predložili Kenedi i Eberhart (Kennedy & Eberhart, 1995) po uzoru na simulacije koordinisanog kretanja jata i istraživanja kolektivnog ponašanja u socijalnoj psihologiji, nije sadržala koeficijent inercije ω , već samo kognitivnu i socijalnu komponentu. Ovaj parametar naknadno su uveli Ši i Eberhart (Shi & Eberhart, 1998), kako bi se eksplicitno kontrolisao doprinos prethodne brzine čestice novoj brzini, čime je omogućena direktna regulacija ravnoteže između eksploracije i eksploatacije, umesto da ona proizilazi isključivo iz slučajnih koeficijenata r_1 i r_2 . Pored izbora parametara, na ponašanje roja značajno utiče i njegova komunikaciona topologija, odnosno način na koji čestice razmenjuju informacije o najboljim pronađenim rešenjima. Kenedi i Mendes (Kennedy

& Mendes, 2002) pokazali su da izbor topologije, poput potpuno povezane strukture u kojoj svaka čestica komunicira sa čitavim rojem (*global best*), prstenaste ili von Nojmanove strukture, značajno utiče na brzinu konvergencije i sposobnost roja da očuva raznovrsnost rešenja, pri čemu gušće povezane topologije ubrzavaju konvergenciju po cenu veće sklonosti ka prevremenom zarobljavanju u lokalnom optimumu. Upravo ovaj kompromis između brzine konvergencije i očuvanja raznovrsnosti roja, zajedno sa postepenim gubitkom raznovrsnosti opisanim u prvom pasusu, predstavlja teorijsku osnovu za modifikaciju predloženu u ovoj disertaciji.

2.7.3. Pregled ostalih algoritama

Genetski algoritam (Genetic Algorithm, GA) (Mirjalili, 2019) predstavlja evolutivnu metaheuristiku inspirisanu prirodnom selekcijom, u kojoj se populacija rešenja iterativno unapređuje primenom operatora selekcije, ukrštanja (*crossover*) i mutacije. Algoritam svica (*Firefly Algorithm*) (Yang & He, 2013b; Yang & Slowik, 2020) zasniva se na modelu privlačenja svitaca, pri čemu se manje „svetla“ (lošija) jedinka kreće ka svetlijoj (boljoj) jedinki, sa privlačnošću koja eksponencijalno opada sa rastojanjem, što algoritmu omogućava snažnu sposobnost eksploatacije u okolini boljih rešenja.

Pored navedenih, u eksperimentalnoj evaluaciji korišćeni su i drugi savremeni metaheuristički algoritmi, od kojih svaki crpi inspiraciju iz specifičnog prirodnog ili društvenog fenomena. Algoritam veštačke pčelinje kolonije (*Artificial Bee Colony*, ABC) (Karaboga & Basturk, 2008) oponaša ponašanje pčela pri sakupljanju nektara, raspoređujući jedinke u uloge zaposlenih, posmatračkih i izviđačkih pčela kako bi se uravnotežila eksploatacija poznatih izvora hrane i istraživanje novih. Algoritam pretrage gmizavaca (*Reptile Search Algorithm*, RSA) (Abualigah et al., 2022) modeluje ponašanje krokodila pri okruživanju i lovu na plen, kroz faze visokog i niskog intenziteta pretrage. Algoritam optimizacije kitova (*Whale Optimization Algorithm*, WOA) (Mirjalili & Lewis, 2016) inspirisan je strategijom lova mehurićima kojom se služe grbavi kitovi, koristeći mehanizam sažimajućeg okruživanja i spiralno ažuriranje pozicije jedinki. Optimizator sivog vuka (*Grey Wolf Optimizer*, GWO) (Faris et al., 2018) modeluje hijerarhiju vođstva i strategiju grupnog lova čopora sivih vukova, u kojoj tri najbolje rangirane jedinke usmeravaju kretanje ostatka čopora ka plenu, odnosno ka optimalnom rešenju. Algoritam optimizacije rakova (*Crayfish Optimization Algorithm*, COA) (Jia et al., 2023) zasniva se na ponašanju rečnih rakova pri traženju hladovine, nadmetanju za sklonište i sakupljanju hrane. Algoritam optimizacije šimpanzi (*Chimp Optimization Algorithm*, ChOA) (Khishe & Mosavi, 2020) modeluje individualne i grupne strategije lova šimpanzi, dodeljujući jedinkama uloge gonjenja, blokiranja, jurenja i napada na plen. Algoritam sinusa i kosinusa (*Sine Cosine Algorithm*, SCA) (Mirjalili, 2016) koristi matematičke funkcije sinusa i kosinusa da iterativno pomera kandidat rešenja ka trenutno najboljem rešenju, oscilujući oko njega opadajućom amplitudom. Sinh-kos optimizator (*Sinh Cosh Optimizer*, SCHO) (Bai et al., 2023) na sličan način koristi hiperbolne funkcije za upravljanje prelaskom iz faze eksploracije u fazu eksploatacije. COLSHADE algoritam (Gurrola-Ramos et al., 2020) predstavlja varijantu istorijski adaptivne diferencijalne evolucije (*Success-History based Adaptive Differential Evolution*, SHADE), proširenu tehnikom rangiranja rešenja prema stepenu narušavanja ograničenja, namenjenu problemima sa ograničenjima. Algoritam slepog miša (*Bat Algorithm*,

BA) (Yang & He, 2013a) modeluje ehologaciju šišmiša, koristeći promenljivu frekvenciju, glasnoću i učestalost emitovanja pulseva za regulisanje odnosa eksploracije i eksploatacije. Algoritam optimizacije olujom ideja (*Brainstorm Optimization*, BSO) (Shi, 2011) inspirisan je ljudskim procesom brejnstorminga, u kome se rešenja grupišu u klastere, a novi predlozi nastaju generisanjem i zamenom unutar i između klastera. Samoprilagodljiva sferna pretraga (*Self-Adaptive Spherical Search*, SASS) (A. Kumar et al., 2020) kombinuje sfernu pretragu sa samoprilagodljivim kontrolnim parametrima, čime se ravnoteža između diverzifikacije i intenzifikacije postiže bez potrebe za ručnim podešavanjem.

Navedeni algoritmi obuhvataju različite paradigme metaheurističke optimizacije: evolutivne pristupe (GA), pristupe inspirisane rojem i kolektivnim ponašanjem životinja (FA, ABC, WOA, GWO, COA, ChOA, BA), matematički inspirisane pristupe (SCA, SCHO), diferencijalnu evoluciju sa mehanizmom za rešavanje ograničenja (COLSHADE), kao i pristupe inspirisane ljudskim kognitivnim procesima (BSO) i samoprilagodljive strategije pretrage (SASS). Ova raznovrsnost obezbeđuje da poređenje ne bude ograničeno na algoritme sa sličnim mehanizmima pretrage, već obuhvata širok spektar strategija za balansiranje eksploracije i eksploatacije. Navedeni algoritmi korišćeni su u eksperimentalnoj evaluaciji kao komparatori za modifikovane metaheuristike predložene u ovoj disertaciji (IAVNS i DADPSO), čime je omogućeno objektivno poređenje njihove sposobnosti optimizacije hiperparametara u okviru oba razmatrana okvira.

2.8. Bioakustika i automatska klasifikacija vrsta ptica na osnovu zova

Bioakustika predstavlja naučnu oblast koja proučava proizvodnju, prenos i percepciju zvuka kod živih organizama, sa posebnim naglaskom, u kontekstu ove disertacije, na vokalizacije ptica. Praćenje prisustva i brojnosti vrsta ptica pruža uvid u biodiverzitet, distribuciju vrsta i uticaj promena životne sredine na populaciju ptica (Xie et al., 2023), s obzirom na to da ptice imaju važnu ulogu u oprašivanju, raznošenju semena i regulaciji populacija insekata. Tradicionalni metodi terenskog posmatranja, iako i dalje u širokoj upotrebi, iziskuju značajne ljudske i vremenske resurse i podložni su subjektivnoj proceni posmatrača, dok akustička detekcija, u pojedinim slučajevima, može nadmašiti tradicionalne metode terenskog popisivanja u proceni relativne gustine populacija (Jarrett & Willis, 2025).

Automatizacija klasifikacije zova ptica prošla je kroz nekoliko razvojnih faza, od ranijih pristupa zasnovanih na spektrogramskim obeležjima i klasifikatorima poput višeslojnog perceptrona (Pahuja & Kumar, 2021), preko primene konvolucionih neuronskih mreža nad spektrogramskim reprezentacijama u cevovodima za identifikaciju vrsta ptica i žaba u tropskim zvučnim pejzažima (LeBien et al., 2020), do savremenih pristupa zasnovanih na dubokom učenju primenjenom direktno nad sirovim zvučnim talasnim oblicima (Sanchez et al., 2021) i modelima zasnovanim na transformer arhitekturi i samonadgledanom učenju za praćenje planinskih vrsta ptica (Wei et al., 2024). Značajan doprinos ovoj oblasti predstavlja i model BirdNET, čija je sposobnost da iz velikih ekoakustičkih skupova podataka izvede zaključke o sastavu evropskih zajednica ptica potvrđena u više studija (Funosas et al., 2024), kao i sistemi za akustičko praćenje noćne migracije ptica (Van Doren et al., 2024). Istraživanja su takođe pokazala da sastav zvučnog pejzaža (*soundscape composition*), odnosno prisustvo drugih izvora zvuka u okruženju, značajno utiče na tačnost klasifikacije vokalizacija ptica u projektima

građanske nauke (*citizen science*) posvećenim praćenju biodiverziteta (Clark et al., 2023), što dodatno naglašava značaj pažljivog izbora skupa podataka i konteksta u kome se klasifikacija sprovodi, uključujući izbor vrsta koje dele isto stanište, primenjen i u ovoj disertaciji.

2.9. Elektroencefalografija i neurodijagnostika epilepsije

Elektroencefalografija (*Electroencephalography*, EEG) predstavlja neinvazivnu dijagnostičku tehniku kojom se, putem elektroda postavljenih na površini glave, registruje bioelektrična aktivnost mozga. Budući da metoda ne narušava telesno tkivo, EEG predstavlja bezbolan i bezbedan način za otkrivanje i razlikovanje normalnih od abnormalnih obrazaca neuronskog okidanja. Blagovremeno prepoznavanje i pravovremeno terapijsko delovanje pritom značajno utiču na dugoročnu prognozu pacijenta, budući da ponovljene epizode napada mogu dovesti do trajnog neurološkog oštećenja (Benbadis et al., 2020). EEG predstavlja ključni dijagnostički postupak u potvrdi prisustva epilepsije, poremećaja karakterisanog pojavom napada usled abnormalnih, sinhronizovanih električnih pražnjenja grupa neurona, kao i u lokalizaciji disfunkcionalnih kortikalnih regiona i praćenju terapijskog odgovora (Noachtar & Rémi, 2009), a igra ključnu ulogu i u razlikovanju sličnih stanja, kategorizaciji tipova napada i predhirurškoj proceni (Tatum et al., 2018).

Uprkos dijagnostičkom značaju, interpretacija EEG zapisa suočava se sa nekoliko izazova. Interobserverska varijabilnost, odnosno razlike u zaključcima do kojih dolaze klinički stručnjaci različitog iskustva prilikom analize istog EEG zapisa, predstavlja često citiran problem koji može dovesti do dijagnostičkih grešaka (Benarous et al., 2019; Benbadis & Kaplan, 2019), dok pogrešno tumačenje atipičnih, epileptiformnih obrazaca može dovesti do prekomerne dijagnoze (*overdiagnosis*) epilepsije (Amin & Benbadis, 2019). Nelinearna i nestacionarna priroda EEG signala dodatno otežava pouzdanu vizuelnu procenu, usled čega klinički suptilne, ali dijagnostički relevantne devijacije oblika talasa mogu ostati neuočene.

Primena veštačke inteligencije u neurodijagnostici, iako u ekspanziji, i dalje predstavlja relativno slabo istraženo polje u odnosu na druge medicinske primene. Rana istraživanja u ovoj oblasti oslanjala su se pretežno na klasične algoritme mašinskog učenja, poput klasifikatora potpornih vektora (*Support Vector Classifier*, SVC), koji, iako korisni, po prirodi ne modeluju sekvencijalne zavisnosti unutar signala, čime je ograničena njihova efikasnost u realnim EEG primenama. Mašinsko učenje je, uz to, doprinelo i razjašnjenju kliničkih relacija u srodnim domenima, na primer primenom modela nasumične šume za predviđanje jezičkih deficita na osnovu traktografije difuzionog tenzorskog snimanja kod pedijatrijskih pacijenata sa kortikalnim malformacijama (Paldino et al., 2014). Noviji radovi sve više se okreću arhitekturama dubokog učenja primenjenim direktno nad sirovim ili minimalno predobrađenim EEG signalima, uključujući konvolucione, LSTM zasnovane rekurentne modele, kao i hibridne CNN-LSTM i transformer arhitekture, pri čemu novije preglede literature ukazuju na to da hibridni i pažnjom (*attention*) potpomognuti modeli mogu unaprediti generalizaciju nezavisnu od pacijenta i lokalizaciju epileptogene aktivnosti u odnosu na ranije, jednostruke arhitekture (Lyu, 2026; Qamar et al., 2025), na primer kroz kombinaciju jednodimenzionalnog CNN-LSTM modela sa diskretnom *wavelet* transformacijom (*Discrete Wavelet Transform*, DWT) u predobradi signala (Kashefi Amiri et al., 2025). Ipak, uočava se jasan istraživački nedostatak u pogledu integracije GRU arhitekture, optimizovane metaheurističkim algoritmima poput PSO,

za potrebe identifikacije anomalija u EEG signalu, čime se otvara prostor za doprinos ove disertacije.

2.10. Metrike za evaluaciju klasifikacionih modela

Objektivna i kvantitativna procena kvaliteta klasifikacionog modela predstavlja preduslov za pouzdano poređenje različitih arhitektura, konfiguracija hiperparametara i optimizacionih strategija. Bez jasno definisanih metrika evaluacije, ocena performansi modela svodila bi se na subjektivan utisak, nepodesan kako za naučnu reprodukciju rezultata, tako i za sistematsko vođenje procesa optimizacije. U kontekstu metaheurističke optimizacije hiperparametara, ove metrike imaju dvostruku ulogu. S jedne strane, služe kao osnovno sredstvo za poređenje performansi različitih modela i algoritama. S druge strane, u obliku funkcije cilja, direktno usmeravaju sam proces pretrage, budući da metaheuristički algoritam u svakoj iteraciji ocenjuje kvalitet kandidat-rešenja upravo na osnovu izabrane metrike.

Većina standardnih metrika za evaluaciju klasifikacionih modela izvodi se iz matrice konfuzije, koja sistematizuje ishode klasifikacije upoređivanjem predviđenih i stvarnih oznaka klasa kroz četiri kategorije: tačno pozitivne, tačno negativne, lažno pozitivne i lažno negativne klasifikacije. Iz ove matrice moguće je izvesti čitav niz metrika koje osvetljavaju različite aspekte ponašanja modela, pri čemu izbor odgovarajuće metrike zavisi od prirode problema i karakteristika skupa podataka, a naročito od stepena uravnoteženosti klasa po broju uzoraka.

Ocena performansi klasifikacionih modela u ovoj disertaciji zasniva se na standardnim metrikama izvedenim iz matrice konfuzije, odnosno iz broja tačno pozitivnih (*true positives*, TP), tačno negativnih (*true negatives*, TN), lažno pozitivnih (*false positives*, FP) i lažno negativnih (*false negatives*, FN) klasifikacija. Preciznost (*precision*) izražava udeo tačno pozitivnih predikcija u ukupnom broju predikcija pozitivne klase, dok osetljivost (*sensitivity*), odnosno odziv (*recall*), izražava udeo tačno pozitivnih predikcija u ukupnom broju stvarno pozitivnih instanci:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (23)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (24)$$

Tačnost (*accuracy*) predstavlja udeo svih tačno klasifikovanih instanci u ukupnom broju instanci:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (25)$$

dok F1-mera predstavlja harmonijsku sredinu preciznosti i osetljivosti:

$$F_1\text{-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (26)$$

Iako raširene u upotrebi, ove metrike, a naročito tačnost, mogu davati zavaravajuće optimističnu sliku o kvalitetu modela u prisustvu neuravnoteženosti klasa po broju uzoraka, budući da model koji sistematski favorizuje većinsku klasu može ostvariti visoku tačnost uprkos lošoj sposobnosti prepoznavanja manjinskih klasa. Iz tog razloga, u oba istraživanja na kojima se zasniva ova disertacija, pored navedenih metrika, praćena je i stopa greške, izražena kao $1 - \text{Accuracy}$, korišćena kao pomoćni indikator konvergencije tokom optimizacionog procesa.

Kao primarna funkcija cilja u procesu metaheurističke optimizacije u oba rada korišćen je Matjuzov korelacioni koeficijent (*Matthews Correlation Coefficient*, MCC), prvobitno uveden u kontekstu procene sekundarne strukture proteina (Matthews, 1975). MCC predstavlja posebno značajnu metriku u radu sa neuravnoteženim skupovima podataka. Za razliku od sirove tačnosti (*raw accuracy*), koja može davati zavaravajuću sliku kada je raspodela klasa neravnomerna, MCC odražava stvarni kvalitet predikcije nagrađujući tačne klasifikacije proporcionalno u svim klasama i penalizujući sistematsku pristrasnost modela ka većinskoj klasi. MCC objedinjuje sve četiri komponente matrice konfuzije u jedinstvenu meru:

$$MCC = \frac{TP \cdot TN - FP \cdot FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (27)$$

čija se vrednost kreće u intervalu od -1 (potpuno pogrešna klasifikacija) do $+1$ (savršena klasifikacija), pri čemu vrednost 0 odgovara klasifikaciji koja ne nadmašuje slučajno pogađanje. Čiko i Jurman (Chicco & Jurman, 2020) pokazali su da MCC pruža pouzdaniju i informativniju procenu kvaliteta binarne klasifikacije u odnosu na F1-meru i tačnost, naročito u prisustvu neuravnoteženih klasa, zbog čega je ova metrika, uprkos poreklu u binarnoj klasifikaciji, prirodno proširena i primenjena i u višeklasnim klasifikacionim scenarijima razmatranim u ovoj disertaciji.

2.11. Statistička validacija rezultata stohastičkih optimizacionih algoritama

S obzirom na to da metaheuristički algoritmi po svojoj prirodi sadrže elemente slučajnosti, pojedinačno poređenje rezultata jednog izvršavanja različitih algoritama ne pruža dovoljno pouzdan osnov za zaključivanje o njihovoj relativnoj superiornosti. Iz tog razloga, metodološke smernice za poređenje bioinspirisanih optimizacionih algoritama (LaTorre et al., 2021) preporučuju sprovođenje većeg broja nezavisnih izvršavanja svakog algoritma, praćeno formalnom statističkom validacijom uočenih razlika. Demšar (Demsar, 2006) je u svom uticajnom radu o statističkom poređenju klasifikatora dodatno naglasio da se u mašinskom učenju i optimizaciji razlike u performansama često pogrešno proglašavaju značajnim

isključivo na osnovu proseka, bez formalnog testiranja statističke značajnosti uočenih razlika, što može dovesti do pogrešnih zaključaka o superiornosti jednog pristupa nad drugim.

Statistička validacija u ovom kontekstu zasniva se na testiranju hipoteza, pri čemu se formuliše nulta hipoteza (H_0), koja pretpostavlja da ne postoji statistički značajna razlika između rezultata poređenih algoritama, i alternativna hipoteza (H_1), koja tvrdi suprotno. Na osnovu dobijenih rezultata izračunava se p-vrednost, koja predstavlja verovatnoću dobijanja posmatranih ili ekstremnijih rezultata pod pretpostavkom da je nulta hipoteza tačna. Ukoliko je p-vrednost manja od unapred definisanog nivoa značajnosti α (u ovoj disertaciji, kao i u oba rada na kojima se ona zasniva, $\alpha = 0.05$), nulta hipoteza se odbacuje u korist alternativne, čime se uočena razlika proglašava statistički značajnom.

Pre primene parametarskih statističkih testova, neophodno je proveriti zadovoljenost njihovih pretpostavki, koje obuhvataju nezavisnost uzoraka, normalnost raspodele rezultata i homogenost varijansi (*homoscedasticity*). Nezavisnost uzoraka obezbeđuje se izvršavanjem svakog algoritma sa različitim, nezavisno generisanim početnim uslovima (semenima slučajnosti). Normalnost raspodele rezultata proverava se Šapiro-Vilkovim testom (Shapiro & Francia, 1972), koji testira nultu hipotezu da uzorak potiče iz normalno raspodeljene populacije, poredeći poredak vrednosti uzorka sa očekivanim poretom pod pretpostavkom normalnosti. U jednom od dva rada na kojima se zasniva ova disertacija, homogenost varijansi dodatno je ispitana Levenovim testom (*Levene's test*) (Glass, 1966), koji testira nultu hipotezu o jednakosti varijansi između poređenih grupa rezultata, na osnovu odstupanja pojedinačnih vrednosti od grupnih sredina, odnosno medijana.

Ukoliko se pretpostavka normalnosti ne potvrdi, što je čest slučaj kod rezultata stohastičkih optimizacionih algoritama usled asimetrije uzrokovane konvergencijom ka boljim rešenjima, primena parametarskih testova nije opravdana, te se pribegava neparametarskim alternativama. U ovoj disertaciji korišćen je Vilkoksonov test ranga sa predznakom (*Wilcoxon signed-rank test*) (Wilcoxon, 1992; Woolson, 2005), kojim se ispituje statistička značajnost razlike između uparenih rezultata predloženog i poredećih algoritama, bez pretpostavke o obliku njihove raspodele. Test funkcioniše tako što se za svaki par rezultata izračunava razlika, potom se apsolutne vrednosti tih razlika rangiraju od najmanje ka najvećoj, a rangovima se pridružuje predznak originalne razlike. Zbir pozitivno i negativno rangiranih razlika potom se koristi za izračunavanje test-statistike, koja se, u zavisnosti od veličine uzorka, poredi sa tabličnim kritičnim vrednostima ili aproksimira normalnom raspodelom. Za poređenje više od dva algoritma istovremeno, u literaturi se često koristi i Fridmanov test (*Friedman test*), praćen odgovarajućim post-hoc procedurama (Demsar, 2006), iako je u ovoj disertaciji, s obzirom na to da je fokus na parnom poređenju predloženog algoritma sa svakim od poredećih pristupa ponaosob, korišćen isključivo Vilkoksonov test.

2.12. Objašnjivost modela veštačke inteligencije

Porastom kompleksnosti modela veštačke inteligencije, a naročito modela dubokog učenja i ansambl metoda, opada njihova inherentna transparentnost, odnosno mogućnost neposrednog razumevanja razloga koji stoje iza pojedinačne predikcije modela. Ovaj problem, poznat kao problem „crne kutije” (*black box*), doveo je do razvoja posebne istraživačke oblasti objašnjive veštačke inteligencije (*Explainable Artificial Intelligence*, XAI) (Samek & Müller,

2019), čiji je cilj razvoj metoda kojima se, bez žrtvovanja prediktivnih performansi modela, obezbeđuje uvid u relativan doprinos pojedinačnih ulaznih obeležja konačnoj odluci modela. Iako istraživanja veštačke inteligencije po pravilu daju prioritet performansama modela, uvid u obrazloženje njegovih odluka od ključnog je značaja za otkrivanje skrivenih pristrasnosti, kako u samim podacima, tako i u modelu. Kod jednostavnijih modela ovaj uvid je relativno lako ostvariv, dok porast kompleksnosti otežava identifikaciju suptilnih odnosa između ulaznih obeležja i izlaza modela, što je i motivisalo razvoj naprednih tehnika za sistematsku procenu značaja obeležja.

Jedna od najrasprostranjenijih savremenih metoda objašnjivosti jeste SHAP (*SHapley Additive exPlanations*) (Lundberg & Lee, 2017), zasnovana na konceptu Šapijevih vrednosti (*Shapley values*) iz kooperativne teorije igara. Osnovna ideja SHAP metode jeste da se doprinos svakog pojedinačnog obeležja konačnoj predikciji modela proceni razmatranjem svih mogućih redosleda uključivanja obeležja u model, pri čemu se doprinos obeležja definiše kao prosečna promena predikcije prilikom njegovog uvođenja, usrednjena preko svih mogućih kombinacija preostalih obeležja. Zbog računске zahtevnosti egzaktnog izračunavanja Šapijevih vrednosti, u praksi se primenjuju efikasne aproksimacije, pogodne za primenu i nad kompleksnim modelima poput ansambl stabala odlučivanja i dubokih neuronskih mreža.

SHAP metoda naširoko je primenjivana za tumačenje modela zasnovanih na ansamblima stabala odlučivanja u različitim primenjenim oblastima. Za modele ovog tipa, poput onih korišćenih u ovoj disertaciji, posebno je značajan efikasan algoritam TreeSHAP (Lundberg et al., 2020), koji obezbeđuje egzaktno i računski skalabilno izračunavanje Šapijevih vrednosti za modele poput slučajnih šuma i modela zasnovanih na gradijentnom pojačavanju. Busman i saradnici (Bussmann et al., 2021) primenili su upravo TreeSHAP u kombinaciji sa XGBoost modelom u oblasti upravljanja kreditnim rizikom, grupišući klijente prema sličnosti u osnovnim finansijskim karakteristikama na osnovu dobijenih Šapijevih vrednosti. SHAP metoda je primenjena i u okviru istraživanja metaheurističke optimizacije modela mašinskog učenja, na primer za tumačenje modela metaheuristički optimizovanog ekstremnog pojačavanja gradijenta u predikciji softverskih defekata (T. Zivkovic et al., 2023). U ovoj disertaciji SHAP je primenjen radi tumačenja odluka najuspešnijeg modela za klasifikaciju zova ptica, pojedinačno za najbolji CNN model, kao i za najbolje hibridne CNN-CatBoost i CNN-LightGBM modele.

3. Pregled postojećih istraživanja

Ovo poglavlje sistematizuje relevantnu naučnu literaturu na kojoj počiva sprovedeno istraživanje, podeljenu u tri tematske celine:

- istraživanja u oblasti bioakustičke klasifikacije i obrade audio signala
- istraživanja u oblasti automatske analize EEG signala i neurodijagnostike epilepsije

- istraživanja u oblasti primene metaheurističke optimizacije na modele dubokog učenja

Na kraju poglavlja dat je kritički osvrt na identifikovana ograničenja postojećih pristupa, čime se opravdava potreba za istraživanjem sprovedenim u ovoj disertaciji.

3.1. Istraživanja u oblasti bioakustičke klasifikacije i obrade audio signala

Automatska klasifikacija vokalizacija životinja, a naročito ptica, u poslednjoj deceniji prešla je put od klasičnih pristupa zasnovanih na spektrogramskim obeležjima i jednostavnim klasifikatorima, do savremenih arhitektura dubokog učenja primenjenih direktno nad sirovim zvučnim signalom. Paralelno s tim, tehnika izdvajanja MFCC obeležja, prvobitno razvijena za prepoznavanje govora, pokazala se kao robusna i široko primenljiva osnova za predobradu bioakustičkih signala.

Tabela 1. Pregled istraživanja u oblasti bioakustičke klasifikacije i obrade audio signala

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Davis & Mermelstein, 1980	<i>Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences</i>	Uveli su Mel-kepstralne koeficijente (MFCC) kao parametarsku reprezentaciju govornog signala, oponašajući nelinearnu percepciju ljudskog sluha	Postavljena je osnova MFCC postupka koji je od tada postao standard u obradi audio signala
Dhingra et al., 2019	<i>Review of MFCC in speech and audio processing applications</i>	Pregledni rad o primeni MFCC obeležja u prepoznavanju govora i audio obradi u prisustvu šuma	Potvrđena robusnost MFCC obeležja pri različitim nivoima zašumljenosti signala
Majeed et al., 2023	<i>Mel frequency cepstral coefficient and its applications: a review</i>	Sveobuhvatan pregled primene MFCC u prepoznavanju muzičkih žanrova, medicinskoj dijagnostici i bioakustici	Potvrđena svestranost MFCC tehnike van domena govora
Erdal Ozbek et al., 2024	<i>Enhancing audio classification through MFCC feature extraction and data augmentation with CNN and RNN models</i>	Kombinovanje MFCC obeležja sa augmentacijom podataka i CNN/RNN arhitekturama radi otpornosti na šum	Poboljšane performanse klasifikacije u kompleksnim, zašumljenim audio okruženjima

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
1 Farbod & Karthikeyan, 2023	<i>Multi-modal vehicle classification using CNN and MFCC feature sets</i>	Primena MFCC obeležja i CNN modela na klasifikaciju vozila na osnovu zvuka motora	Potvrđena sposobnost MFCC da izdvoji distinktivna obeležja u zadacima ekološkog monitoringa zvuka
50 LeCun et al., 1998	<i>Gradient-based learning applied to document recognition</i>	Formalizacija konvolucione neuronske mreže kao arhitekture za hijerarhijsko izdvajanje vizuelnih obeležja	Postavljeni temelji savremenih pristupa vizuelnom, a kasnije i audio učenju obeležja
57 Piczak, 2015	<i>Environmental sound classification with convolutional neural networks</i>	Primena CNN modela nad spektrogramima za klasifikaciju zvukova iz okruženja	Demonstrirana snažna efikasnost CNN arhitekture u audio klasifikaciji
1 Yin et al., 2019	<i>Speech emotion recognition based on optimized CNN parameters</i>	Primena CNN modela sa podešenim hiperparametrima na prepoznavanje emocija u govoru	Poboljšane performanse klasifikacije emocija u odnosu na modele sa nepodešenim hiperparametrima
1 Zhang et al., 2022	<i>A deep CNN-based acoustic model for the identification of sound events</i>	Primena dubokih CNN arhitektura na identifikaciju zvučnih događaja visoke tačnosti	Potvrđena skalabilnost CNN pristupa na kompleksne zadatke klasifikacije zvuka
36 Xie et al., 2023	<i>A review of automatic recognition technology for bird vocalizations in the deep learning era</i>	Sveobuhvatan pregled tehnika dubokog učenja primenjenih na prepoznavanje ptičjih zova	Sistematizovan razvoj oblasti, od klasičnih ka savremenim pristupima automatskog prepoznavanja vrsta
24 Clark et al., 2023	<i>The effect of soundscape composition on bird vocalization classification in a citizen science biodiversity monitoring project</i>	Analiza uticaja prisustva drugih zvučnih izvora u okruženju na tačnost klasifikacije zova ptica	Pokazano da sastav zvučnog pejzaža značajno utiče na pouzdanost klasifikacije u projektima građanske nauke

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Jarrett & Willis, 2025	<i>Acoustic detection rate can outperform traditional survey approaches in estimating relative densities of breeding waders</i>	Poređenje akustičke detekcije sa tradicionalnim terenskim popisivanjem gnezdećih populacija ptica močvarica	Akustička detekcija nadmašila tradicionalne metode u proceni relativne gustine populacija
Wei et al., 2024	<i>Advanced montane bird monitoring using self-supervised learning and transformer on passive acoustic data</i>	Primena samonadgledanog učenja i transformer arhitekture na praćenje planinskih vrsta ptica	Unapređeno praćenje vrsta u zahtevnim, planinskim akustičkim uslovima
Funosas et al., 2024	<i>Assessing the potential of BirdNET to infer European bird communities from large-scale ecoacoustic data</i>	Evaluacija modela BirdNET nad velikim ekoakustičkim skupovima podataka evropskih zajednica ptica	Potvrđena pouzdanost BirdNET modela u zaključivanju o sastavu zajednica ptica
LeBien et al., 2020	<i>A pipeline for identification of bird and frog species in tropical soundscape recordings using a convolutional neural network</i>	Razvoj CNN cevovoda za identifikaciju vrsta ptica i žaba u tropskim zvučnim pejzažima	Uspostavljen efikasan pristup za automatsku identifikaciju vrsta u kompleksnim tropskim staništima
Pahuja & Kumar, 2021	<i>Sound-spectrogram based automatic bird species recognition using MLP classifier</i>	Klasifikacija vrsta ptica na osnovu spektrogramskih obeležja primenom višeslojnog perceptrona	Potvrđena izvodljivost ranijih, jednostavnijih arhitektura za prepoznavanje vrsta
Sanchez et al., 2021	<i>Bioacoustic classification of avian calls from raw sound waveforms with an open-source deep learning architecture</i>	Primena dubokog učenja direktno nad sirovim zvučnim talasnim oblicima, bez ručnog izdvajanja obeležja	Otvoren pristup klasifikaciji ptičjih zova bez oslanjanja na predobradu poput MFCC
Van Doren et al., 2024	<i>Nighthawk: acoustic monitoring of nocturnal bird migration in the Americas</i>	Razvoj sistema za akustičko praćenje noćne migracije ptica na širokom geografskom području	Omogućeno kontinuirano, automatizovano praćenje migratornih obrazaca

3.2. Istraživanja u oblasti EEG analize i neurodijagnostike epilepsije

Primena veštačke inteligencije u analizi EEG signala razvijala se od klasičnih algoritama mašinskog učenja, poput klasifikatora zasnovanih na metodi potpornih vektora (*Support Vector Classifier*, SVC), ka savremenim arhitekturama dubokog učenja, sposobnim da direktno modeluju sekvencijalnu i nelinearnu prirodu moždane aktivnosti.

Tabela 2. Pregled istraživanja u oblasti EEG analize i neurodijagnostike epilepsije

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Acharya et al., 2013	<i>Automated EEG analysis of epilepsy: A review</i>	Pregled tehnika obrade signala primenjenih na automatsku analizu EEG zapisa kod epilepsije	Potvrđena korisnost analitičkih metoda kao pomoćnog alata, uz prostor za dalje unapređenje
Kaur et al., 2021	<i>Artificial intelligence in epilepsy</i>	Pregled primene veštačke inteligencije u dijagnostici epilepsije	Potvrđen potencijal VI za brže i preciznije tumačenje EEG zapisa i ranije prepoznavanje atipične aktivnosti
Rasheed et al., 2021	<i>Machine learning for predicting epileptic seizures using EEG signals: A review</i>	Sistematski pregled modela mašinskog učenja za predviđanje epileptičnih napada	Sumirane prednosti i ograničenja postojećih pristupa, bez isticanja univerzalno superiornog rešenja
Abbasi & Goldenholz, 2019	<i>Machine learning applications in epilepsy</i>	Pregled primena klasifikacionih algoritama, uključujući klasifikatore zasnovane na potpornim vektorima (SVC), u dijagnostici epilepsije	SVC modeli ostvarili tačnost od oko 86%, dok su neimadžing dijagnostički pristupi postizali tačnost 80-86%
Paldino et al., 2014	<i>Independent contribution of individual white matter pathways to language function in pediatric epilepsy patients</i>	Primena modela slučajne šume za predviđanje jezičkih deficita na osnovu traktografije difuzionog tenzorskog snimanja kod pedijatrijskih pacijenata	Ostvarena osetljivost od 100% i specifičnost od 95,4%, uz ograničenja indirektno prirode traktografije

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Qamar et al., 2025	<i>Deep learning in intracranial EEG for seizure detection: Advances, challenges, and clinical applications</i>	Pregled arhitektura dubokog učenja (CNN, LSTM, transformer, hibridni modeli) primenjenih na detekciju napada u intrakranijalnom EEG-u	Ukazano da hibridni i attention modeli unapređuju generalizaciju nezavisnu od pacijenta
Lyu, 2026	<i>Deep learning approaches for EEG-based healthcare applications: A comprehensive review</i>	Sveobuhvatan pregled primena dubokog učenja u EEG zdravstvenim aplikacijama	Potvrđen trend ka hibridnim i attention-potpomognutim arhitekturama u odnosu na jednostruke modele
Kashefi Amiri et al., 2025	<i>Epileptic seizure detection from EEG signals based on 1D CNN-LSTM deep learning model using discrete wavelet transform</i>	Kombinacija 1D CNN-LSTM modela sa diskretnom wavelet transformacijom u predobradi EEG signala	Postignuta visoka tačnost klasifikacije napada na javno dostupnim EEG skupovima podataka

3.3. Istraživanja u oblasti primene metaheurističke optimizacije na modele dubokog učenja

Podešavanje hiperparametara modela dubokog učenja prepoznato je kao NP-težak problem, usled čega su metaheuristički algoritmi sve više prihvaćeni kao praktično rešenje. Sledeća istraživanja ilustruju raznovrsnost primena ovog pristupa, uključujući i domene direktno srodne problemima razmatranim u ovoj disertaciji.

Tabela 3. Pregled istraživanja u oblasti primene metaheurističke optimizacije na modele dubokog učenja

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Nassif et al., 2019	<i>Speech emotion recognition using convolutional neural networks</i>	Primena metaheurističke optimizacije hiperparametara CNN modela u zadatku prepoznavanja emocija u govoru	Postignuto efikasno podešavanje hiperparametara uz smanjenje računskog opterećenja, bez značajnog gubitka tačnosti

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Inik, 2025	<i>SwarmCNN: an efficient method for CNN hyperparameter optimization using PSO and ABC metaheuristic algorithms</i>	Podešavanje hiperparametara CNN modela kombinacijom PSO i ABC algoritama	Potvrđena efikasnost roj-zasnovanih metaheuristika u podešavanju CNN arhitektura
Tasic et al., 2025	<i>Waste classification using convolutional neural networks tuned by modified metaheuristics algorithm</i>	Klasifikacija otpada primenom CNN modela čiji su hiperparametri podešeni modifikovanom metaheuristikom	Poboljšane performanse klasifikacije u odnosu na CNN sa podrazumevanim hiperparametrima
Padmavathi & Ganesan, 2025	<i>Metaheuristic optimizers integrated with vision transformer model for severity detection and classification via multimodal COVID-19 images</i>	Integracija metaheurističkih optimizatora sa vision transformer modelom za procenu težine bolesti na medicinskim snimcima	Potvrđena primenljivost metaheuristika i van klasičnih CNN arhitektura
Villoth et al., 2025	<i>Two-tier deep and machine learning approach optimized by adaptive multi-population firefly algorithm for software defects prediction</i>	Dvoslojni okvir (CNN + ansambl klasifikatori) optimizovan modifikovanim algoritmom svica za predikciju softverskih defekata	Potvrđena efikasnost dvoslojne arhitekture i FA optimizacije, analogne pristupu primenjenom u ovoj disertaciji
Jovanovic et al., 2023	<i>Anomaly detection in ECG using recurrent networks optimized by modified metaheuristic algorithm</i>	Detekcija anomalija u EKG signalima primenom rekurentnih mreža optimizovanih modifikovanom metaheuristikom	Potvrđena primenljivost metaheuristički optimizovanih rekurentnih mreža na fiziološke vremenske serije
Viswanathan & Ravichandran, 2025	<i>Gain-based green ant colony optimization for 3D path planning on remote sensing images</i>	Primena energetske svesne varijante algoritma kolonije mrava na trodimenzionalno planiranje putanje	Potvrđena primenljivost roj-zasnovanih metaheuristika na kontinualne, prostorne probleme

Naziv autora	Naziv rada	Opis istraživanja	Rezultat istraživanja
Ozcalci & Kilic, 2025	<i>GA-LDA approach for topic modeling in Turkish accounting and finance articles</i>	Kombinacija genetskog algoritma sa latentnom Dirihleovom alokacijom za modelovanje tema u tekstu	Potvrđena fleksibilnost genetskog algoritma u diskretnim, tekstualnim reprezentacijama

3.4. Kritički osvrt na postojeća istraživanja

Pregled sprovedenih istraživanja ukazuje na nekoliko sistematskih ograničenja. U oblasti bioakustičke klasifikacije, MFCC, CNN i metaheuristička optimizacija pojedinačno su dobro istraženi, ali njihova kombinacija gotovo se isključivo primenjuje u zadacima usmerenim na čoveka, poput prepoznavanja govora ili emocija, dok je primena na klasifikaciju zova ptica, a naročito na blisko srodne vrste koje dele isto stanište, ostala uglavnom neistražena. Dodatno, u pregledanim studijama zamena završnog, potpuno povezanog sloja CNN arhitekture snažnijim ansambl klasifikatorima retko je kombinovana sa metaheurističkom optimizacijom oba nivoa hibridnog okvira, iako srodna istraživanja iz oblasti predikcije softverskih defekata (J. P. Villioth et al., 2025) ukazuju na potencijal ovakvog pristupa. Nijedno od pregledanih istraživanja ne primenjuje modifikovan VNS algoritam, niti bilo koju varijantu koja eksplicitno kombinuje mehanizme promenljivog susedstva sa dodatnim mehanizmom pretrage poput FA algoritma, za potrebe podešavanja hiperparametara ovakvog dvoslojnog okvira.

U oblasti neurodijagnostike, pregledana istraživanja pokazuju jasan pomak od klasičnih algoritama mašinskog učenja, ograničenih nesposobnošću da modeluju sekvencijalne zavisnosti, ka arhitekturama dubokog učenja, uključujući CNN, LSTM i hibridne, pažnjom potpomognute (*attention-based*) modele. Ipak, ove arhitekture po pravilu oslanjaju se na veće mreže i duže režime obučavanja, retko uključuju sistematičnu fazu optimizacije hiperparametara, i gotovo nijedno pregledano istraživanje ne razmatra GRU arhitekturu, iako ona, u poređenju sa LSTM-om, nudi jednostavniju strukturu uz zadržavanje sposobnosti modelovanja dugoročnih vremenskih zavisnosti. Primena PSO algoritma, a naročito njegove modifikovane varijante svesne raznovrsnosti populacije, na podešavanje GRU hiperparametara u kontekstu EEG detekcije anomalija, do sada nije razmatrana u pregledanoj literaturi.

Konačno, iako je metaheuristička optimizacija uspešno primenjena u brojnim, međusobno vrlo različitim domenima, poput predikcije softverskih defekata, detekcije anomalija u EKG signalima, planiranja putanje i modelovanja tema u tekstu, ova raznovrsnost primena ukazuje na opštu primenljivost pristupa, ali istovremeno otkriva da modifikacije usmerene na eksplicitno regulisanje odnosa eksploracije i eksploatacije, poput onih predloženih u ovoj disertaciji (IAVNS i DADPSO), ostaju retko zastupljene, a njihova primena na bioakustičku klasifikaciju i EEG analizu anomalija do sada nije bila predmet sistematskog istraživanja. Upravo ovaj dvostruki nedostatak, kako u pogledu specifičnih primena, tako i u pogledu samih metaheurističkih modifikacija, predstavlja osnovu i opravdanje istraživanja sprovedenog u ovoj disertaciji.

4. Metodologija naučnog doprinosa rada


Za razliku od prethodnog poglavlja, u kome je sistematizovana i kritički sagledana postojeća literatura, ovo poglavlje fokusira se isključivo na originalan naučni doprinos ove disertacije. Predstavljena su dva predložena hibridna okvira za klasifikaciju kompleksnih signalnih podataka, kao i dva modifikovana metaheuristička algoritma razvijena za potrebe podešavanja njihovih hiperparametara: iteraciono svestan VNS algoritam (IAVNS), namenjen optimizaciji dvoslojnog okvira za klasifikaciju zova ptica, i dinamički prilagodljiv PSO algoritam svestan raznovrsnosti populacije (DADPSO), namenjen optimizaciji GRU modela za detekciju anomalija u EEG signalima.

4.1. Predloženi dvoslojni hibridni okvir za klasifikaciju zova ptica

Predloženi okvir za klasifikaciju zova ptica strukturiran je kao dvoslojni sistem učenja, u kome se konvoluciona neuronska mreža i ansambl klasifikatori zasnovani na pojačavanju gradijenta kombinuju u jedinstven optimizacioni proces (Dogandzic, Zivkovic, et al., 2026). U prvom sloju, hiperparametri CNN klasifikatora, koji obrađuje spektrogramske reprezentacije zova ptica, kodirani su kao parametri kandidat-rešenja unutar populacije metaheurističkog algoritma, a optimizacija se sprovodi iterativnim ažuriranjem, obučavanjem i evaluacijom modela sve dok se ne dostigne kriterijum konvergencije. Nakon što je pronađena optimalna konfiguracija CNN mreže, njen završni, potpuno povezani izlazni sloj se uklanja, a izdvojene, hijerarhijski naučene reprezentacije obeležja prosleđuju se u drugi sloj okvira.

U drugom sloju, obeležja izdvojena konvolucionom mrežom koriste se kao ulaz za ansambl klasifikatore zasnovane na pojačavanju gradijenta, CatBoost i LightGBM, čiji su hiperparametri, na isti način kao i kod CNN sloja, kodirani kao parametri jedinki unutar populacije i podvrgnuti dodatnoj metaheurističkoj optimizaciji. Na ovaj način se konačna klasifikacija ne prepušta standardnom izlaznom sloju CNN arhitekture, već robusnijim, nezavisno optimizovanim ansambl klasifikatorima, koji nad ovako pripremljenim obeležjima po pravilu ostvaruju bolje rezultate. Šematski prikaz ovog hijerarhijskog optimizacionog procesa prikazan je na Slika 1.

Predloženi okvir projektovan je modularno, tako da svaka njegova komponenta može funkcionisati nezavisno, a optimizacioni mehanizam nije ograničen na jedan metaheuristički algoritam, već može ugraditi i alternativne optimizatore, što je iskorišćeno i u eksperimentalnoj fazi ovog istraživanja radi poređenja predložene modifikacije sa više savremenih metaheuristika.



Slika 1. Dijagram toka predloženog dvoslojnog okvira

4.2. Modifikovani algoritam pretrage promenljivog susedstva (IAVNS)

Osnovna varijanta VNS algoritma predstavlja snažan optimizator, ali, poput drugih metaheurističkih metoda, poseduje određena ograničenja. Opsežne simulacije nad skupovima *benchmark* funkcija pokazale su da, iako VNS ispoljava snažnu sposobnost eksploracije, u kasnijim iteracijama mu nedostaje dovoljna snaga eksploatacije, upravo u fazi u kojoj bi pretraga trebalo da se usmeri na finije rafiniranje rešenja unutar već identifikovanih, obećavajućih regiona prostora pretrage. Da bi se ovo ograničenje otklonilo, u ovoj disertaciji predložena je integracija postupka pretrage svojstvenog FA (*Firefly Algorithm*) algoritmu (Yang & Slowik, 2020), poznatog po snažnim performansama eksploatacije.

Na početku izvršavanja, rešenja se ažuriraju standardnim VNS postupkom pretrage, opisanim jednačinama (18)-(20). Kako izvršavanje algoritma napreduje, eksploatacija se dodatno pojačava primenom postupka pretrage preuzetog iz FA algoritma, definisanog jednačinom (28):

$$X_i^{t+1} = X_i^t + \beta_0 \cdot e^{-\gamma r_{ij}^2} (X_j^t - X_i^t) + \alpha^t (\kappa - 0.5) \quad (28)$$

U okviru ove jednačine, X_i^t i X_j^t označavaju pozicije jedinke (*firefly*) i i „svetlije“ jedinke (*brighter firefly*) j (sa boljom vrednošću funkcije cilja) u iteraciji t . Jedinka i se kreće

ka jedinki j , vođena privlačnošću i međusobnim rastojanjem. Početna privlačnost na rastojanju $r = 0$ data je parametrom β_0 , po pravilu ograničenim na interval $[0, 1]$, koji određuje koliko snažno se jedna jedinka (svica) privlači ka drugoj kada su međusobno veoma blizu. Rastojanje između jedinki i i j predstavlja Euklidsko rastojanje $r_{i,j}$, koje utiče na privlačnost koja eksponencijalno opada sa kvadratom rastojanja, pri čemu koeficijent apsorpcije svetlosti γ kontroliše brzinu tog opadanja. Parametar α uvodi nasumičnost radi izbegavanja prevremene konvergencije, dok je κ slučajna promenljiva sa Gausovom raspodelom, koja obezbeđuje simetričnost perturbacija oko nule. Na ovaj način, jednačina (28) omogućava FA algoritmu da uspešno uravnoteži eksploataciju, odnosno kretanje ka svetlijim jedinkama, i eksploraciju, odnosno nasumičnu pretragu.

Naizmenična primena ova dva postupka pretrage tokom kasnijih faza izvršavanja algoritma regulisana je parom novouvedenih kontrolnih parametara. Prvi parametar, parametar promenljive pretrage vs , određuje trenutak u kome modifikovana metaheuristika počinje naizmenično da primenjuje VNS i FA mehanizme pretrage. Kada je zadovoljen uslov $t > vs$, algoritam počinje naizmenično da primenjuje oba postupka pretrage. Vrednost vs određena je empirijski kao $\text{round}(maxIter/3)$, što u sprovedenim simulacijama iznosi 3, s obzirom na to da je $maxIter = 8$.

Drugi kontrolni parametar, parametar režima pretrage sm , na nivou svake pojedinačne jedinke određuje da li će se u datoj iteraciji primeniti VNS ili FA pretraga. Svaka jedinka u populaciji generiše slučajan broj rnd na intervalu $[0, 1]$. Ukoliko je $rnd < sm$, jedinka nastavlja VNS pretragu, u suprotnom primenjuje FA pretragu. Vrednost ovog parametra opada tokom iteracija, čime se u kasnijim fazama pretrage postepeno naglašava FA mehanizam, u trenutku kada je metaheuristika već dovoljno konvergirala. Početna vrednost $sm = 0,8$ određena je empirijski, i smanjuje se tokom iteracija prema jednačini (29):

$$sm_t = sm_{t-1} - \frac{sm_{t-1}}{10} \quad (29)$$

Ovako modifikovana varijanta VNS metaheuristike naziva se iteraciono svestan VNS (*Iteration Aware VNS*, IAVNS), s obzirom na to da algoritam prilagođava sopstveno ponašanje u zavisnosti od trenutne iteracije. Pseudokod koji sumira funkcionisanje IAVNS-a je predstavljen u Algoritmu 1.

Postupak algoritma može se sumirati na sledeći način: nakon inicijalizacije populacije, u svakoj iteraciji se za svaku jedinku proverava da li je zadovoljen uslov $t < vs$; ako jeste, primenjuje se standardna VNS pretraga; ako uslov nije zadovoljen, generiše se slučajan broj koji, u zavisnosti od vrednosti sm , određuje da li će se primeniti VNS ili FA pretraga. Postupak se ponavlja do ispunjenja kriterijuma zaustavljanja, nakon čega se vraća jedinka sa najboljom vrednošću funkcije cilja.

Algoritam 1. Pseudokod IAVNS metaheuristike

Algoritam 1: IAVNS pseudokod

```

Generiši početni skup jedinki ( $X$ )
dok  $t < \text{maxIter}$  radi
    izračunaj vrednost funkcije cilja za svaku jedinku
    za svaku jedinku iz  $X$  radi
        ako  $t < \text{vs}$  onda
            izvrši VNS pretragu prema jednačinama (18), (19) i (20)
        suprotno
            ako  $\text{rnd} < \text{sm}$  onda
                izvrši VNS pretragu prema jednačinama (18), (19) i (20)
            suprotno
                izvrši FA pretragu prema jednačini (28)
        kraj ako
    kraj ako
kraj za
kraj dok
vрати jedinku sa najboljom vrednošću funkcije cilja
    
```

Budući da predložena modifikacija ne uvodi dodatna izračunavanja funkcije cilja (*fitness function evaluations*, FFEs) u odnosu na baznu verziju algoritma, računaska složenost IAVNS ostaje identična složenosti originalnog VNS algoritma, izražena kao $O(N \times T \times k_{\max})$, gde N predstavlja broj kandidat-rešenja, T broj iteracija, a $k_{\max}$ broj razmatranih struktura susedstva.

4.3. Predloženi GRU okvir za detekciju anomalija u EEG signalima

Za razliku od okvira predloženog za klasifikaciju zova ptica, koji je dvoslojan, okvir predložen za detekciju anomalija u EEG signalima zasniva se na jedinstvenoj GRU arhitekturi, čija je matematička formulacija (kapija ažuriranja, kapija resetovanja, kandidat skrivenog stanja i konačno skriveno stanje) detaljno opisana u poglavlju posvećenom teorijskim osnovama ove disertacije (Dogandzic, Bacanin, et al., 2026). Hiperparametri GRU modela, uključujući stopu učenja, stopu isključivanja neurona, broj epoha, broj GRU slojeva i broj neurona po sloju, kodirani su kao parametri kandidat-rešenja unutar populacije, a njihovo podešavanje sprovedeno je primenom modifikovanog PSO algoritma predloženog u ovoj disertaciji, opisanog u narednom potpoglavlju.

Osim optimizacije hiperparametara, dizajn predloženog okvira obuhvata i dodatne mehanizme koji doprinose stabilnosti treniranja i kvalitetu ulaznih podataka. Ulazna sekvenca modela formirana je na osnovu unapred definisanog broja lagova, odnosno prethodnih

vremenskih koraka signala koji se koriste za predikciju trenutnog stanja, čime se GRU arhitekturi omogućava da uhvati kratkoročne vremenske zavisnosti karakteristične za EEG aktivnost. Dodatno, ulazni podaci se pre treniranja normalizuju, čime se ublažavaju razlike u amplitudi između pojedinačnih segmenata i doprinosi bržoj i stabilnijoj konvergenciji tokom optimizacionog procesa.

4.4. Modifikovani algoritam optimizacije rojem čestica svestan raznovrsnosti populacije (DADPSO)

Standardni PSO algoritam i dalje predstavlja snažan optimizacioni alat u brojnim savremenim primenama. Ipak, njegova sposobnost eksploracije po pravilu opada tokom kasnijih iteracija, što može dovesti do smanjene efikasnosti pretrage. Da bi se ovo ograničenje otklonilo, modifikovani PSO algoritam predložen u ovoj disertaciji integriše mehanizam kojim se eksplicitno reguliše raznovrsnost populacije. Visoka raznovrsnost korisna je u početnim fazama pretrage, omogućavajući širu eksploraciju, dok bi u kasnijim fazama algoritam trebalo postepeno da se usmeri ka koncentrisanijoj eksploataciji. Sledeći ovaj princip, predložena varijanta dinamički prilagođava raznovrsnost, podstičući eksploraciju u ranim fazama i pojačavajući intenzifikaciju kako pretraga napreduje.

Raznovrsnost populacije kvantifikovana je L_1 normom (Cheng & Shi, 2011), koja odražava stepen rasprostranjenosti kandidat-rešenja duž dimenzija prostora pretrage. Ukoliko N predstavlja broj rešenja, a D dimenzionalnost problema, mera raznovrsnosti L_1 izračunava se prema sledećim jednačinama (30)-(32):

$$\bar{x}_j = \frac{1}{N} \sum_{i=1}^N x_{ij} \quad (30)$$

$$Dv_j^p = \frac{1}{N} \sum_{i=1}^N |x_{ij} - \bar{x}_j| \quad (31)$$

$$Dv^p = \frac{1}{D} \sum_j Dv_j^p = 1^D Dv_j^p \quad (32)$$

gde $\bar{x}_j$ predstavlja srednju poziciju svih jedinki u dimenziji j , a Dv_j^p predstavlja izračunatu vrednost raznovrsnosti za tu dimenziju. Na početku izvršavanja algoritma raznovrsnost bi trebalo da bude relativno visoka, a zatim postepeno da opada kako pretraga napreduje. Da bi se ovakav obrazac podstakao, modifikovani PSO uvodi dinamički prag (*threshold*) Dv_t , kojim se ograničava prihvatljiv opseg raznovrsnosti. Kad god je u nekoj iteraciji zadovoljen uslov $Dv_p < Dv_t$, deo populacije se ponovo generiše.

Za sprovođenje ove strategije uveden je dodatni parametar, NRS , kojim se određuje broj najlošije rangiranih rešenja koja se zamenjuju novogenerisanim kandidatima kad god raznovrsnost populacije padne ispod propisanog praga. U preliminarnim eksperimentima testirane su vrednosti $NRS \in \{1, 2, 3, 4\}$, uz istu veličinu populacije od šest jedinki kao i u

glavnim eksperimentima. Rezultati su pokazali da $NRS = 1$ regeneriše premali broj jedinki da bi se efikasno obnovila raznovrsnost populacije nakon što Dv_p padne ispod praga. Sa druge strane, vrednosti $NRS \geq 3$ zamenjuju najmanje polovinu relativno male populacije u jednom koraku, čime se narušavaju akumulisane informacije o pretrazi i usporava konvergencija. Podešavanje $NRS = 2$ pokazalo se kao najpovoljniji kompromis, jer obnavlja raznovrsnost populacije uz očuvanje dve trećine postojećeg roja. Zbog toga je vrednost $NRS = 2$ usvojena u svim narednim eksperimentima. Ova preliminarna ispitivanja korišćena su kao korak selekcije parametara, dok su sva glavna poređenja u 30 nezavisnih pokretanja sprovedena sa $NRS = 2$. Shodno tome, izabrana vrednost smatra se odgovarajućom za usvojenu veličinu populacije od šest čestica, ali se ne tvrdi da je univerzalno optimalna za druge veličine populacije ili druge optimizacione probleme. Početni prag Dv_{t0} izračunava se prema jednačini (33):

$$Dv_{t0} = \sum_{j=1}^{NP} \frac{(ub_j - lb_j)}{2 \cdot NP} \quad (33)$$

a zatim se ova vrednost ažurira u svakoj iteraciji prema jednačini (34):

$$Dv_{t+1} = Dv_t - Dv_t \cdot \frac{t}{T} \quad (34)$$

gde t označava tekuću iteraciju, a T ukupan broj iteracija. Usled ovoga, Dv_t se postepeno smanjuje tokom izvršavanja algoritma, čime se pretraga postepeno usmerava ka intenzivnijoj eksploataciji. Ovaj mehanizam je minimalne računске složenosti i ne uvodi dodatno vremensko ili memorijsko opterećenje. Ovako unapređeni pristup nazvan je *Diversity-Aware Dynamic PSO* (DADPSO), a njegov pseudokod dat je u Algoritmu 2.

Algoritam 2. Pseudokod DADPSO metaheuristike

Algoritam 2: DADPSO pseudokod
Generiši početnu populaciju (P) izračunaj Dv_{t0} i inicijalizuj Dv_t dok $t \leq T$ radi izvrši standardnu PSO pretragu izračunaj fitnes vrednost svih jedinki u P ako $Dv_p < Dv_t$ onda zameni NRS najlošijih jedinki u P novogenerisanim kandidatima kraj ako ažuriraj Dv_t kraj dok vрати jedinku sa najvećom fitnes vrednošću

Postupak algoritma sumira se na sledeći način: nakon generisanja početne populacije i izračunavanja početnog praga Dv_{t0} , u svakoj iteraciji sprovodi se standardna PSO pretraga, nakon čega se evaluira funkcija cilja svih kandidata; ukoliko je zadovoljen uslov $Dv^p < Dv_t$, najlošije rangiranih *NRS* jedinki zamenjuje se novogenerisanim kandidatima; prag Dv_t se potom ažurira, a postupak ponavlja do ispunjenja kriterijuma zaustavljanja, nakon čega se vraća jedinka sa najvišom vrednošću funkcije cilja.

5. Metodologija istraživanja

U ovom poglavlju opisuje se eksperimentalna provera oba doprinosa predstavljena u poglavlju 4, dvoslojnog CNN-CatBoost/LightGBM okvira optimizovanog algoritmom IAVNS za klasifikaciju vrsta ptica na osnovu audio signala (Dogandzic, Zivkovic, et al., 2026) i GRU modela optimizovanog algoritmom DADPSO za detekciju anomalija u EEG signalima (Dogandzic, Bacanin, et al., 2026). Za svaki doprinos detaljno se opisuju korišćeni skup podataka, priprema podataka, eksperimentalno okruženje, podešavanje hiperparametara, dobijeni rezultati i njihova statistička validacija, kao i poređenje sa alternativnim metaheurističkim algoritmima.


5.1. Eksperimentalna provera okvira za klasifikaciju vrsta ptica

U okviru ovog potpoglavlja detaljno se opisuje eksperimentalna provera predloženog dvoslojnog CNN-CatBoost/LightGBM okvira za klasifikaciju zova ptica, optimizovanog algoritmom IAVNS (Dogandzic, Zivkovic, et al., 2026). Najpre se predstavljaju korišćeni skup podataka i postupak pripreme podataka, nakon čega sledi opis eksperimentalnog okruženja i podešenih hiperparametara za svaki od tri modela uključena u okvir (CNN, CatBoost i LightGBM). Potom se prikazuju i analiziraju rezultati simulacije za svaki od tri modela ponaosob, kao i sveobuhvatna analiza performansi i statistička validacija dobijenih rezultata u odnosu na alternativne metaheurističke algoritme. Na kraju, sprovedena je interpretacija najuspešnijeg dobijenog modela primenom SHAP metode, kako bi se objasnio uticaj pojedinačnih obeležja na konačnu klasifikacionu odluku modela.

5.1.1. Opis skupa podataka i priprema podataka

Istraživanje je sprovedeno na javno dostupnom skupu podataka koji sadrži audio-snimke 114 vrsta ptica, dostupnom na platformi *Kaggle* (<https://www.kaggle.com/datasets/soumendraprasad/sound-of-114-species-of-birds-till-2022>). Zbog velikih računskih zahteva eksperimenata, analiza je ograničena na šest vrsta ptica: andski gvan (*Andean guan*), Bartletov tinamu (*Bartlett's tinamou*), bradati gvan (*bearded guan*), plavogrli gvan (*blue-throated piping guan*), Kauka gvan (*Cauca guan*) i talasasti tinamu (*undulated tinamou*). Ove vrste nisu odabrane nasumično, već zato što dele isti geografski stanišni prostor u Južnoj Americi, što ih čini ekološki relevantnim za zajedničko praćenje. U

praksi, razlikovanje vrsta koje se nikada ne javljaju na istom području imalo bi ograničenu praktičnu vrednost za praćenje biodiverziteta. Shodno tome, istraživanje demonstrira pogodnost metode za praćenje specifično po staništu, a ne kao univerzalni klasifikator svih 114 vrsta. Spektrogramski uzorci koji odgovaraju posmatranim vrstama ptica prikazani su na Slika 2.



Slika 2. Primeri spektrograma za posmatrane vrste ptica

Modeli su validirani osnovnim skupom metrika: tačnošću (*accuracy*), preciznošću (*precision*), osetljivošću (*sensitivity/recall*) i F1-merom (*f1-measure*). Matthews-ov koeficijent korelacije (MCC) odabran je kao funkcija cilja koju je potrebno maksimizovati, s obzirom na to da MCC posebno dobro odražava kvalitet klasifikacije kod neuravnoteženih skupova podataka, jer za razliku od sirove tačnosti uzima u obzir sve četiri komponente matrice konfuzije i ravnomerno nagrađuje tačnu klasifikaciju svih klasa, ne favorizujući većinske klase. Pored MCC, praćena je i greška klasifikacije ($1 - \text{tačnost}$), korišćena kao indikator funkcija tokom eksperimenata.

5.1.2. Eksperimentalno okruženje i podešavanje hiperparametara

U prvom sloju predloženog okvira optimizovani su hiperparametri CNN modela. Tabela 4 prikazuje opsege pretrage za stopu učenja (*learning rate*), *dropout*, broj epoha, broj CNN slojeva, broj potpuno povezanih (*dense*) slojeva i broj neurona po sloju. Preostali parametri CNN modela fiksirani su na sledeće vrednosti: ciljna veličina (*target size*) slike (32×32), veličina *batch*-a 512, RGB režim boja i kategorički režim klase (*class mode*).

Tabela 4. Opsezi pretrage hiperparametara CNN modela

Hyperparameter	Limit (low)	Limit (high)
Learning rate	0.0001	0.003
Dropout	0.05	0.2
Epochs	100	300
CNN layers	1	2
Dense layers	1	2
Neurons per layer	32	128

Međurezultati (*intermediate outputs*) CNN modela prosleđeni su drugom sloju okvira. Ovi rezultati/izlazi prikupljeni su tokom procesa CNN klasifikacije za svaki uzorak iz skupa podataka, a zatim podeljeni na novi skup od 70% za obuku i 30% za testiranje, koji je korišćen za optimizaciju CatBoost i LightGBM modela. Tabela 5 prikazuje opsege pretrage hiperparametara CatBoost modela (stopa učenja, *col sample by level*, *subsample*, broj iteracija, dubina, minimalan broj podataka po listu), dok Tabela 6 prikazuje opsege pretrage hiperparametara LightGBM modela (broj rundi, maksimalna dubina, broj listova, minimalna težina po detetu, *feature fraction*, *bagging fraction*, minimalni *split gain*, λ L_1 i λ L_2 regularizacija, stopa učenja). Ovi hiperparametri odabrani su jer je poznato da imaju najveći uticaj na performanse modela.

Tabela 5. Opsezi pretrage hiperparametara CatBoost modela

Parameter	Limit (low)	Limit (high)
Learning rate	0.001	0.1
Col sample by level (CBL)	0.05	1
Subsample	0.05	1
Iterations	50	100
Depth	1	5
Minimum data in leaf (MDL)	1	10

Tabela 6. Opsezi pretrage hiperparametara LightGBM modela

Parameter	Limit (low)	Limit (high)
Number of rounds	50	100
max depth	5	10
Number of leaves	24	45
min child weight	5	60
Feature fraction	0.1	0.9
Bagging fraction	0.5	1
min split gain	0.001	0.1
λ L_1 (regularization)	0	5
λ L_2 (regularization)	0	3
Learning rate	0.01	0.9

Predloženi algoritam IAVNS korišćen je za podešavanje oba sloja okvira klasifikacije, a njegovi rezultati upoređeni su sa nekoliko snažnih optimizacionih algoritama: osnovnim VNS (*Variable Neighborhood Search*), GA (*Genetic Algorithm*), PSO (*Particle Swarm Optimization*), COA (*Crayfish Optimization Algorithm*), ChOA (*Chimp Optimization Algorithm*), SCHO (*Sinh Cosh Optimizer*) i algoritmom COLSHADE. Svi optimizatori implementirani su sa podrazumevanim podešavanjima preporučenim od strane njihovih autora. U prvom sloju okvira, algoritmi su korišćeni za podešavanje CNN modela sa populacijom od 6 jedinki, 8 iteracija po izvršavanju i 30 nezavisnih izvršavanja. Za optimizaciju CatBoost i LightGBM modela u drugom sloju, algoritmi su ponovo korišćeni sa 6 jedinki, 8 iteracija po izvršavanju, ali sa 15 nezavisnih izvršavanja.

5.1.3. Rezultati simulacije CNN-a prvog sloja

Eksperimentalni rezultati prvog nivoa okvira, gde je CNN podešavan u odnosu na funkciju cilja (maksimizacija MCC vrednosti), prikazani su u Tabela 7. Predloženi IAVNS algoritam postigao je najbolji rezultat, sa MCC vrednošću od 0,598521 u svom najuspešnijem izvršavanju. Stohastička priroda metaheurističkih algoritama vidljiva je u preostalim metrikama, gde su različite metode bile najuspešnije u različitim kategorijama. Najbolji rezultat u najgorem izvršavanju postigao je PSO, sa MCC vrednošću od 0,523017. Najbolje srednje i medijalne vrednosti postigao je GA, dok je najstabilnije rezultate, na šta ukazuju najniže standardno odstupanje i varijansa, postigao elementarni VNS algoritam, koji je, međutim, ostao приметно iza ostalih metaheuristika po relevantnijim metrikama performansi.

Tabela 7. Vrednosti funkcije cilja simulacije CNN-a prvog sloja

Method	Best	Worst	Mean	Median	Std	Var
CNN-IAVNS	0.598521	0.504386	0.5426297	0.524982	0.040405	0.001633
CNN-VNS	0.533274	0.504534	0.5225025	0.529699	0.012789	0.000164
CNN-GA	0.563441	0.507144	0.5427207	0.557577	0.025270	0.000639
CNN-PSO	0.556105	0.523017	0.5373234	0.532848	0.013874	0.000192
CNN-COA	0.553519	0.500482	0.5233732	0.516119	0.022252	0.000495
CNN-ChOA	0.546586	0.494536	0.5250224	0.533946	0.022166	0.000491
CNN-SCHO	0.539225	0.501063	0.5253708	0.535824	0.017244	0.000297
CNN-COLSHADE	0.537300	0.506874	0.5244573	0.529199	0.012866	0.000166

Rezultati funkcije cilja vizuelizovani su pomoću *violin* i *swarm* dijagrama prikazanih na Slika 3. Iako predloženi IAVNS nije proizveo najstabilnije rezultate, metode koje su pokazale veću stabilnost tokom nezavisnih izvršavanja nisu uspele da dostignu ukupno najbolju performansu ostvarenu u najboljem izvršavanju IAVNS-a. Ovo se takođe vidi na *swarm* dijagramu, koji ilustruje raznovrsnost rešenja tokom poslednje iteracije najboljeg izvršavanja svakog algoritma. Dodatne vizualizacije funkcije cilja prikazane su na Slika 4 i jasno ukazuju na snažne konvergentne sposobnosti IAVNS-a tokom njegovog najboljeg izvršavanja, gde je



značajno nadmašio ostale konkurente uprkos tome što je krenuo od nešto slabijih početnih rešenja.

Rezultati indikator funkcije, odnosno greške klasifikacije, prikazani su u Tabela 8. U skladu sa rezultatima funkcije cilja, predloženi IAVNS postigao je najnižu stopu greške od 0,352941. Za preostale metrike, nekoliko algoritama je proizvelo identične rezultate za najgore izvršavanje, GA je postigao najbolju srednju i medijalnu vrednost, dok je najveću stabilnost rezultata, na šta ukazuje najmanje rasipanje (*dispersion*), pokazao SCHO algoritam.



Rezultati indikator funkcije vizuelizovani su pomoću *box plot* dijagrama i *swarm* dijagrama prikazanih na Slika 5. Iako predloženi IAVNS nije dao najstabilnije rezultate indikator funkcije, metode koje su pokazale veću stabilnost tokom nezavisnih izvršavanja nisu uspele da dostignu superiornu najbolju performansu koju je ostvario najbolji IAVNS run. Ovo se takođe vidi na *swarm* dijagramu, koji ilustruje raznovrsnost rešenja tokom poslednje iteracije najboljeg izvršavanja svakog algoritma, gde je IAVNS ostvario najnižu stopu greške klasifikacije među svim evaluiranim metodama. Dodatne vizualizacije rezultata indikator funkcije prikazane su na Slika 6 i jasno ukazuju na snažne konvergentne sposobnosti predloženog IAVNS-a tokom njegovog najboljeg izvršavanja, gde je značajno nadmašio ostale konkurente uprkos tome što je krenuo od nešto slabijih početnih rešenja. Treba naglasiti da stopa greške nije korišćena kao funkcija cilja u simulacijama, već isključivo kao dopunski indikator.

Tabela 9 prikazuje širu evaluaciju najbolje ostvarenih CNN modela po metaheuristici. Čak i posle podešavanja, pojedini CNN modeli imali su poteškoća sa tačnom identifikacijom svih klasa. Na primer, model CNN-COA nije uspešno konvergirao, što je rezultiralo veoma lošom konačnom tačnošću. Radi jasnijeg razumevanja mogućnosti svakog modela, potrebno je razmotriti nekoliko metrika, uključujući preciznost, osetljivost i F1-meru za svaku klasu ponaosob, gde je predloženi CNN-IAVNS model ostvario zadovoljavajuće vrednosti. Što se tiče ukupne tačnosti među svim evaluiranim modelima, predloženi CNN-IAVNS model nadmašio je konkurente, ostvarivši vrednost od 0,647059.

Radi zaokruživanja vizualizacija za eksperimente prvog sloja, Slika 7 prikazuje PR krive zajedno sa matricom konfuzije najbolje ostvarenog modela, koji je u ovom slučaju CNN-IAVNS. Konačno, najbolji skupovi CNN hiperparametara proizvedeni svakim od optimizacionih algoritama prikazani su u **Error! Reference source not found.**, radi omogućavanja replikacije istraživanja, s obzirom na to da su upravo ove CNN konfiguracije proizvele rezultate prikazane u Tabeli 9. Arhitektura najboljeg proizvedenog CNN modela, zajedno sa *tapped* arhitekturom korišćenom za generisanje međurezultata prosleđenih boosting klasifikatorima, prikazana je na Slika 8.



Slika 3. Dijagrami raspodele funkcije cilja i rojeva simulacije CNN-a prvog sloja




Slika 4. Dijagrami konvergencije funkcije cilja simulacije CNN-a prvog sloja

Tabela 8. Vrednosti indikatorske funkcije simulacije CNN-a prvog sloja



Method	Best	Worst	Mean	Median	Std	Var
CNN-IAVNS	0.352941	0.426471	0.397059	0.411765	0.031768	0.001009
CNN-VNS	0.382353	0.411765	0.397059	0.397059	0.012007	0.000144
CNN-GA	0.367647	0.426471	0.387255	0.367647	0.027730	0.000769
CNN-PSO	0.397059	0.411765	0.397059	0.397059	0.012007	0.000144
CNN-COA	0.397059	0.411765	0.411765	0.411765	0.012007	0.000144
CNN-ChOA	0.382353	0.411765	0.392157	0.382353	0.013865	0.000192
CNN-SCHO	0.411765	0.411765	0.406863	0.411765	0.006932	0.000048
CNN-COLSHADE	0.382353	0.411765	0.397059	0.397059	0.012007	0.000144

Tabela 9. Poređenje detaljnih metrika najboljeg optimizovanog modela simulacije CNN-a prvog sloja


Approach	Metric	Andean Guan	Bartlett's tinamou	Bearded Guan	Blue-throated Piping Guan	Cauca Guan	Undulated Timamou	Accuracy	Macro avg	Weighted avg
CNN IAVNS	precision	0.750000	0.800000	0.444444	0.666667	0.388889	1.000000	0.647059	0.675000	0.685539
	recall	0.315789	0.888889	0.333333	1.000000	0.777778	1.000000	0.647059	0.719298	0.647059
	f1-score	0.444444	0.842105	0.380952	0.800000	0.518519	1.000000	0.647059	0.664337	0.627375
CNN VNS	precision	0.416667	0.800000	0.600000	0.666667	0.444444	1.000000	0.617647	0.654630	0.627206
	recall	0.526316	0.888889	0.250000	0.750000	0.444444	1.000000	0.617647	0.643275	0.617647
	f1-score	0.465116	0.842105	0.352941	0.705882	0.444444	1.000000	0.617647	0.635082	0.607331
CNN GA	precision	0.500000	0.692308	1.000000	0.538462	0.400000	1.000000	0.632353	0.688462	0.685860
	recall	0.473684	1.000000	0.250000	0.875000	0.444444	1.000000	0.632353	0.673855	0.632353
	f1-score	0.486486	0.818182	0.400000	0.666667	0.421053	1.000000	0.632353	0.632065	0.610731
CNN PSO	precision	0.750000	0.692308	1.000000	0.411765	0.312500	1.000000	0.602941	0.694429	0.729226
	recall	0.315789	1.000000	0.250000	0.875000	0.555556	1.000000	0.602941	0.666058	0.602941
	f1-score	0.444444	0.818182	0.400000	0.560000	0.400000	1.000000	0.602941	0.603771	0.583648
CNN COA	precision	1.000000	0.095238	0.000000	0.000000	0.116279	0.000000	0.147059	0.201920	0.307407
	recall	0.157895	0.222222	0.000000	0.000000	0.555556	0.000000	0.147059	0.155945	0.147059
	f1-score	0.272727	0.133333	0.000000	0.000000	0.192308	0.000000	0.147059	0.099728	0.119303
CNN ChOA	precision	0.600000	0.727273	0.600000	0.700000	0.266667	0.916667	0.617647	0.635101	0.635717
	recall	0.473684	0.888889	0.250000	0.875000	0.444444	1.000000	0.617647	0.655336	0.617647
	f1-score	0.529412	0.800000	0.352941	0.777778	0.333333	0.956522	0.617647	0.624998	0.606442
CNN SCHO	precision	0.422222	0.000000	0.333333	0.000000	0.454545	1.000000	0.441176	0.368350	0.398723
	recall	1.000000	0.000000	0.250000	0.000000	0.555556	0.272727	0.441176	0.346380	0.441176
	f1-score	0.593750	0.000000	0.285714	0.000000	0.500000	0.428571	0.441176	0.301339	0.351825
CNN COLSHADE	precision	0.294118	0.166667	0.176471	0.000000	0.117647	0.375000	0.205882	0.188317	0.211613
	recall	0.263158	0.111111	0.250000	0.000000	0.222222	0.272727	0.205882	0.186536	0.205882
	f1-score	0.277778	0.133333	0.206897	0.000000	0.153846	0.315789	0.205882	0.181274	0.203218
	support	19	9	12	8	9	11			




53




Slika 6. Dijagrami konvergencije indikatorske funkcije simulacije CNN-a prvog sloja



CNN-IAVNS Call identification of South America Bird Species - PR curve



Slika 7. Matrica konfuzije i PR kriva najboljeg optimizovanog CNN-IAVNS modela simulacije CNN-a prvog sloja



Slika 8. Arhitektura najboljeg dobijenog CNN modela i tapped model korišćen za klasifikatore pojačavanja

Tabela 10. Izbor parametara modela sa najboljim performansama simulacije CNN-a prvog sloja

Approach	lr	d/o	epc	D-L	CNN-L	CNN1	CNN2	DL1	DL2
CNN-IAVNS	3.00e-03	5.00e-02	300	1	1	126	34	128	108
CNN-VNS	2.71e-03	6.45e-02	286	2	1	88	32	71	128
CNN-GA	3.00e-03	2.00e-01	300	1	2	100	108	128	128
CNN-PSO	1.60e-03	5.00e-02	300	1	2	128	32	123	94
CNN-COA	2.42e-03	1.70e-01	298	1	2	103	97	50	54
CNN-ChOA	2.40e-03	2.00e-01	184	1	2	32	66	50	118
CNN-SCHO	2.43e-03	1.49e-01	101	2	2	115	58	52	34
CNN-COLSHADE	1.3e-03	8.77e-02	282	1	1	49	37	99	127

5.1.4. Rezultati simulacije CatBoost algoritma drugog sloja

Eksperimentalni rezultati drugog nivoa okvira, gde je podešavanje CatBoost-a vršeno u odnosu na funkciju cilja (maksimizacija MCC vrednosti), prikazani su u Tabela 11. Predloženi IAVNS algoritam postigao je najbolji rezultat, ostvarivši MCC vrednost od 0,717462 u svom najuspešnijem izvršavanju, zajedno sa nekoliko drugih metaheuristika koje su dostigle isti rezultat. Najbolji rezultat u najgorem izvršavanju svakog algoritma proizveo je SCHO, sa MCC vrednošću od 0,679334. Najbolje srednje i medijalne rezultate ostvario je predloženi IAVNS, dok su najstabilniji rezultati, naznačeni najnižim standardnim odstupanjem i varijansom, proizvedeni od strane SCHO algoritma.

Rezultati funkcije cilja vizuelizovani su kroz *violin* i *swarm* dijagrame prikazane na Slika 9. Iako predloženi IAVNS nije proizveo najstabilnije rezultate u ovom scenariju, konkurenti koji su pokazali veću stabilnost tokom nezavisnih izvršavanja nisu bili u stanju da dostignu superiorne najbolje performanse koje je postigao IAVNS. Ovo zapažanje je takođe vidljivo na *swarm* dijagramu, koji ilustruje raznovrsnost rešenja tokom poslednje iteracije najboljeg izvršavanja svakog algoritma. Dodatne vizualizacije rezultata funkcije cilja prikazane su na Slika 10, jasno demonstrirajući snažne konvergentne sposobnosti predloženog IAVNS metaheuristika tokom njegovog najboljeg izvršavanja, gde je izjednačio najbolje rezultate ostalih konkurenata uprkos tome što je počeo sa početnim rešenjima nižeg kvaliteta.

Rezultati indikator funkcije, odnosno greške klasifikacije, prikazani su u Tabela 12. U skladu sa rezultatima funkcije cilja, predloženi IAVNS postigao je najnižu stopu greške od 0,250000 u ovom scenariju, zajedno sa nekoliko drugih metaheuristika koje su dostigle istu najbolju vrednost. Što se tiče preostalih metrika, nekoliko algoritama proizvelo je identične rezultate za najgore izvršavanje, predloženi IAVNS je ostvario najbolji srednji rezultat, više algoritama je delilo istu medijalnu vrednost, a najveću stabilnost rezultata pokazao je SCHO metaheuristika.

Rezultati indikator funkcije vizuelizovani su kroz *box plot* i *swarm* dijagrame prikazane na Slika 11. Iako predloženi IAVNS nije postigao najstabilnije rezultate indikator funkcije, metode koje su pokazale veću stabilnost tokom nezavisnih izvršavanja nisu bile u stanju da dostignu superiorne najbolje rezultate koje je ostvario IAVNS. Ovo zapažanje je takođe vidljivo na *swarm* dijagramu, koji ilustruje raznovrsnost jedinki tokom poslednje iteracije najboljeg izvršavanja svakog algoritma. Dodatne vizualizacije rezultata indikator funkcije prikazane su na Slika 12, jasno pokazujući snažne konvergentne sposobnosti predloženog IAVNS algoritma tokom njegovog najboljeg izvršavanja, gde je izjednačio najbolje rezultate uprkos tome što je počeo sa nešto nižim kvalitetom početnih rešenja. Treba još jednom napomenuti da stopa greške nije korišćena kao funkcija cilja u simulacijama.

Tabela 13 predstavlja širu evaluaciju najbolje ostvarenih CatBoost modela proizvedenih svakim testiranim metaheurističkim algoritmom. Ovi podešeni CatBoost modeli su se susretali sa manje poteškoća u tačnoj identifikaciji svake klase, a ukupni rezultati su bili poboljšani u poređenju sa rezultatima CNN-a prvog nivoa. Da bi se dobilo jasnije razumevanje sposobnosti svakog modela, treba razmotriti nekoliko metrika, uključujući preciznost, osetljivost i F1-meru za svaku klasu, gde je predloženi CNN-CB-IAVNS ostvario zadovoljavajuće vrednosti. Nadalje, što se tiče ukupne tačnosti među svim evaluiranim modelima, predloženi CNN-CB-IAVNS izjednačio se sa najboljim rezultatom koji su ostvarili nekoliko drugih konkurenata, postigavši ukupnu tačnost od 0,75.

U CatBoost nivou, nekoliko optimizatora je ostvarilo identične najbolje tačnosti (75%), što ukazuje na to da je osnovni domen pretrage hiperparametara za ovaj model relativno gladak i sadrži širok plato skoro-optimalnih rešenja. Ovo ponašanje je u skladu sa inherentnom robusnošću CatBoost-ovog gradijentno zasnovanog treniranja i mehanizama regularizacije, koji smanjuju osetljivost na fino (*fine-grained*) podešavanje hiperparametara. Takođe je važno naglasiti da je cilj optimizacije bio MCC, a ne stopa greške (*error rate*) klasifikacije. Ipak, IAVNS je ostvario više srednje i medijalne MCC vrednosti, zajedno sa nižom varijansom kroz nezavisna izvršavanja, što ukazuje na pouzdaniju konvergenciju i poboljšanu stabilnost. Ovi nalazi pokazuju da iako IAVNS možda ne proizvodi jedinstveno superiornu vrednost tačnosti, i dalje pruža jasne prednosti u pogledu konzistentnosti i reproduktivnosti optimizacije.


Da bi se zaokružile vizualizacije za simulacije CatBoost-a drugog sloja, Slika 13 prikazuje PR krive zajedno sa matricom konfuzije najuspešnijeg modela, koji je u ovom slučaju bio CNN-CB-IAVNS. Konačno, najbolji skupovi CatBoost hiperparametara generisani svakim optimizacionim algoritmom navedeni su u Tabela 14, omogućavajući naredne studije replikacije, s obzirom na to da su ove CatBoost konfiguracije ostvarile rezultate prikazane u Tabela 13.

Tabela 11. Vrednosti funkcije cilja simulacije CatBoost-a drugog sloja


Method	Best	Worst	Mean	Median	Std	Var
CNN-CB-IAVNS	0.717462	0.654245	0.701020	0.699023	0.016845	0.000284
CNN-CB-VNS	0.717462	0.663093	0.696119	0.696314	0.015572	0.000243
CNN-CB-GA	0.703047	0.649024	0.682678	0.694429	0.018320	0.000336
CNN-CB-PSO	0.717462	0.676606	0.694134	0.694529	0.014093	0.000199
CNN-CB-COA	0.717462	0.662525	0.682270	0.680500	0.013372	0.000179
CNN-CB-ChOA	0.717462	0.675198	0.694027	0.697897	0.011538	0.000133
CNN-CB-SCHO	0.717462	0.679334	0.698734	0.698735	0.011261	0.000127
CNN-CB-COLSHADE	0.717462	0.676606	0.693720	0.696314	0.012724	0.000162

Tabela 12. Vrednosti indikatorske funkcije simulacije CatBoost-a drugog sloja

Method	Best	Worst	Mean	Median	Std	Var
CNN-CB-IAVNS	0.250000	0.308824	0.263725	0.264706	0.016522	0.000273
CNN-CB-VNS	0.250000	0.294118	0.266667	0.264706	0.013006	0.000169
CNN-CB-GA	0.264706	0.308824	0.279412	0.264706	0.017810	0.000317
CNN-CB-PSO	0.250000	0.279412	0.268627	0.264706	0.011349	0.000129
CNN-CB-COA	0.250000	0.294118	0.278431	0.279412	0.011349	0.000129
CNN-CB-ChOA	0.250000	0.279412	0.268627	0.264706	0.009998	0.000010
CNN-CB-SCHO	0.250000	0.279412	0.264706	0.264706	0.009301	0.000009
CNN-CB-COLSHADE	0.250000	0.279412	0.269608	0.264706	0.010282	0.000106




Slika 9. Dijagrami raspodele funkcije cilja i rojeva simulacije CatBoost-a drugog sloja




Slika 10. Dijagrami konvergencije funkcije cilja simulacije CatBoost-a drugog sloja





Slika 12. Dijagrami konvergencije indikatorske funkcije simulacije CatBoost-a drugog sloja



Slika 13. Matrica konfuzije i PR kriva najboljeg optimizovanog CNN-CB-IAVNS modela simulacije CatBoost-a drugog sloja

Tabela 13. Poređenje detaljnih metrika najboljeg optimizovanog modela simulacije CatBoost-a drugog sloja

Approach	Metric	Andean Guan	Bartletts tinamou	Bearded Guan	Blue-throated Piping Guan	Cauca Guan	Undulated Timamou	Accuracy	Macro avg	Weighted avg
CNN-CB IAVNS	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
CNN-CB VNS	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
CNN-CB GA	precision	0.818182	0.818182	1.000000	0.615385	0.470588	1.000000	0.735294	0.787056	0.809816
	recall	0.473684	1.000000	0.416667	1.000000	0.888889	1.000000	0.735294	0.796540	0.735294
	f1-score	0.600000	0.900000	0.588235	0.761905	0.615385	1.000000	0.735294	0.744254	0.723419
CNN-CB PSO	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
CNN-CB COA	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
CNN-CB ChOA	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
CNN-CB SCHO	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
CNN-CB COLSHADE	precision	0.833333	0.818182	1.000000	0.615385	0.500000	1.000000	0.750000	0.794483	0.817942
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.900000	0.588235	0.761905	0.640000	1.000000	0.750000	0.755884	0.739296
	support	19	9	12	8	9	11			

Tabela 14. Izbor parametara modela sa najboljim performansama simulacije CatBoost-a drugog sloja

Approach	Learning rate	Col sample by level	Subsample	Iterations	Depth	Min leaf data
CNN-CB-IAVNS	4.27e-02	5.00e-02	6.62e-02	56	4	10
CNN-CB-VNS	3.74e-03	3.98e-01	1.00e+00	50	1	10
CNN-CB-GA	1.72e-02	5.00e-02	2.68e-01	53	4	3
CNN-CB-PSO	3.81e-02	5.00e-02	6.66e-01	66	4	10
CNN-CB-COA	1.00e-01	5.00e-02	3.46e-01	70	4	6
CNN-CB-ChOA	2.95e-02	5.00e-02	1.22e-01	73	4	1
CNN-CB-SCHO	4.38e-02	5.04e-02	6.40e-02	70	4	2
CNN-CB-COLSHADE	4.03e-02	5.02e-02	2.05e-01	76	4	10

5.1.5. Rezultati simulacije LightGBM algoritma drugog sloja

Eksperimentalni rezultati drugog nivoa okvira, gde je podešavanje LightGBM-a vršeno sa MCC kao funkcijom cilja koju treba maksimizovati, prikazani su u Tabela 15. Uvedeni IAVNS metaheuristički algoritam postigao je najbolji rezultat, dostižući MCC vrednost od 0,722354 u svom najuspešnijem izvršavanju. Najjaču performansu u najgorem izvršavanju ostvario je COLSHADE, sa MCC vrednošću od 0,656168. Najviši srednji rezultat, 0,677676, postigao je uvedeni IAVNS algoritam, dok je najbolje medijalne rezultate proizveo SCHO. Najstabilnije rezultate, naznačene najnižim standardnim odstupanjem i varijansom, takođe je ostvario COLSHADE.

Rezultati funkcije cilja vizuelizovani su kroz *violin* i *swarm* dijagrame na Slika 14. Uvedeni IAVNS nije postigao najstabilnije rezultate u ovom scenariju. Ipak, konkurenti koji su pokazali veću stabilnost tokom nezavisnih izvršavanja i dalje nisu bili u stanju da dostignu superiorni najbolji rezultat koji je ostvario IAVNS. Ovo je vidljivo na *swarm* dijagramu, koji ilustruje raznovrsnost jedinki tokom poslednje iteracije najuspešnijeg izvršavanja svakog algoritma. Dodatne vizualizacije rezultata funkcije cilja prikazane su na Slika 15, jasno demonstrirajući snažne konvergentne sposobnosti predloženog IAVNS algoritma tokom njegovog najboljeg izvršavanja, gde je ostvario najbolju performansu uprkos tome što nije počeo sa najvišim kvalitetom početnih rešenja.

Rezultati indikator funkcije, odnosno greške klasifikacije, prikazani su u Tabela 16. Kao i kod rezultata funkcije cilja, predloženi IAVNS je ostvario najbolju stopu greške od 0,235294 u ovom scenariju. Što se tiče preostalih metrika, ChOA i COLSHADE su proizveli identične vrednosti za najgore izvršavanje, dok je predloženi IAVNS dostigao najbolji srednji rezultat od 0,282353. Nekoliko algoritama, uključujući IAVNS, delilo je istu medijalnu vrednost od 0,279412. Najveću stabilnost rezultata, naznačenu najnižim odstupanjem i varijansom, ostvario je COLSHADE.

Rezultati indikator funkcije vizuelizovani su kroz *box plot* i *swarm* dijagrame prikazane na Slika 16. Iako uvedeni IAVNS nije ostvario najstabilnije rezultate indikator funkcije, druge metode koje su pokazale veću stabilnost tokom nezavisnih izvršavanja ipak nisu bile u stanju da dostignu superiorni najbolji rezultat koji je ostvario IAVNS. Ovo je takođe vidljivo na *swarm* dijagramu, koji ilustruje raznovrsnost rešenja u poslednjoj iteraciji najuspešnijeg izvršavanja svakog metaheurističkog algoritma. Dodatne vizualizacije rezultata indikator funkcije

prikazane su na Slika 17, jasno demonstrirajući snažne konvergentne sposobnosti predloženog IAVNS-a tokom njegovog najboljeg izvršavanja, gde je nadmašio sve ostale konkurente uprkos tome što je počeo sa nešto slabijim kvalitetom početnih rešenja. Treba još jednom naglasiti da stopa greške klasifikacije nije korišćena kao funkcija cilja ni u jednoj od simulacija.

Tabela 17 predstavlja širu evaluaciju najbolje ostvarenih LightGBM modela sintetizovanih svakim posmatranim metaheurističkim algoritmom. Ovi podešeni LightGBM modeli imali su manje poteškoća u tačnoj identifikaciji svih klasa, a njihove **ukupne performanse bile su znatno bolje u poređenju sa rezultatima CNN-a prvog nivoa**. Da bi se steklo jasnije razumevanje sposobnosti svakog modela, treba razmotriti nekoliko metrika, uključujući preciznost, osetljivost i F1-meru za svaku klasu, gde je predloženi CNN-LGBM-IAVNS ostvario zadovoljavajuće rezultate. Nadalje, što se tiče najviše ukupne tačnosti među svim evaluiranim modelima, predloženi CNN-LGBM-IAVNS je postigao superioran rezultat, sa utvrđenom tačnošću od 0,764706.

Da bi se zaokružile vizualizacije za simulacije LightGBM algoritma drugog sloja, Slika 18 prikazuje PR krive zajedno sa matricom konfuzije najsuperiornijeg modela (u ovom slučaju CNN-LGBM-IAVNS). Konačno, najbolji skupovi LightGBM hiperparametara sintetizovani svakim optimizacionim algoritmom korišćenim u evaluacijama navedeni su u Tabela 18, radi omogućavanja potencijalnih studija replikacije, s obzirom na to da su ovi LightGBM modeli ostvarili performanse prikazane u Tabela 17.

Tabela 15. Vrednosti funkcije cilja simulacije LightGBM-a drugog sloja



Method	Best	Worst	Mean	Median	Std	Var
CNN-LGBM-IAVNS	0.722354	0.640904	0.677676	0.674081	0.018917	0.000358
CNN-LGBM-VNS	0.694242	0.000000	0.272156	0.000000	0.333352	0.111123
CNN-LGBM-GA	0.675824	0.000000	0.477686	0.648850	0.288652	0.083320
CNN-LGBM-PSO	0.708777	0.613419	0.667082	0.667995	0.021063	0.000444
CNN-LGBM-COA	0.694405	0.000000	0.560848	0.645335	0.221240	0.048947
CNN-LGBM-ChOA	0.716706	0.650331	0.676918	0.675479	0.017614	0.000310
CNN-LGBM-SCHO	0.696276	0.634820	0.672132	0.675997	0.016227	0.000263
CNN-LGBM-COLSHADE	0.698206	0.656168	0.675837	0.673890	0.013667	0.000187

Tabela 16. Vrednosti indikatorske funkcije simulacije LightGBM-a drugog sloja


Method	Best	Worst	Mean	Median	Std	Var
CNN-LGBM-IAVNS	0.235294	0.323529	0.282353	0.279412	0.021613	0.000467
CNN-LGBM-VNS	0.264706	0.882353	0.641176	0.882353	0.295428	0.087278
CNN-LGBM-GA	0.279412	0.882353	0.456863	0.308824	0.257274	0.066190
CNN-LGBM-PSO	0.250000	0.338235	0.291176	0.294118	0.020935	0.000438
CNN-LGBM-COA	0.264706	0.882353	0.381373	0.308824	0.197626	0.039056
CNN-LGBM-ChOA	0.250000	0.308824	0.284314	0.279412	0.019111	0.000365
CNN-LGBM-SCHO	0.264706	0.323529	0.287255	0.279412	0.017701	0.000313
CNN-LGBM-COLSHADE	0.264706	0.308824	0.285294	0.279412	0.017647	0.000311

Tabela 17. Poređenje detaljnih metrika najboljeg optimizovanog modela simulacije LightGBM-a drugog sloja



Approach	Metric	Andean Guan	Bartletts tinamou	Bearded Guan	Blue-throated Piping Guan	Cauca Guan	Undulated Timamou	Accuracy	Macro avg	Weighted avg
CNN-LGBM IAVNS	precision	0.733333	0.750000	0.857143	0.727273	0.583333	1.000000	0.764706	0.775180	0.779959
	recall	0.578947	1.000000	0.500000	1.000000	0.777778	1.000000	0.764706	0.809454	0.764706
	f1-score	0.647059	0.857143	0.631579	0.842105	0.666667	1.000000	0.764706	0.774092	0.754768
CNN-LGBM VNS	precision	0.833333	0.888889	0.750000	0.777778	0.470588	0.846154	0.735294	0.761124	0.773508
	recall	0.526316	0.888889	0.500000	0.875000	0.888889	1.000000	0.735294	0.779849	0.735294
	f1-score	0.645161	0.888889	0.600000	0.823529	0.615385	0.916667	0.735294	0.748272	0.730413
CNN-LGBM GA	precision	0.769231	0.692308	0.833333	0.700000	0.466667	1.000000	0.720588	0.743590	0.759502
	recall	0.526316	1.000000	0.416667	0.875000	0.777778	1.000000	0.720588	0.765960	0.720588
	f1-score	0.625000	0.818182	0.555556	0.777778	0.583333	1.000000	0.720588	0.726641	0.711434
CNN-LGBM PSO	precision	0.733333	0.750000	1.000000	0.615385	0.583333	1.000000	0.750000	0.780342	0.792006
	recall	0.578947	1.000000	0.416667	1.000000	0.777778	1.000000	0.750000	0.795565	0.750000
	f1-score	0.647059	0.857143	0.588235	0.761905	0.666667	1.000000	0.750000	0.753501	0.737683
CNN-LGBM COA	precision	0.769231	0.818182	0.833333	0.636364	0.500000	1.000000	0.735294	0.759518	0.773087
	recall	0.526316	1.000000	0.416667	0.875000	0.888889	1.000000	0.735294	0.784479	0.735294
	f1-score	0.625000	0.900000	0.555556	0.736842	0.640000	1.000000	0.735294	0.742900	0.724947
CNN-LGBM ChOA	precision	0.833333	0.750000	1.000000	0.615385	0.533333	1.000000	0.750000	0.788675	0.813330
	recall	0.526316	1.000000	0.416667	1.000000	0.888889	1.000000	0.750000	0.805312	0.750000
	f1-score	0.645161	0.857143	0.588235	0.761905	0.666667	1.000000	0.750000	0.753185	0.737153
CNN-LGBM SCHO	precision	0.769231	0.818182	1.000000	0.615385	0.466667	1.000000	0.735294	0.778244	0.795619
	recall	0.526316	1.000000	0.416667	1.000000	0.777778	1.000000	0.735294	0.786793	0.735294
	f1-score	0.625000	0.900000	0.588235	0.761905	0.583333	1.000000	0.735294	0.743079	0.726163
CNN-LGBM COLSHADE	precision	0.833333	0.727273	1.000000	0.615385	0.533333	0.916667	0.735294	0.770998	0.796841
	recall	0.526316	0.888889	0.416667	1.000000	0.888889	1.000000	0.735294	0.786793	0.735294
	f1-score	0.645161	0.800000	0.588235	0.761905	0.666667	0.956522	0.735294	0.736415	0.722557
	support	19	9	12	8	9	11			





Slika 14. Dijagrami raspodele funkcije cilja i rojeva simulacije LightGBM-a drugog sloja




Slika 15. Dijagrami konvergencije funkcije cilja simulacije LightGBM-a drugog sloja




Slika 16. Dijagrami raspodele indikatorske funkcije i rojeva simulacije LightGBM-a drugog sloja



Slika 17. Dijagrami konvergencije indikatorske funkcije simulacije LightGBM-a drugog sloja



CNN-LGBM-IAVNS Call identification of South America Bird Species L2 LGBM - PR curve



Slika 18. Matrica konfuzije i PR kriva najboljeg optimizovanog CNN-LGBM-IAVNS modela simulacije LightGBM-a drugog sloja

Tabela 18. Najbolje LGBM konfiguracije ustanovljene od strane svakog optimizatora drugog sloja

Approach	rounds	max_depth	leaves	mcw	ff	bf	msg	λ L1	λ L2	lr
CNN-LGBM-IAVNS	50	9	29	5	0.100000	1.000000	0.086632	0.000000	3.000000	0.676732
CNN-LGBM-VNS	69	8	45	6	0.188592	0.658603	0.094134	1.237157	1.731024	0.900000
CNN-LGBM-GA	100	6	45	6	0.769880	1.000000	0.001000	1.051535	3.000000	0.853905
CNN-LGBM-PSO	100	7	45	5	0.100000	0.806319	0.043699	4.348592	0.000000	0.512987
CNN-LGBM-COA	100	6	24	7	0.646319	0.666639	0.100000	2.658229	1.294883	0.900000
CNN-LGBM-ChOA	100	5	27	5	0.100000	0.680387	0.083249	1.194588	3.000000	0.874695
CNN-LGBM-SCHO	50	10	40	7	0.100000	0.500000	0.079888	0.000000	1.575987	0.171576
CNN-LGBM-COLSHADE	100	10	38	5	0.100000	0.500000	0.024493	1.427010	3.000000	0.898761

5.1.6. Analiza performansi

Računarski napor metaheurističkih algoritama najčešće se izražava u terminima evaluacija funkcije cilja (*fitness function evaluations*, FFEs), metrike nezavisne od hardvera koja broji koliko puta je funkcija cilja izračunata tokom izvršavanja algoritma i omogućava objektivno poređenje algoritmičke efikasnosti. Kao dopuna ovoj meri, Tabela 19 sumira prosečna vremena izvršavanja zabeležena za svaku metodu, koristeći konfiguraciju od pet kandidatskih rešenja i pet iteracija po izvršavanju, ponovljenih tokom 30 nezavisnih izvršavanja. Ove vrednosti treba tumačiti kao indikativne, a ne apsolutne, budući da stvarno vreme izvršavanja u velikoj meri zavisi od hardverskog i softverskog okruženja.

Za eksperimente prvog sloja, svaka iteracija uključuje treniranje i evaluaciju CNN-a koji odgovara svakom kandidatskom rešenju u populaciji, što rezultuje sa šest CNN-ova po iteraciji. U proseku, jedna iteracija zahtevala je oko jednu minutu, što dovodi do oko 8 do 10 minuta po potpunom izvršavanju i otprilike 4 do 5 sati za 30 nezavisnih izvršavanja jednog optimizatora. Zbog stohastičke prirode algoritama, prikazana vremena predstavljaju srednje vrednosti svih izvršavanja. Svi eksperimenti izvršeni su na radnoj stanici opremljenoj Intel Core i9-13900K procesorom, 128 GB RAM memorije i dva NVIDIA A800 GPU-a (po 40 GB), pri čemu je TensorFlow konfigurisan za paralelno korišćenje GPU-ova. Faza optimizacije drugog sloja, koja operiše na numeričkim podacima obeležja, bila je računarski zanemarljiva i stoga izostavljena iz analize vremena izvršavanja.

Podaci u Tabela 19 potkrepljuju zapažanja izvedena iz analize složenosti zasnovane na FFE. Gotovo identično vreme izvršavanja IAVNS varijante u odnosu na osnovni VNS potvrđuje da modifikovani algoritam ne uvodi nikakve dodatne evaluacije funkcije cilja.

Tabela 19. Vremena izvršavanja optimizacije CNN-a prvog sloja, šest rešenja u populaciji i osam iteracija po izvršavanju

Algorithm	Per iteration(s)	Per single run(s)
IAVNS	64	514
VNS	63	507
GA	66	531
PSO	59	477
COA	62	501
ChOA	68	548
SCHO	65	523
COLSHADE	61	492

5.1.7. Statistička validacija rezultata

Prilikom komparativne analize optimizatora zasnovanih na slučajnosti, neophodno je utvrditi statističku značajnost dobijenih razlika. Statistička validacija sprovedena je prema principima opisanim u poglavlju 2.11 ove disertacije. Za opravdanost korišćenja parametarskih testova, potrebno je zadovoljiti tri stroga kriterijuma: nezavisnost (*independence*), normalnost (*normality*) i homogenost varijansi (*homoscedasticity*). Kriterijum nezavisnosti ispunjen je izvršavanjem 30 nezavisnih izvršavanja, svako inicijalizovano različitim slučajnim semenom (*random seed*). Za proveru homogenosti varijansi primenjen je Levenov test, koji je za sve slučajeve dao p -vrednost od 0,62, što ukazuje na to da pretpostavka jednakosti varijansi važi.

Za proveru normalnosti primenjen je Shapiro-Wilk test, čiji su rezultati prikazani u Tabela 20. Kako sve p -vrednosti ne prevazilaze utvrđeni prag $\alpha = 0,05$, kriterijum normalnosti nije ispunjen, pa primena parametarskih testova nije opravdana. Ovi nalazi dodatno su potvrđeni vizuelno kroz KDE dijagrame za svaki eksperiment na Slika 19.


Pošto kriterijumi za bezbednu primenu parametarskih testova nisu u potpunosti ispunjeni, evaluacija je sprovedena korišćenjem neparametarskih metoda. Wilcoxonov signed-rank test primenjen je za procenu superiornosti predloženog IAVNS algoritma u odnosu na ostale pristupe. Rezultujuće p -vrednosti prikazane su u Tabela 21. Sve p -vrednosti bile su ispod praga $\alpha = 0,05$, čime je potvrđena statistički značajna superiornost IAVNS algoritma u odnosu na sve testirane konkurentske metode, na sva tri nivoa okvira (CNN, CatBoost i LightGBM).

Tabela 20. Vrednosti p Shapiro-Wilk testa normalnosti za svaki od posmatranih optimizatora

Model	IAVNS	VNS	GA	PSO	COA	ChOA	SCHO	COLSHADE
L1 CNN	0.028	0.025	0.033	0.041	0.039	0.036	0.039	0.036
L2 CB	0.021	0.037	0.024	0.031	0.042	0.046	0.042	0.046
L2 LGBM	0.020	0.030	0.016	0.028	0.035	0.040	0.035	0.040

Tabela 21. Wilcoxon signed-rank test rezultati za sprovedene evaluacije

Model	IAVNS	VNS	GA	PSO	COA	ChOA	SCHO	COLSHADE
L1 CNN	0.024	0.035	0.019	0.031	0.041	0.044	0.020	0.033
L2 CB	0.021	0.029	0.030	0.023	0.037	0.041	0.034	0.032
L2 LGBM	0.032	0.024	0.036	0.020	0.030	0.042	0.035	0.030



Slika 19. Dijagrami raspodele funkcije cilja za svaki optimizator za tri sprovedene simulacije

5.1.8. Interpretacija najboljeg modela


Istraživanja u oblasti veštačke inteligencije često stavljaju naglasak isključivo na performanse modela. Međutim, razumevanje obrazloženja iza određene odluke, kao i faktora koji tu odluku pokreću, ključno je za otkrivanje skrivenih pristrasnosti kako u podacima tako i u samom modelu. Interpretacija modela stoga igra ključnu ulogu u određivanju važnosti obeležja (*feature importance*). Dok je ovo izvodljivo kod jednostavnih modela, povećanje kompleksnosti modela otežava identifikaciju suptilnih odnosa između ulaznih obeležja i izlaza modela.

Kako je detaljnije opisano u poglavlju 2.12 SHAP metoda pruža relativno računski efikasan pristup za interpretaciju kompleksnih modela. Oslanjajući se na aproksimacije, SHAP procenjuje doprinos pojedinačnih obeležja i kvantifikuje njihov uticaj na odluke modela. Interpretacije najboljeg CNN modela za skup uzoraka prikazane su na Slika 20, nakon čega slede interpretacije najboljih hibridnih CNN-CB i CNN-LGBM modela na Slika 21 i Slika 22.


Ukratko, najuspešniji model u ovom istraživanju bio je CNN-LGBM-IAVNS (CNN sa LightGBM modelom umesto poslednjeg potpuno povezanog sloja, podešen predloženim IAVNS algoritmom), koji je ostvario ukupnu tačnost klasifikacije od 76,47%, čime je potvrđena efikasnost dvoslojnog CNN-boosting okvira optimizovanog algoritmom IAVNS za klasifikaciju poziva ptica.



Slika 20. SHAP interpretacija CNN modela prvog sloja sa najboljim performansama



Slika 21. SHAP interpretacija CatBoost modela drugog sloja sa najboljim performansama



Slika 22. SHAP interpretacija LightGBM modela drugog sloja sa najboljim performansama

5.2. Eksperimentalna provera GRU modela za detekciju EEG anomalija

U ovom potpoglavlju predstavljena je eksperimentalna provera predloženog GRU modela za detekciju anomalija u EEG signalima, optimizovanog primenom DADPSO algoritma (Dogandzic, Bacanin, et al., 2026). Najpre je opisan korišćeni skup podataka i postupak njegove pripreme, nakon čega slede detalji predloženog okvira i podešavanja hiperparametara. Potom su prikazani i analizirani rezultati tri eksperimentalna scenarija, praćeni diskusijom dobijenih nalaza i statističkom validacijom kojom se potvrđuje značajnost postignutih poboljšanja u odnosu na osam konkurentskih metaheurističkih algoritama.

5.2.1. Opis skupa podataka i priprema podataka

Eksperimenti su sprovedeni na javno dostupnom Bonn EEG skupu podataka dostupnom na <https://www.upf.edu/web/ntsa/downloads>. Skup sadrži pet podskupova, označenih od A do E, od kojih svaki sadrži po 100 zasebnih jednokanalnih (*single-channel*) EEG segmenata. Svaki segment sadrži 4097 amplitudskih vrednosti uzorkovanih na frekvenciji od 173,61 Hz i traje približno 23,6 sekundi. Podskupovi A i B sadrže površinske EEG snimke dobijene od zdravih dobrovoljaca, pri čemu je u podskupu A snimanje vršeno sa otvorenim očima, a u podskupu B sa zatvorenim očima. Podskupovi C i D sadrže intrakranijalne interiktalne snimke dobijene od pacijenata sa epilepsijom, dok podskup E sadrži intrakranijalne snimke prikupljene tokom napada. Treba naglasiti da podskupovi ne odgovaraju petorici pojedinačnih ispitanika, niti 100 fajlova unutar jednog podskupa predstavlja 100 istovremeno snimljenih elektrodnih kanala.


Predloženi pristup proveren je kroz tri eksperimentalna scenarija. U prvom eksperimentu korišćena je nasumična mešavina podataka iz podskupova B i D radi konstruisanja skupa fokusiranog na detekciju anomalija. Drugi eksperiment generiše neuravnotežen skup podataka kombinovanjem segmenata A, B i C. Treći eksperiment uključuje segmente B, C i E kako bi se omogućila detekcija i anomalija i teških epileptičkih napada. U sva tri eksperimenta, Matthews-ov koeficijent korelacije (MCC) korišćen je kao funkcija cilja.

Da bi se konstruisali segmenti korišćeni u svakom eksperimentu, kontinuirani snimci koji pripadaju relevantnim grupama ispitanika (B/D za Eksperiment 1, A/B/C za Eksperiment 2, B/C/E za Eksperiment 3) najpre su spojeni nasumičnim redosledom na nivou celih snimaka u trajanju od 23,6 sekundi, tako da nijedan pojedinačni segment ne meša uzorke iz dva različita izvorna snimka. Dobijena sekvenca zatim je podeljena na neprekidne (*non-overlapping*) prozore od 158 uzastopnih uzoraka, od kojih je svaki dobio oznaku klase (normalna, anomalna ili napad) prema snimku iz kog potiče. Dužina prozora od 158 uzoraka odabrana je empirijski, kao kompromis između obezbeđivanja dovoljno dugog vremenskog konteksta za GRU modele i održavanja dovoljno velikog broja dostupnih segmenata za obuku, validaciju i testiranje. Nasumičnost redosleda snimaka, umesto nasumičnosti pojedinačnih uzoraka, primenjena je kako bi se sprečilo veštačko curenje vremenske informacije između susednih prozora, uz istovremeno postizanje izmešanog, nesekvencijalnog redosleda segmenata kroz čitav skup podataka. Na ove segmente potom je primenjena ista podela na skupove za obuku, validaciju i testiranje u odnosu 70%/10%/20%.


Vizuelni prikazi za svaki eksperiment dati su na Slika 23, pri čemu je normalna aktivnost prikazana belom pozadinom, anomalna aktivnost svetloplavom, a epileptični napadi tamnoplavom bojom. Odgovarajuće distribucije broja instanci prikazane su na Slika 24.

Podaci prosleđeni GRU modelima sastoje se od 15 uzastopnih vremenskih koraka prikupljenih sa 100 elektroda. Cilj modela je da odredi verovatnoću da uzorak pripada normalnoj aktivnosti, abnormalnoj aktivnosti ili aktivnosti napada. Izlazni sloj generiše tri realne vrednosti u opsegu od 0 do 1, od kojih svaka odgovara verovatnoći pripadnosti jednoj od tri klase, a njihov zbir iznosi 1. Konačna predviđena oznaka klase dodeljuje se izborom klase sa najvišom verovatnoćom.

Modeli su validirani standardnim skupom metrika klasifikacije: preciznošću (*precision*), osetljivošću (*recall/sensitivity*), tačnošću (*accuracy*) i F1-merom (*f1-score*). Matthews-ov koeficijent korelacije (MCC) odabran je kao primarna funkcija cilja koju je potrebno maksimizovati u sva tri eksperimenta, s obzirom na to da MCC posebno dobro odražava kvalitet klasifikacije kod neuravnoteženih skupova podataka, poput onog korišćenog u Eksperimentu 2. Za razliku od preciznosti, koja može sakriti loše performanse na manjinskim klasama, MCC objedinjuje informacije iz sve četiri komponente matrice konfuzije, TP, TN, FP i FN, i ravnomerno nagrađuje tačnu klasifikaciju svih klasa. Pored MCC, praćena je i stopa greške (1 - tačnost), korišćena kao dopunski indikator tokom eksperimenata.



Slika 23. Grafikoni koji prikazuju ponašanje EEG signala kroz skupove podataka korišćene u Eksperimentima 1, 2 i 3



Slika 24. Grafikoni broja instanci koji odgovaraju skupovima podataka korišćenim u Eksperimentima 1, 2 i 3, prikazani redosledom

5.2.2. Eksperimentalno okruženje

Da bi svaki algoritam funkcionisao efikasno, ključno je odabrati odgovarajuće vrednosti hiperparametara koje daju dobre performanse za dati zadatak. Određivanje ovih vrednosti predstavlja izazovan, NP-težak problem, jer prostor pretrage sadrži ogroman broj mogućih konfiguracija, zbog čega tradicionalni metodi izbora nisu adekvatni. Iz tog razloga, ovo istraživanje primenjuje metaheurističke optimizacione pristupe za pronalaženje podešavanja hiperparametara koja daju ciljane nivoe performansi.

Algoritmi korišćeni kao referentni za poređenje sa predloženim DADPSO obuhvatili su nekoliko snažnih optimizacionih metoda, uključujući osnovni **PSO (Particle Swarm Optimization)**, **VNS (Variable Neighborhood Search)**, **GA (Genetic Algorithm)**, **FA (Firefly Algorithm)**, **BSO (Brainstorm Optimization)**, **RSA (Reptile Search Algorithm)**, **SASS (Self-Adaptive Spherical Search)** i **COLSHADE**. Ovaj izbor obezbedio je uravnoteženu kombinaciju klasičnih i savremenijih optimizacionih strategija. Svaki optimizator je izvršen kroz 30 nezavisnih pokušaja, uz populaciju od šest jedinki i šest iteracija po pokušaju.

Kao što je opisano ranije, sprovedene su tri odvojene eksperimentalne konfiguracije. Prvi eksperiment fokusiran je na detekciju anomalne aktivnosti i formulisan je kao zadatak binarne klasifikacije. Drugi eksperiment ima isti cilj detekcije, ali operiše nad neuravnoteženim skupom podataka. Treći eksperiment ima za cilj razlikovanje različitih vrsta anomalnih događaja, čime postaje problem multiklasne klasifikacije. U svim slučajevima, skupovi

podataka podeljeni su na standardan način, gde je 70% podataka služilo kao skup za obuku, 10% kao skup za validaciju, a preostalih 20% kao skup za testiranje. Dodatno, primenjena je normalizacija, a broj kašnjenja (*number of lags*) fiksiran je na 15.

Optimizovane su dve grupe parametara. Prvo, pažljivo su odabrani parametri vezani za treniranje GRU modela. Stopa učenja birana je iz intervala od 0,0001 do 0,01, dok je stopa *dropout*-a birana u opsegu od 0,05 do 0,2 za oba eksperimentalna podešavanja. Pored toga, broj epoha obuke definisan je u opsegu od 30 do 60. Dozvoljene granice za broj neurona postavljene su na $[n/3, n]$, gde n predstavlja broj kašnjenja ($n = 15$). Da bi se smanjila verovatnoća prekomernog prilagođavanja (*overfitting*), primenjen je mehanizam ranog zaustavljanja (*early stopping*), koji obustavlja treniranje po dostizanju trećine maksimalnog broja epoha. Parametri, kao i njihovi odgovarajući opsezi, dati su u Tabela 22.

Drugo, s obzirom na to da arhitektura mreže značajno utiče na ukupne performanse, optimizovani su i strukturni parametri GRU modela. Broj slojeva biran je iz intervala od 1 do 2 za oba eksperimentalna podešavanja. Pored toga, broj neurona po sloju biran je iz opsega od $lags/3$ do $lags$ za prvi eksperiment, a iz opsega od $lags/2$ do $lags \cdot 2$ za drugi eksperiment. Vrednosti parametara u drugom eksperimentu, poput broja epoha obuke i broja neurona, povećane su kako bi se prilagodile većoj složenosti zadatka multiklasne klasifikacije. Odabrane granice parametara proizašle su iz empirijskih zapažanja dobijenih metodom pokušaja i greške (*trial and error*), dopunjenih prethodnim iskustvom u podešavanju hiperparametara.

Tabela 22. Opsezi pretrage hiperparametara GRU modela

Parameter	Learning rate	Dropout	Epochs	Layers	Cells
Min	0.0001	0.05	30	1	5
Max	0.01	0.20	60	2	15

5.2.3. Rezultati prvog eksperimenta

Tabela 23 prikazuje rezultate funkcije cilja (MCC) dobijene u prvom eksperimentu, uključujući najbolju, najgoru, srednju i medijalnu performansu za sva izvršavanja, kao i varijansu i standardno odstupanje koji ilustruju stabilnost svakog algoritma. Predloženi DADPSO ostvario je najvišu performansu u svom najboljem izvršavanju (0,994936), zajedno sa nekoliko drugih metaheurističkih pristupa koji su dostigli isti rezultat u svojim najuspešnijim izvršavanjima. Najbolju vrednost među najgorim izvršavanjima proizveo je FA (0,994936). FA je takođe ostvario najjače srednje i medijalne MCC vrednosti, obe rezultirajući sa vrednošću 0,994936. Iako je DADPSO pokazao veoma nisku varijansu, neke metode, uključujući osnovni PSO, COLSHADE i VNS, pokazale su čak i niže nivoe varijanse.

U pogledu stopa greške klasifikacije za sve evaluirane optimizacione algoritme, prikazanih u Tabela 24, vidljivo je da je DADPSO ostvario odličnu performansu, postigavši najnižu vrednost greške od 0,002462, rezultat koji su ostvarile i neke druge tehnike. Kako stopa greške nije bila primarna metrika optimizacije u ovom istraživanju, ona se koristi isključivo kao dopunski indikator.

Vizualizacija na Slika 25 pokazuje raspodelu vrednosti funkcije cilja i grešaka klasifikacije kroz 30 nezavisnih izvršavanja. Ovi dijagrami pokazuju da DADPSO pouzdano isporučuje jaku ukupnu performansu funkcije cilja. Ipak, njegovi MCC rezultati pokazuju nešto

veću varijabilnost u poređenju sa COLSHADE i osnovnim PSO. Ova dodatna fluktuacija proističe iz namerne odluke u dizajnu, budući da algoritam stavlja naglasak na maksimizaciju vrhunskih performansi, čak i ako to rezultuje smanjenom stabilnošću tokom izvršavanja.

Obrasci konvergencije metaheurističkih optimizatora prikazani su na Slika 26. Među svim upoređenim metodama, DADPSO je pokazao najefikasniju konvergenciju, dostižući svoju optimalnu vrednost funkcije cilja do pete iteracije u svom najboljem izvršavanju. Sličan obrazac uočen je i pri posmatranju konvergencije stope greške.

Izbori parametara za model sa najboljim performansama koji je proizveo svaki optimizator navedeni su u Tabela 25 radi podrške eksperimentalnoj reproduktibilnosti. Vredan pažnje nalaz je da relativno lagane (*lightweight*) arhitekture mreže teže da daju povoljnije rezultate u evaluacijama.

Tabela 23. Ukupne metrike MCC funkcije cilja za Eksperiment 1



Method	Best	Worst	Mean	Median	Std	Var
GRU-DADPSO	0.994936	0.992404	0.993671	0.993672	0.001034	1.07×10^{-6}
GRU-PSO	0.994936	0.993672	0.994094	0.993672	0.000596	3.55×10^{-7}
GRU-VNS	0.994936	0.993672	0.994094	0.993672	0.000596	3.55×10^{-7}
GRU-GA	0.994936	0.989872	0.992827	0.993672	0.002152	4.63×10^{-6}
GRU-FA	0.994936	0.994936	0.994936	0.994936	0	0
GRU-BSO	0.993672	0.992404	0.993249	0.993670	0.000597	3.57×10^{-7}
GRU-RSA	0.994936	0.993670	0.994093	0.993672	0.000596	3.56×10^{-7}
GRU-SASS	0.994936	0.993672	0.994515	0.994936	0.000596	3.55×10^{-7}
GRU-COLSHADE	0.993672	0.993670	0.993671	0.993672	1.26×10^{-6}	1.59×10^{-12}

Tabela 24. Pregled metrika indikatora greške za Eksperiment 1


Method	Best	Worst	Mean	Median	Std	Var
GRU-DADPSO	0.002462	0.003692	0.003077	0.003077	0.000502	2.52×10^{-7}
GRU-PSO	0.002462	0.003077	0.002872	0.003077	0.000290	8.42×10^{-8}
GRU-VNS	0.002462	0.003077	0.002872	0.003077	0.000290	8.42×10^{-8}
GRU-GA	0.002462	0.004923	0.003487	0.003077	0.001046	1.09×10^{-6}
GRU-FA	0.002462	0.002461	0.002461	0.002462	0	0
GRU-BSO	0.003077	0.003692	0.003282	0.003077	0.000290	8.42×10^{-8}
GRU-RSA	0.002462	0.003077	0.002872	0.003077	0.000290	8.42×10^{-8}
GRU-SASS	0.002462	0.003077	0.002667	0.002462	0.000290	8.42×10^{-8}
GRU-COLSHADE	0.003077	0.003077	0.003077	0.003077	0	0

Tabela 25. Optimizovane konfiguracije parametara za Eksperiment 1

Method	LR	Dropout	Epochs	Layers	Neurons L1	Neurons L2
GRU-DADPSO	0.0064	0.11	55	1	14	—
GRU-PSO	0.0099	0.05	59	1	9	—
GRU-VNS	0.0077	0.20	60	1	13	—
GRU-GA	0.01	0.0800	60	1	12	—
GRU-FA	0.01	0.1686	36	1	15	—
GRU-BSO	0.01	0.20	55	2	12	15
GRU-RSA	0.0072	0.20	60	1	15	—
GRU-SASS	0.0043	0.1238	35	1	15	—
GRU-COLSHADE	0.0033	0.20	50	1	12	—



Slika 25. Vizuelizovane raspodele MCC vrednosti i grešaka klasifikacije za Eksperiment 1



Slika 26. Dijagrami konvergencije MCC i metrika greške za Eksperiment 1

5.2.4. Rezultati drugog eksperimenta

Tabela 26 prikazuje rezultate funkcije cilja (MCC) dobijene u drugom eksperimentu, uključujući najbolju, najgoru, srednju i medijalnu performansu za sva izvršavanja, kao i varijansu i standardno odstupanje koji ilustruju stabilnost svakog algoritma. Predloženi DADPSO nadmašio je sve ostale metode, ostvarivši najviše vrednosti i u svom najboljem (0,989661) i u svom najgorem izvršavanju (0,984490). Takođe je proizveo najjače srednje i medijalne MCC rezultate, 0,987649 i 0,988797. Iako je DADPSO pokazao veoma nisku varijansu u svim izvršavanjima, FA je ostvario nešto niži nivo varijabilnosti.

Tabela 27, koja prikazuje rezultate klasifikacije svih optimizacionih tehnika na osnovu stopa greške, pokazuje da je DADPSO ostvario izuzetnu performansu, postigavši minimalnu vrednost greške od 0,004910. Iako je ovo bila najniža zabeležena greška, nekoliko drugih algoritama, poput RSA i osnovnog PSO, proizvelo je slično niske vrednosti greške. Međutim, budući da stopa greške nije bila primarna metrika optimizacije u ovoj studiji, koristi se isključivo kao sekundarni indikator.

Vizualizacija na Slika 27 prikazuje raspodelu vrednosti funkcije podobnosti i grešaka klasifikacije kroz 30 nezavisnih izvršavanja. Ovi dijagrami pokazuju da DADPSO algoritam dosledno isporučuje jaku ukupnu performansu funkcije cilja. Ipak, njegove MCC vrednosti pokazuju nešto veću varijabilnost u poređenju sa FA u ovoj eksperimentalnoj konfiguraciji. Kao i u prvom eksperimentu, ova dodatna fluktuacija direktna je posledica namerne odluke u dizajnu algoritma, koji stavlja naglasak na postizanje što viših vrhunskih performansi, čak i ako to dovodi do smanjene stabilnosti između izvršavanja.

Obrasci konvergencije metaheurističkih optimizatora prikazani su na Slika 28. Među svim testiranim pristupima, DADPSO je pokazao najefikasniju konvergenciju, dostižući svoju optimalnu ciljnu vrednost do četvrte iteracije u svom najboljem izvršavanju. Nekoliko drugih metoda konvergiralo je sporije i zaglavilo se u lokalnim optimumima. Sličan obrazac uočen je pri posmatranju konvergencije stope greške.

Konfiguracije parametara za najuspešnije modele proizvedene svakim optimizatorom navedene su u Tabela 28, radi podrške eksperimentalnoj reproduktibilnosti. Ponovo je uočeno da relativno lagane (*lightweight*) mrežne arhitekture teže da daju povoljnije rezultate u evaluacijama.


Tabela 26. Ukupne metrike MCC funkcije cilja za Eksperiment 2

Method	Best	Worst	Mean	Median	Std	Var
GRU-DADPSO	0.989661	0.984490	0.987649	0.988797	0.002262	5.11×10^{-6}
GRU-PSO	0.985390	0.969029	0.979642	0.984508	0.007513	5.64×10^{-5}
GRU-VNS	0.983626	0.959592	0.974488	0.980246	0.010623	0.000113
GRU-GA	0.983624	0.976724	0.979915	0.979396	0.002841	8.07×10^{-6}
GRU-FA	0.977636	0.975866	0.976525	0.976074	0.000790	6.24×10^{-7}
GRU-BSO	0.982786	0.969880	0.977336	0.979342	0.005456	2.98×10^{-5}
GRU-RSA	0.986220	0.981035	0.984492	0.986220	0.002444	5.98×10^{-6}
GRU-SASS	0.975045	0.957103	0.967939	0.971669	0.007785	6.06×10^{-5}
GRU-COLSHADE	0.981903	0.906136	0.945004	0.946972	0.030963	0.000959


Tabela 27. Pregled metrika indikatora greške za Eksperiment 2

Method	Best	Worst	Mean	Median	Std	Var
GRU-DADPSO	0.004910	0.007365	0.005865	0.005319	0.001074	1.15×10^{-6}
GRU-PSO	0.006956	0.014730	0.009684	0.007365	0.003572	1.28×10^{-5}
GRU-VNS	0.007774	0.019640	0.012275	0.009411	0.005251	2.76×10^{-5}
GRU-GA	0.007774	0.011047	0.009547	0.009820	0.001350	1.82×10^{-6}
GRU-FA	0.010638	0.011457	0.011184	0.011457	0.000386	1.49×10^{-7}
GRU-BSO	0.008183	0.014321	0.010775	0.009820	0.002595	6.73×10^{-6}
GRU-RSA	0.006547	0.009002	0.007365	0.006547	0.001157	1.34×10^{-6}
GRU-SASS	0.011866	0.020458	0.015276	0.013502	0.003725	1.39×10^{-5}
GRU-COLSHADE	0.008592	0.046236	0.026732	0.025368	0.015398	0.000237


EEG Anomaly detection experiment 2 - objective box plot diagram



EEG Anomaly detection experiment 2 - error box plot diagram



Slika 27. Raspodele MCC vrednosti i grešaka za Eksperiment 2



Slika 28. Dijagrami konvergencije MCC i metrika greške za Eksperiment 2

Tabela 28. Optimizovane konfiguracije parametara za Eksperiment 2

Method	LR	Dropout	Epochs	Layers	Neurons L1	Neurons L2
GRU-DADPSO	0.01	0.2	60	2	14	14
GRU-PSO	0.0095	0.1492	30	1	6	—
GRU-VNS	0.0093	0.05	48	2	5	5
GRU-GA	0.0053	0.1715	60	1	15	—
GRU-FA	0.0096	0.1506	60	1	10	—
GRU-BSO	0.0080	0.1306	59	2	6	7
GRU-RSA	0.01	0.1585	60	1	8	—
GRU-SASS	0.0038	0.0670	60	2	15	15
GRU-COLSHADE	0.0083	0.1617	43	1	13	—

5.2.5. Rezultati trećeg eksperimenta

U poređenju sa Eksperimentima 1 i 2, Eksperiment 3 je proizveo znatno niže i promenljivije vrednosti funkcije cilja kod svih evaluiranih optimizatora. Glavna razlika je u tome što treći eksperiment zahteva istovremeno razlikovanje normalne, interiktalne abnormalne i aktivnosti napada, dok su prva dva eksperimenta zadaci binarne klasifikacije. Dodatna klasa uvodi dodatne granice odlučivanja i povećava verovatnoću preklapanja između reprezentacija klasa. Normalna i anomalna klasa su takođe znatno slabije zastupljene u odnosu na klasu napada, zbog čega je funkcija cilja osetljivija na mali broj pogrešnih klasifikacija u manjinskim klasama. Konačno, granica između zdrave pozadinske aktivnosti i interiktalne abnormalnosti suštinski je manje razdvojiva u ovom skupu podataka nego granica između bilo koje od te dve klase i aktivnog napada, što multiklasnu granicu odlučivanja čini teže naučivom za kompaktan, lagano treniran GRU model.

Tabela 29 prikazuje rezultate funkcije cilja (MCC) za, po svemu sudeći, najzahtevniji eksperiment u ovom istraživanju. Tabela prikazuje najbolje, najlošije, srednje i medijalne vrednosti između izvršavanja. Pored toga, uključene su varijansa i standardno odstupanje radi uvida u stabilnost svakog algoritma. Predloženi DADPSO ostvario je najvišu performansu u svom najboljem izvršavanju (0,554613), dok je GA proizveo najjači rezultat među najgorim izvršavanjima (0,295004). GA je takođe ostvario najviše srednje i medijalne MCC vrednosti, 0,431937 i 0,474283, redom. U ovom konkretnom eksperimentu, DADPSO je pokazao veću varijansu između izvršavanja, dok je nekoliko drugih metoda, posebno osnovni PSO, VNS i SASS, pokazalo znatno nižu varijabilnost.

Prema Tabela 30, koja sumira rezultate klasifikacije svih optimizacionih tehnika na osnovu stopa greške, DADPSO je pokazao solidnu performansu, ostvarivši drugu najnižu vrednost greške od 0,124386 (nadmašen jedino od strane GA, koji je dostigao 0,114157 u svom najboljem izvršavanju). Ostali algoritmi zabeležili su znatno više vrednosti greške. Međutim, budući da stopa greške nije bila primarna metrika optimizacije u ovoj studiji, tumači se isključivo kao pomoćna mera.

Vizualizacija na Slika 29 prikazuje raspodelu vrednosti funkcije cilja i grešaka klasifikacije kroz 30 nezavisnih izvršavanja. Ovi dijagrami pokazuju da DADPSO algoritam generalno isporučuje snažnu performansu funkcije cilja. Ipak, njegove MCC vrednosti pokazuju znatno veću varijabilnost u poređenju sa osnovnim PSO, SASS i nekoliko drugih metoda. Kao i kod prethodnih eksperimenata, ovo povećano variranje je rezultat namernog dizajnerskog izbora, jer algoritam daje prioritet postizanju što viših vrhunskih performansi, čak i po cenu smanjene stabilnosti kroz izvršavanja.

Karakteristike konvergencije metaheurističkih optimizatora prikazane su na Slika 30. Među svim evaluiranim metodama, DADPSO je pokazao najbržu i najefikasniju konvergenciju, dostižući svoju optimalnu vrednost funkcije cilja u okviru prve iteracije u svom najboljem izvršavanju. Nijedna druga tehnika nije konvergirala tako brzo, a nekoliko njih zaglavilo se u lokalnim optimumima. Sličan obrazac uočen je pri posmatranju konvergentnog ponašanja stope greške.

Konfiguracije parametara za najuspešnije modele proizvedene svakim optimizatorom navedene su u Tabela 31 radi osiguranja reproduktibilnosti eksperimentalnih rezultata.

Tabela 29. Pregled metrika MCC funkcije cilja za Eksperiment 3

Method	Best	Worst	Mean	Median	Std	Var
GRU-DADPSO	0.554613	0.248253	0.398976	0.394061	0.125119	0.015655
GRU-PSO	0.338912	0.255207	0.283866	0.257479	0.038934	0.001516
GRU-VNS	0.290974	0.199977	0.236777	0.219382	0.039133	0.001531
GRU-GA	0.526523	0.295004	0.431937	0.474283	0.099147	0.009830
GRU-FA	0.494750	0.231927	0.347422	0.315589	0.109633	0.012019
GRU-BSO	0.357876	0.207490	0.275789	0.261999	0.062165	0.003864
GRU-RSA	0.314969	0.185811	0.251480	0.253660	0.052751	0.002783
GRU-SASS	0.221068	0.181032	0.198457	0.193272	0.016751	0.000281
GRU-COLSHADE	0.298340	0.186826	0.232467	0.212236	0.047720	0.002277


Tabela 30. Pregled metrika indikatora greške za Eksperiment 3

Method	Best	Worst	Mean	Median	Std	Var
GRU-DADPSO	0.124386	0.343290	0.265685	0.329378	0.100074	0.010015
GRU-PSO	0.414484	0.452946	0.462493	0.452946	0.043622	0.001903
GRU-VNS	0.473813	0.907529	0.614566	0.473813	0.207208	0.042935
GRU-GA	0.114157	0.505728	0.231724	0.114157	0.194399	0.037791
GRU-FA	0.221358	0.399755	0.298418	0.274141	0.074826	0.005599
GRU-BSO	0.359247	0.558511	0.446945	0.423077	0.083081	0.006902
GRU-RSA	0.445581	0.839198	0.512957	0.445581	0.243573	0.059328
GRU-SASS	0.441489	0.768003	0.619203	0.648118	0.134858	0.018187
GRU-COLSHADE	0.510638	0.576105	0.546236	0.551964	0.027032	0.000731


Tabela 31. Optimizovane konfiguracije parametara za Eksperiment 3

Method	LR	Dropout	Epochs	Layers	Neurons L1	Neurons L2
GRU-DADPSO	0.0072	0.0741	60	2	10	11
GRU-PSO	0.0043	0.0539	39	2	15	11
GRU-VNS	0.0053	0.1278	53	2	7	6
GRU-GA	0.0091	0.1787	44	2	5	9
GRU-FA	0.0034	0.0901	60	2	15	5
GRU-BSO	0.01	0.20	60	1	15	—
GRU-RSA	0.0075	0.1717	47	1	5	—
GRU-SASS	0.0048	0.0756	30	1	15	—
GRU-COLSHADE	0.01	0.20	60	2	11	15


EEG Anomaly detection experiment 3 - objective box plot diagram



EEG Anomaly detection experiment 3 - error box plot diagram



Slika 29. Dijagrami raspodele MCC i metrika greške za Eksperiment 3



Slika 30. Dijagrami konvergencije MCC i metrika greške za Eksperiment 3

5.2.6. Diskusija rezultata

Detaljna poređenja metrika za najuspešnije modele u sva tri eksperimenta prikazana su u Tabela 32, Tabela 33 i Tabela 34. Iako je predloženi DADPSO ostvario značajna poboljšanja i najbolje rezultate za većinu metrika, pojedini konkurenti su ga nadmašili u specifičnim merama. Ovaj ishod dodatno potvrđuje NFL (*No Free Lunch*) teorem, naglašavajući da nijedna optimizaciona metoda nije univerzalno optimalna za sva podešavanja problema ili kriterijume evaluacije. Iz tog razloga, kontinuirano eksperimentisanje i metodološko usavršavanje ostaju neophodni za pronalaženje najprikladnijeg pristupa za dati izazov.

Osim opšte tačnosti, DADPSO je pokazao snažnu sposobnost razlikovanja svih ciljnih klasa (normalna i abnormalna aktivnost u Eksperimentima 1 i 2, normalna, abnormalna i aktivnost napada u Eksperimentu 3), dosledno proizvodeći odlične makro i ponderisane prosečne rezultate. Kao što je naznačeno u Tabela 32, Tabela 33 i Tabela 34, neki optimizacioni metodi pokazali su ograničenu sposobnost istraživanja prostora pretrage, naginjući ka suboptimalnim oblastima prostora pretrage i proizvodeći rešenja nižeg kvaliteta. Ovaj problem posebno je izražen u Tabela 34, gde su algoritmi poput VNS, BSO, RSA, SASS i COLSHADE ostvarili приметно niske tačnosti. Ovi rezultati usklađeni su sa dijagramima konvergencije odgovarajućih algoritama, ukazujući na to da nisu napredovali ka povoljnijim regionima prostora pretrage.

Međutim, važno je naglasiti da ova zapažanja ne umanjuju ukupnu vrednost ovih tehnika. U alternativnim scenarijima, sporija stopa konvergencije ili šire ponašanje pretrage može biti korisno, posebno kada je od ključne važnosti izbegavanje prevremene konvergencije ili izlazak iz lokalnih minimuma.

Slika 31 prikazuje dijagrame raznovrsnosti roja, pokazujući raspon i raznovrsnost vrednosti funkcije cilja i stopa greške koje su ostvarili različiti metaheuristički algoritmi, procenjeni u poslednjoj iteraciji njihovog najboljeg izvršavanja u sva tri eksperimenta. Ove vizualizacije pružaju jasan uvid u obrazac pretrage svakog algoritma i kvalitet njegovih konačnih rešenja. Algoritmi poput DADPSO prikazuju čvrsto grupisane rojeve centrirane oko svojih najboljih rešenja, odražavajući snažnu sposobnost globalnog istraživanja u kombinaciji sa izraženom snagom konvergencije i doslednošću, s obzirom na to da se većina članova populacije približava optimalnom regionu.

Zajedničkom vizualizacijom i mera performansi i raznovrsnosti populacije, ovi dijagrami pružaju sveobuhvatnije razumevanje sposobnosti svakog optimizatora da uravnoteži eksploraciju i eksploataciju. Ova ravnoteža je od suštinskog značaja za sprečavanje preuranjene stagnacije i za identifikovanje robusnih, dobro generalizovanih podešavanja hiperparametara. Ovakva dvostrana perspektiva analize posebno je važna kod zadataka medicinske prognoze, gde su otpornost na efekte inicijalizacije, prilagodljivost varijabilnosti podataka i sveukupna robusnost ključni za primenu pouzdanih modela u stvarnim uslovima.

Nastavljajući analizu, Slika 32 prikazuje radarske dijagrame (*radar charts*) koji sumiraju makro i ponderisane prosečne metrike, nudeći objedinjen pregled performansi modela kroz više dimenzija evaluacije. Makro prosek tretira sve klase podjednako, čineći ga posebno informativnim za procenu sposobnosti modela da prepozna manjinske kategorije, dosledno izazovan aspekt kod rada sa neuravnoteženim skupovima podataka. Nasuprot tome, ponderisani prosek uzima u obzir učestalost klasa, pružajući meru performansi koja odražava ukupnu raspodelu podataka i naglašava ponašanje na većinskim klasama.

Posmatranje ove dve perspektive zajedno ističe prirodne kompromise koji nastaju između konkurentskih optimizacionih metoda. Modeli koji postižu visoke rezultate na ponderisanim prosecima i dalje mogu imati poteškoća sa nedovoljno zastupljenim klasama, dok oni koji pokazuju snažnu performansu na nivou makro proseka teže da pokažu veću otpornost u uslovima neuravnoteženosti klasa. Zbirno posmatrano, radarski dijagrami služe kao dopunski dijagnostički alat, omogućavajući detaljniju procenu sposobnosti generalizacije, pravednosti i pouzdanosti metaheuristički optimizovanih klasifikatora.

Konačno, PR krive i vizualizacije matrice konfuzije za najuspešniji model (GRU-DADPSO) u svakom od tri eksperimenta prikazane su na Slika 33. Gornji red odgovara Eksperimentu 1, gde je GRU-DADPSO model ostvario skoro savršenu detekciju anomalija, sa mikroprosečnom AP vrednošću od 0,999 i AP vrednostima po klasama od 0,999 (normalna) i 0,998 (anomalna). Matrica konfuzije dodatno potvrđuje ovaj nalaz, ukazujući na 99,8% tačne identifikacije normalnih uzoraka i 99,7% tačne detekcije anomalne EEG aktivnosti, praćeno izuzetno niskim stopama lažnih uzbuna (0,2%) i propuštenih detekcija (0,3%). Ovi rezultati ističu snažnu pouzdanost i kliničku primenljivost predloženog pristupa za otkrivanje EEG anomalija.

Srednji red prikazuje rezultate Eksperimenta 2, gde je GRU-DADPSO model nastavio da funkcioniše izuzetno dobro, ostvarivši mikroprosečnu AP vrednost od 0,996 i AP vrednosti po klasama od 0,997 (normalna) i 0,995 (anomalna). Matrica konfuzije pokazuje 99,1% tačne klasifikacije normalnih signala i 99,8% detekcije anomalne EEG aktivnosti, uz niske stope lažnih uzbuna (0,9%) i propusta (0,2%). Ovi rezultati potvrđuju stabilnost i robusnost modela u alternativnim eksperimentalnim konfiguracijama.

Donji red prikazuje rezultate Eksperimenta 3, koji uključuje tri klase (normalna, anomalna i napad). U ovom zahtevnijem podešavanju, GRU-DADPSO model ostvario je snažnu mikroprosečnu AP vrednost od 0,968, uz posebno visoku performansu za detekciju napada ($AP = 0,986$). Normalna i anomalna klasa ostvarile su AP vrednosti od 0,803 i 0,825, redom. Matrica konfuzije otkriva odličnu detekciju napada sa stopom tačno pozitivnih od 99,0%, iako dolazi do izvesne pogrešne klasifikacije između normalnih i signala napada (20,3%), što odražava povećanu težinu svojstvenu multiklasnim scenarijima. Generalno, ovi rezultati demonstriraju da model održava visoku efikasnost za identifikaciju napada čak i kada se suočava sa složenijim zahtevima klasifikacije.

Tabela 32. Sveobuhvatne metrike performansi za najbolje optimizovane GRU modele u Eksperimentu 1


Model	Metric	Normal	Abnormal	Accuracy	Macro avg	Weight avg
GRU-DADPSO	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-PSO	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-VNS	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-GA	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-FA	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-BSO	Precision	0.997888	0.995575	0.996923	0.996732	0.996924
	Recall	0.996835	0.997046	0.996923	0.996941	0.996923
	F1-score	0.997361	0.996310	0.996923	0.996836	0.996923
GRU-RSA	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-SASS	Precision	0.997890	0.997046	0.997538	0.997468	0.997538
	Recall	0.997890	0.997046	0.997538	0.997468	0.997538
	F1-score	0.997890	0.997046	0.997538	0.997468	0.997538
GRU-COLSHADE	Precision	0.997888	0.995575	0.996923	0.996732	0.996924
	Recall	0.996835	0.997046	0.996923	0.996941	0.996923
	F1-score	0.997361	0.996310	0.996923	0.996836	0.996923
	Entries	948	677			

Tabela 33. Sveobuhvatne metrike performansi za najbolje optimizovane GRU modele u Eksperimentu 2


Model	Metric	Normal	Abnormal	Accuracy	Macro avg	Weight avg
GRU-DADPSO	Precision	0.996815	0.994008	0.995090	0.995412	0.995097
	Recall	0.990506	0.997995	0.995090	0.994250	0.995090
	F1-score	0.993651	0.995997	0.995090	0.994824	0.995087
GRU-PSO	Precision	0.987435	0.996642	0.993044	0.992038	0.993071
	Recall	0.994726	0.991979	0.993044	0.993352	0.993044
	F1-score	0.991067	0.994305	0.993044	0.992686	0.993049
GRU-VNS	Precision	0.990496	0.993320	0.992226	0.991908	0.992225
	Recall	0.989451	0.993984	0.992226	0.991718	0.992226
	F1-score	0.989974	0.993652	0.992226	0.991813	0.992225
GRU-GA	Precision	0.993624	0.991351	0.992226	0.992487	0.992232
	Recall	0.986287	0.995989	0.992226	0.991138	0.992226
	F1-score	0.989942	0.993665	0.992226	0.991803	0.992221
GRU-FA	Precision	0.983229	0.993289	0.989362	0.988259	0.989386
	Recall	0.989451	0.989305	0.989362	0.989378	0.989362
	F1-score	0.986330	0.991293	0.989362	0.988811	0.989368
GRU-BSO	Precision	0.987395	0.994638	0.991817	0.991017	0.991829
	Recall	0.991561	0.991979	0.991817	0.991770	0.991817
	F1-score	0.989474	0.993307	0.991817	0.991390	0.991820
GRU-RSA	Precision	0.990526	0.995315	0.993453	0.992920	0.993457
	Recall	0.992616	0.993984	0.993453	0.993300	0.993453
	F1-score	0.991570	0.994649	0.993453	0.993109	0.993455
GRU-SASS	Precision	0.982162	0.991952	0.988134	0.987057	0.988154
	Recall	0.987342	0.988636	0.988134	0.987989	0.988134
	F1-score	0.984745	0.990291	0.988134	0.987518	0.988140
GRU-COLSHADE	Precision	0.993610	0.990033	0.991408	0.991822	0.991421
	Recall	0.984177	0.995989	0.991408	0.990083	0.991408
	F1-score	0.988871	0.993002	0.991408	0.990937	0.991400
	Entries	948	1496			

Tabela 34. Detaljni rezultati performansi za najbolje optimizovane GRU modele u Eksperimentu 3


Model	Metric	Normal	Abnormal	Seizure	Accuracy	Macro avg	Weight avg
GRU-DADPSO	Precision	0.907692	0.893750	0.986480	0.978314	0.929308	0.978100
	Recall	0.797297	0.905063	0.989602	0.978314	0.897321	0.978314
	F1-score	0.848921	0.899371	0.988039	0.978314	0.912110	0.978094
GRU-PSO	Precision	0.808219	0.899371	0.986438	0.975450	0.898009	0.975413
	Recall	0.797297	0.905063	0.986438	0.975450	0.896266	0.975450
	F1-score	0.802721	0.902208	0.986438	0.975450	0.897122	0.975430
GRU-VNS	Precision	0.141618	0.155054	1.000000	0.526187	0.432224	0.919386
	Recall	0.662162	1.000000	0.487794	0.526187	0.716652	0.526187
	F1-score	0.233333	0.268479	0.655728	0.526187	0.385847	0.617903
GRU-GA	Precision	0.241830	0.550725	0.992267	0.885843	0.594941	0.941000
	Recall	1.000000	0.240506	0.928119	0.885843	0.722875	0.885843
	F1-score	0.389474	0.334802	0.959122	0.885843	0.561132	0.901513
GRU-FA	Precision	0.167800	0.475460	0.998211	0.778642	0.547157	0.939273
	Recall	1.000000	0.981013	0.756781	0.778642	0.912598	0.778642
	F1-score	0.287379	0.640496	0.860890	0.778642	0.596255	0.829277
GRU-BSO	Precision	0.116719	0.309255	0.991222	0.640753	0.472399	0.920655
	Recall	1.000000	0.867089	0.612568	0.640753	0.826552	0.640753
	F1-score	0.209040	0.455907	0.757195	0.640753	0.474047	0.721120
GRU-RSA	Precision	0.178788	0.161026	1.000000	0.554419	0.446605	0.920897
	Recall	0.797297	0.993671	0.514919	0.554419	0.768629	0.554419
	F1-score	0.292079	0.277140	0.679797	0.554419	0.416339	0.642027
GRU-SASS	Precision	0.064292	0.000000	0.998453	0.558511	0.354248	0.905620
	Recall	1.000000	0.000000	0.583635	0.558511	0.527878	0.558511
	F1-score	0.120816	0.000000	0.736662	0.558511	0.285826	0.670391
GRU-COLSHADE	Precision	0.089480	0.230171	1.000000	0.489362	0.439884	0.922663
	Recall	1.000000	0.936709	0.440325	0.489362	0.792345	0.489362
	F1-score	0.164262	0.369538	0.611425	0.489362	0.381742	0.582248
	Entries	74	158	2212			



Slika 31. Dijagrami raznovrsnosti roja funkcije cilja za sva tri eksperimenta



Slika 32. Radarski dijagrami makro i ponderisanih prosečnih vrednosti za Eksperimente 1-3



Slika 33. Vizuelizacije PR krive i matrice konfuzije za modele sa najboljim performansama u Eksperimentima 1-3

5.2.7. Statistička validacija rezultata

Radi sprovođenja statističke validacije, prikupljeni su uzorci najuspešnijih modela iz 30 nezavisnih izvršavanja svakog optimizatora. Pre primene parametarskih statističkih testova, bilo je neophodno proveriti da li su ispunjene potrebne pretpostavke. Ove pretpostavke uključuju nezavisnost, normalnost i homogenost varijansi podataka. Kriterijum nezavisnosti ispunjen je jer je svaki algoritam inicijalizovan sa različitim slučajnim semenom, što je proizvelo jedinstveni skup stohastičkih rešenja za svako izvršavanje.

Za procenu pretpostavke normalnosti, Shapiro-Wilk test primenjen je odvojeno na vrednosti funkcije cilja svakog od tri eksperimenta. Test je izvršen nezavisno za svaki algoritam, a rezultujuće p vrednosti sumirane su u Tabela 35. Pošto nijedan uzorak nije

zadovoljio uslov normalnosti, sa svim p vrednostima ispod 0,05, nulta hipoteza (H_0) je odbačena. Ovaj zaključak dodatno je potvrđen KDE dijagramima prikazanim na Slika 34, koji vizuelno potkrepljuju odsustvo normalnosti.

KDE dijagrami pokazuju da, iako GRU-DADPSO ostvaruje snažne vrednosti funkcije cilja, ne proizvodi dosledno najviši vrh gustine u Eksperimentima 2 i 3. U tim slučajevima, nekoliko konkurentskih optimizatora pokazuje oštrije i više vrhove, ukazujući na jaču stabilnost konvergencije. Ovaj efekat posebno je izražen u Eksperimentu 3, gde širi i niži KDE vrh GRU-DADPSO modela odražava povećanu varijabilnost u zahtevnijem multiklasnom podešavanju. Ova zapažanja sugerišu da, iako predloženi metod ostaje veoma efikasan u pogledu tačnosti detekcije, njegova stabilnost optimizacije osetljivija je na složenost problema u poređenju sa pojedinim alternativnim metaheuristikama.

Smanjena stabilnost, najizraženija u Eksperimentu 3, može se objasniti povećanom težinom zadatka. Preklapajuće raspodele klasa i veći višeklasni prostor pretrage stvaraju nepravilniji i zahtevniji pejzaž funkcije cilja. U takvim okolnostima, optimizator češće konvergira ka različitim lokalnim optimumima tokom nezavisnih izvršavanja, što rezultuje širim KDE raspedelama. Ovo ponašanje očekivano je u problemima detekcije epileptičkih napada i višeklasne EEG klasifikacije, gde inherentna nelinearnost i vremenska varijabilnost moždane aktivnosti značajno komplikuju proces optimizacije.

Kako Shapiro-Wilk testovi nisu potvrdili pretpostavku normalnosti, primena parametarskih statističkih testova ocenjena je kao neprikladna. Zbog toga je primenjen neparametarski Wilcoxonov *signed-rank* test. U ovoj evaluaciji, DADPSO metod je korišćen kao kontrolni algoritam. Rezultati Wilcoxonovog testa prikazani su u Tabela 36.


Rezultati statističke validacije usklađeni su sa ranijom analizom performansi zasnovanom na vrednostima funkcije cilja kroz 30 nezavisnih izvršavanja. Predloženi algoritam ostvario je rezultate statistički značajno superiorne u odnosu na sve ostale evaluirane metode u svakom eksperimentu, uz jedini izuzetak GA algoritma u Eksperimentu 3.

Tabela 35. Rezultati Shapiro-Wilk testa normalnosti

Problem	DADPSO	PSO	VNS	GA	FA	BSO	RSA	SASS	COLSHADE
Experiment 1	0.011	0.009	0.012	0.015	0.012	0.007	0.011	0.013	0.015
Experiment 2	0.016	0.027	0.021	0.019	0.014	0.019	0.022	0.014	0.023
Experiment 3	0.023	0.029	0.026	0.031	0.025	0.023	0.029	0.024	0.019

Tabela 36. Vrednosti p Wilcoxon signed-rank testa za sva tri scenarija (DADPSO u poređenju sa ostalima)

Problem	PSO	VNS	GA	FA	BSO	RSA	SASS	COLSHADE
Experiment 1	0.017	0.016	0.013	0.016	0.013	0.016	0.017	0.015
Experiment 2	0.032	0.036	0.038	0.034	0.033	0.046	0.032	0.023
Experiment 3	0.035	0.027	0.057	0.039	0.031	0.028	0.015	0.026



Slika 34. KDE dijagrami za Eksperimente 1-3

6. Zaključak

6.1. Kritički osvrt na urađeno istraživanje

Rezultati oba istraživanja potvrđuju da uvođenje kontrolisanog mehanizma za balansiranje eksploracije i eksploatacije u metaheurističku pretragu, bilo kroz postepeno prebacivanje na FA pretragu u IAVNS-u, bilo kroz dinamičko regulisanje raznovrsnosti populacije u DADPSO-u, donosi merljivu prednost u kvalitetu najboljeg pronađenog rešenja u odnosu na osnovne varijante VNS i PSO algoritma. Ova prednost je statistički potvrđena u oba slučaja, što ovim zaključcima daje veću težinu od pukog poređenja srednjih vrednosti. Istovremeno, oba istraživanja pokazuju da poboljšanje vrhunskih performansi dolazi sa kompromisom u stabilnosti. I IAVNS i DADPSO u pojedinim eksperimentima pokazuju veću varijansu između nezavisnih izvršavanja u odnosu na pojedine konkurentne algoritme, što je direktna posledica dizajnerskog izbora da se prioritet da kvalitetu najboljeg rešenja, a ne konzistentnosti svakog pojedinačnog izvršavanja. Ovaj kompromis treba imati u vidu prilikom eventualne praktične primene, jer stabilnost može biti podjednako važna kao i vrhunske performanse, u zavisnosti od konteksta primene.

Rezultati eksperimenta sa višeklasnom detekcijom epileptičnih napada (Eksperiment 3) ukazuju na jasnu granicu primenljivosti predloženog DADPSO pristupa. Dok je algoritam dominantan u binarnim scenarijima, njegova prednost nad konkurentima znatno se smanjuje, pa čak i gubi po pojedinim metrikama, kada se broj klasa i preklapanje njihovih granica poveća. Ovo je važno metodološko zapažanje, jer pokazuje da poboljšanje koje donosi predložena metaheuristika nije jednako izraženo u svim uslovima problema, u skladu sa NFL teoremom, a ne isključivo posledica generalne superiornosti algoritma. Slično tome, rezultati klasifikacije ptica pokazuju da se prednost IAVNS-a nad drugim algoritmima smanjuje na CatBoost nivou u odnosu na CNN nivo, gde je prostor pretrage hiperparametara očigledno gladak i sadrži širi plato skoro-optimalnih rešenja, što ukazuje na to da izbor metaheuristike ima različit uticaj u zavisnosti od osetljivosti osnovnog modela na hiperparametre.

Sa metodološke strane, glavni nedostatak oba istraživanja proizlazi iz istog izvora, ograničenih računskih resursa, koji su nametnuli male populacije (šest jedinki) i mali broj iteracija po izvršavanju. Ovakvo podešavanje je neophodno za praktičnu izvodljivost eksperimenata koji uključuju treniranje dubokih modela u svakoj iteraciji, ali istovremeno ograničava prostor u kojem se metaheuristike mogu u potpunosti razviti, pa je moguće da bi se razlike između algoritama, kako u korist tako i na štetu predloženih pristupa, drugačije ispoljile pri većim budžetima pretrage. Iz istog razloga, broj konkurentskih algoritama uključenih u poređenje bio je ograničen, a kod istraživanja klasifikacije ptica i broj razmatranih vrsta sveden je na šest, što umanjuje mogućnost generalizacije zaključaka na širi skup vrsta ili druga staništa. Kod istraživanja EEG anomalija, poređenje je ograničeno na jednu rekurentnu arhitekturu (GRU), bez direktnog empirijskog poređenja sa savremenim konkurentskim pristupima dubokog učenja nad istim podelama podataka, čime ostaje otvoreno pitanje koliko bi se uočena poboljšanja zadržala u odnosu na širi spektar savremenih modela.

6.2. Pravci budućih istraživanja

56 Dalji rad na predloženim metaheuristikama trebalo bi da obuhvati sistematsku analizu osetljivosti njihovih kontrolnih parametara (v_s i s_m kod IAVNS-a, *NRS* i dinamičkog praga kod DADPSO-a) na različitim veličinama populacije, budžetima iteracija i klasama problema, kako bi se utvrdilo da li su vrednosti usvojene u ovom istraživanju specifične za razmatrane zadatke ili prenosive na šire okvire primene. Takođe bi bilo korisno ispitati ponašanje oba algoritma pri znatno većim budžetima pretrage, dostupnim uz veće računске resurse, radi provere da li se uočeni kompromis između vrhunske performanse i stabilnosti zadržava i pri obimnijoj pretrazi.

U domenu bioakustičke klasifikacije, budući rad trebalo bi da prevaziđe ograničenje na šest vrsta ptica proširenjem analize na dodatna staništa i veći broj vrsta, uz paralelno istraživanje tehnika za smanjenje računskog opterećenja koje bi to omogućile. Integracija sa autonomnim terenskim uređajima za snimanje i sistemima za obradu podataka o životnoj sredini predstavlja prirodan sledeći korak ka praktičnoj primeni u nadzoru biodiverziteta, dok bi metodološki pravci poput transfera znanja između vrsta i staništa, kao i multimodalne fuzije akustičkih i vizuelnih podataka, mogli dodatno povećati robusnost pristupa u uslovima šuma prisutnog na terenu.

U domenu analize EEG signala, budući rad trebalo bi da uključi direktno poređenje sa alternativnim rekurentnim i savremenim arhitekturama dubokog učenja (LSTM, BiLSTM, transformer i hibridni pristupi) nad istim podelama podataka, kako bi se preciznije utvrdio doprinos DADPSO optimizacije nezavisno od izbora osnovnog modela. Prošireno podešavanje dodatnih hiperparametara, poput stope rekurentnog dropout-a, uz svest o pratećem porastu računskih troškova, takođe predstavlja logičan sledeći korak. Dugoročno, demonstrirana tačnost predloženog pristupa otvara prostor za razvoj sistema kontinuiranog praćenja pacijenata sa rizikom od epileptičnih napada, kao i za primenu srodne metodologije na druga klinička stanja kod kojih rana detekcija anomalija u vremenskim serijama medicinskih signala ima dijagnostičku vrednost.

Literatura

- Abdul, Z. Kh., & Al-Talabani, A. K. (2022). Mel Frequency Cepstral Coefficient and its Applications: A Review. *IEEE Access*, 10, 122136–122158. <https://doi.org/10.1109/ACCESS.2022.3223444>
- Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z. W., & Gandomi, A. H. (2022). Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications*, 191, 116158.
- Al-Betar, M. A., Awadallah, M. A., Braik, M. S., Makhadmeh, S., & Doush, I. A. (2024). Elk herd optimizer: a novel nature-inspired metaheuristic algorithm. *Artificial Intelligence Review*, 57(3), 48.
- Aljohani, M., Bahgat, W. M., Balaha, H. M., AbdulAzeem, Y., El-Abd, M., Badawy, M., & Elhosseini, M. A. (2024). An automated metaheuristic-optimized approach for diagnosing and classifying brain tumors based on a convolutional neural network. *Results in Engineering*, 23, 102459.
- Al-Sarem, M., Saeed, F., Boulila, W., Emara, A. H., Al-Mohaimed, M., & Errais, M. (2021). Feature selection and classification using CatBoost method for improving the performance of predicting Parkinson's disease. *Advances on Smart and Soft Computing: Proceedings of ICACIn 2020*, 189–199.
- Amin, U., & Benbadis, S. R. (2019). The role of EEG in the erroneous diagnosis of epilepsy. *Journal of Clinical Neurophysiology*, 36(4), 294–297.
- Anicin, L., Andjelic, S., Blagojevic, M. M., Bulaja, D., Zivkovic, M., Zivkovic, T., Antonijevic, M., & Bacanin, N. (2026). Metaheuristic-driven dual-layer model for classifying Alzheimer's disease stages. *Frontiers in Computational Neuroscience*, 20, 1731812.
- Bacanin, N., Jovanovic, L., Djordjevic, M., Petrovic, A., Zivkovic, T., Zivkovic, M., & Antonijevic, M. (2024). Crop Yield Forecasting Based on Echo State Network Tuned by Crayfish Optimization Algorithm. *2024 IEEE International Conference on Contemporary Computing and Communications (InC4)*, 1, 1–6.
- Bacanin, N., Jovanovic, L., Radic, G., Zivkovic, M., Kumpf, K., & Antonijevic, M. (2024). Exploring Echo State Network for Detection of Gait Freezing in Parkinson's Patients Optimized Through Modified Metaheuristics. In V. Shrivastava, J. C. Bansal, & B. K. Panigrahi (Eds.), *Power Engineering and Intelligent Systems* (pp. 57–68). Springer Nature Singapore.
- Bai, J., Li, Y., Zheng, M., Khatir, S., Benaissa, B., Abualigah, L., & Abdel Wahab, M. (2023). A Sinh Cosh optimizer. *Knowledge-Based Systems*, 282, 111081. <https://doi.org/https://doi.org/10.1016/j.knosys.2023.111081>
- Benarous, L., Gavaret, M., Diop, M. S., Tobarias, J., de Bourmont, S. de G., Allez, C., Bouzana, F., Gainnier, M., & Trebuchon, A. (2019). Sources of interrater variability and prognostic value of standardized EEG features in post-anoxic coma after resuscitated cardiac arrest. *Clinical Neurophysiology Practice*, 4, 20–26.
- Benbadis, S. R., Beniczky, S., Bertram, E., MacIver, S., & Moshé, S. L. (2020). The role of EEG in patients with suspected epilepsy. *Epileptic Disorders*, 22(2), 143–155.
- Benbadis, S. R., & Kaplan, P. W. (2019). The dangers of over-reading an EEG. *Journal of Clinical Neurophysiology*, 36(4), 249.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32.

- Bussmann, N., Giudici, P., Marinelli, D., & Papenbrock, J. (2021). Explainable Machine Learning in Credit Risk Management. *Computational Economics*, 57(1), 203–216. <https://doi.org/10.1007/s10614-020-10042-0>
- Cheng, S., & Shi, Y. (2011). Diversity control in particle swarm optimization. *2011 IEEE Symposium on Swarm Intelligence*, 1–9.
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21, 1–13.
- Cho, K., Van Merriënboer, B., Gulçehre, Ç., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1724–1734.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *ArXiv Preprint ArXiv:1412.3555*.
- Clark, M. L., Salas, L., Baligar, S., Quinn, C. A., Snyder, R. L., Leland, D., Schackwitz, W., Goetz, S. J., & Newsam, S. (2023). The effect of soundscape composition on bird vocalization classification in a citizen science biodiversity monitoring project. *Ecological Informatics*, 75, 102065.
- Dabic, P., Petrovic, J., Zivkovic, M., Zivkovic, T., Simic, V., Pamucar, D., Dobrojevic, M., & Bacanin, N. (2025). Hospital Admission Classification of Cardiac Patients Utilizing Metaheuristics-Optimized Two Tier Framework. *International Journal of Computational Intelligence Systems*.
- Davis, S. B., & Mermelstein, P. (1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 28(4), 357–366.
- Demsar, J. (2006). Statistical Comparisons of Classifiers over Multiple Data Sets. *Journal of Machine Learning Research*, 7, 1–30.
- Dhingra, A., & others. (2019). Review of MFCC in speech and audio processing applications. *International Journal of Speech Technology*, 22(3), 715–726.
- Dobrojevic, M., Jovanovic, L., Babic, L., Cajic, M., Zivkovic, T., Zivkovic, M., Muthusamy, S., Antonijevic, M., & Bacanin, N. (2024). Cyberbullying Sexism Harassment Identification by Metaheuristics-Tuned eXtreme Gradient Boosting. *Computers, Materials & Continua*, 80(3).
- Dogandzic, T., Bacanin, N., Vukmirovic, S., Selakov, A., Stankovic, M., Zivkovic, M., Radomirovic, B., Simic, V., Abdel-Salam, M., & Antonijevic, M. (2026). Tuning gated recurrent unit models for electroencephalogram anomaly detection with modified particle swarm optimization metaheuristics. *AIP Advances*, 16(8). <https://doi.org/10.1063/5.0349791>
- Dogandzic, T., Zivkovic, M., Jovanovic, L., Perisic, J., Milovanovic, M., Antonijevic, M., Hammad, M., & Bacanin, N. (2026). Classifying birds of South America via audio analysis using convolutional networks and boosting models optimized by metaheuristics. *Iran Journal of Computer Science*, 9(1), 13. <https://doi.org/10.1007/s42044-025-00363-4>
- Er, M., Bayaz, K., & Oktay Firat, S. Ü. (2025). SVR-Based Cryptocurrency Price Prediction Using a Hybrid FISA-Rao and Firefly Algorithm for Feature and Hyperparameter Selection. *Applied Sciences*, 15(24). <https://doi.org/10.3390/app152413177>

- Erdal Ozbek, M., Ozkurt, N., & Savaci, F. A. (2024). Enhancing Audio Classification Through MFCC Feature Extraction and Data Augmentation with CNN and RNN Models. *International Journal of Advanced Computer Science and Applications*, 15(7), 40–52.
- Farbod, K., & Karthikeyan, M. (2023). Multi-modal Vehicle Classification Using CNN and MFCC Feature Sets. *Applied Acoustics*, 203, 108135. <https://doi.org/10.1016/j.apacoust.2023.108135>
- Faris, H., Aljarah, I., Al-Betar, M. A., & Mirjalili, S. (2018). Grey wolf optimizer: a review of recent variants and applications. *Neural Computing and Applications*, 30, 413–435.
- Freund, Y., & Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1), 119–139.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 1189–1232.
- Fu, R., Zhang, Z., & Li, L. (2016). Using LSTM and GRU neural network methods for traffic flow prediction. *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)*, 324–328.
- Funosas, D., Barbaro, L., Schillé, L., Elger, A., Castagneyrol, B., & Cauchoix, M. (2024). Assessing the potential of BirdNET to infer European bird communities from large-scale ecoacoustic data. *Ecological Indicators*, 164, 112146.
- Glass, G. V. (1966). Testing Homogeneity of Variances. *American Educational Research Journal*, 3(3), 187–190. <https://doi.org/10.3102/00028312003003187>
- Gómez-Guzmán, M. A., Jiménez-Berista\’in, L., Garc\’ia-Guerrero, E. E., López-Bonilla, O. R., Tamayo-Perez, U. J., Esqueda-Elizondo, J. J., Palomino-Vizcaino, K., & Inzunza-González, E. (2023). Classifying brain tumors on magnetic resonance imaging by using convolutional neural networks. *Electronics*, 12(4), 955.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & others. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377.
- Guo, X., Gui, X., Xiong, H., Hu, X., Li, Y., Cui, H., Qiu, Y., & Ma, C. (2023). Critical role of climate factors for groundwater potential mapping in arid regions: Insights from random forest, XGBoost, and LightGBM algorithms. *Journal of Hydrology*, 621, 129599.
- Guo, Z., Wang, X., & Ge, L. (2023). Classification prediction model of indoor PM2. 5 concentration using CatBoost algorithm. *Frontiers in Built Environment*, 9, 1207193.
- Gurrola-Ramos, J., Hernández-Aguirre, A., & Dalmau-Cedeño, O. (2020). COLSHADE for real-world single-objective constrained optimization problems. *2020 IEEE Congress on Evolutionary Computation (CEC)*, 1–8.
- Hansen, P., & Mladenović, N. (2001). Variable neighborhood search: Principles and applications. *European Journal of Operational Research*, 130(3), 449–467. [https://doi.org/https://doi.org/10.1016/S0377-2217\(00\)00100-4](https://doi.org/https://doi.org/10.1016/S0377-2217(00)00100-4)
- Hansen, P., Mladenović, N., & Perez-Britos, D. (2001). Variable Neighborhood Decomposition Search. *Journal of Heuristics*, 7(4), 335–350. <https://doi.org/10.1023/A:1011336210885>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hosseini Shirvani, M., & Kanaan Salih, K. (2025). A survey on meta-heuristic-based workflow scheduling algorithms running in the cloud computing platforms. *Service Oriented Computing and Applications*. <https://doi.org/10.1007/s11761-025-00478-3>

- Ismail, W. N. (2025). A Novel Metaheuristic-Based Methodology for Attack Detection in Wireless Communication Networks. *Mathematics*, 13(11). <https://doi.org/10.3390/math13111736>
- Jarrett, D., & Willis, S. G. (2025). Acoustic detection rate can outperform traditional survey approaches in estimating relative densities of breeding waders. *Ibis*, 167(2), 562–574.
- Jia, H., Rao, H., Wen, C., & Mirjalili, S. (2023). Crayfish optimization algorithm. *Artificial Intelligence Review*, 1, 1. <https://doi.org/10.1007/s10462-023-10567-4>
- Jovanovic, A., Jovanovic, L., Zivkovic, M., Bacanin, N., Simic, V., Pamucar, D., & Antonijevic, M. (2024). Particle swarm optimization tuned multi-headed long short-term memory networks approach for fuel prices forecasting. *Journal of Network and Computer Applications*, 104048.
- Jovanovic, L., Bacanin, N., Zivkovic, M., Antonijevic, M., Petrovic, A., & Zivkovic, T. (2023). Anomaly detection in ecg using recurrent networks optimized by modified metaheuristic algorithm. *2023 31st Telecommunications Forum (TELFOR)*, 1–4.
- Karaboga, D., & Basturk, B. (2008). On the performance of artificial bee colony (ABC) algorithm. *Applied Soft Computing*, 8(1), 687–697.
- Kashefi Amiri, H., Zarei, M., & Daliri, M. R. (2025). Epileptic seizure detection from electroencephalogram signals based on 1D CNN-LSTM deep learning model using discrete wavelet transform. *Scientific Reports*, 15(1), 32820. <https://doi.org/10.1038/s41598-025-18479-9>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942–1948 vol.4. <https://doi.org/10.1109/ICNN.1995.488968>
- Kennedy, J., & Mendes, R. (2002). Population structure and particle swarm performance. *Proceedings of the 2002 Congress on Evolutionary Computation. CEC'02 (Cat. No.02TH8600)*, 2, 1671–1676 vol.2. <https://doi.org/10.1109/CEC.2002.1004493>
- Khishe, M., & Mosavi, M. R. (2020). Chimp optimization algorithm. *Expert Systems with Applications*, 149, 113338. <https://doi.org/https://doi.org/10.1016/j.eswa.2020.113338>
- Kumar, A., Das, S., & Zelinka, I. (2020). A self-adaptive spherical search algorithm for real-world constrained optimization problems. *Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion*, 13–14.
- Kumar, G. S. C., Kumar, R. K., Kumar, K. P. V., Sai, N. R., & Brahmaiah, M. (2024). Deep residual convolutional neural network: an efficient technique for intrusion detection system. *Expert Systems with Applications*, 238, 121912.
- Lameesa, A., Hoque, M., Alam, M. S. Bin, Ahmed, S. F., & Gandomi, A. H. (2024). Role of metaheuristic algorithms in healthcare: a comprehensive investigation across clinical diagnosis, medical imaging, operations management, and public health. *Journal of Computational Design and Engineering*, 11(3), 223–247. <https://doi.org/10.1093/jcde/qwae046>
- Lao, Z., He, D., Wei, Z., Shang, H., Jin, Z., Miao, J., & Ren, C. (2023). Intelligent fault diagnosis for rail transit switch machine based on adaptive feature selection and improved LightGBM. *Engineering Failure Analysis*, 148, 107219.

- LaTorre, A., Molina, D., Osaba, E., Poyatos, J., Del Ser, J., & Herrera, F. (2021). A prescription of methodological guidelines for comparing bio-inspired optimization algorithms. *Swarm and Evolutionary Computation*, 67, 100973. <https://doi.org/https://doi.org/10.1016/j.swevo.2021.100973>
- LeBien, J., Zhong, M., Campos-Cerqueira, M., Velez, J. P., Dodhia, R., Ferres, J. L., & Aide, T. M. (2020). A pipeline for identification of bird and frog species in tropical soundscape recordings using a convolutional neural network. *Ecological Informatics*, 59, 101113.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- Li, L., Liu, Z., Shen, J., Wang, F., Qi, W., & Jeon, S. (2023). A LightGBM-based strategy to predict tunnel rockmass class from TBM construction data for building control. *Advanced Engineering Informatics*, 58, 102130.
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., & Lee, S.-I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56–67. <https://doi.org/10.1038/s42256-019-0138-9>
- Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. In I. Guyon, U. V Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems 30* (pp. 4765–4774). Curran Associates, Inc. <http://papers.nips.cc/paper/7062-a-unified-approach-to-interpreting-model-predictions.pdf>
- Lyu, R. (2026). Deep learning approaches for EEG-based healthcare applications: a comprehensive review. *Frontiers in Human Neuroscience*, Volume 19-2025. <https://doi.org/10.3389/fnhum.2025.1689073>
- Majeed, S. A., Husain, H., Samad, S. A., & Idbeaa, T. F. (2023). Mel Frequency Cepstral Coefficient and its Applications: A Review. *IEEE Xplore*, 1–9. <https://doi.org/10.1109/ACCESS.2023.9955539>
- Markovic, V., Jovanovic, L., Zivkovic, M., Radomirovic, B., Njeguš, A., Abdel-Salam, M., Simic, V., & Bacanin, N. (2026). Attention Augmented Recurrent Architectures for Solar Energy Production Forecasting. *Applied Soft Computing*, 186, 114119. <https://doi.org/10.1016/j.asoc.2025.114119>
- Matthews, B. W. (1975). Comparison of the predicted and observed secondary structure of T4 phage lysozyme. *Biochimica et Biophysica Acta (BBA)-Protein Structure*, 405(2), 442–451.
- Medsker, L., & Jain, L. C. (1999). *Recurrent neural networks: design and applications*. CRC press.
- Meena, G., Mohbey, K. K., Indian, A., Khan, M. Z., & Kumar, S. (2024). Identifying emotions from facial expressions using a deep convolutional neural network-based approach. *Multimedia Tools and Applications*, 83(6), 15711–15732.
- Mirjalili, S. (2016). SCA: A Sine Cosine Algorithm for solving optimization problems. *Knowledge-Based Systems*, 96, 120–133.

- Mirjalili, S. (2019). Genetic Algorithm. In *Evolutionary Algorithms and Neural Networks: Theory and Applications* (pp. 43–55). Springer International Publishing. https://doi.org/10.1007/978-3-319-93025-1_4
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in Engineering Software*, 95, 51–67.
- Mladenovic, D., Antonijevic, M., Jovanovic, L., Simic, V., Zivkovic, M., Bacanin, N., Zivkovic, T., & Perisic, J. (2024). Sentiment classification for insider threat identification using metaheuristic optimized machine learning classifiers. *Scientific Reports*, 14(1), 25731.
- Mladenović, N., & Hansen, P. (1997). Variable neighborhood search. *Computers & Operations Research*, 24(11), 1097–1100. [https://doi.org/https://doi.org/10.1016/S0305-0548\(97\)00031-2](https://doi.org/https://doi.org/10.1016/S0305-0548(97)00031-2)
- Mumtahina, U., Alahakoon, S., & Wolfs, P. (2024). Hyperparameter Tuning of Load-Forecasting Models Using Metaheuristic Optimization Algorithms—A Systematic Review. *Mathematics*, 12(21). <https://doi.org/10.3390/math12213353>
- Nassif, A. E.-S., & others. (2019). Speech emotion recognition using convolutional neural networks. *IEEE Access*, 7, 132779–132801.
- Noachtar, S., & Rémi, J. (2009). The role of EEG in epilepsy: A critical review. *Epilepsy & Behavior*, 15(1), 22–33.
- Ozcalci, M., & Kilic, M. (2025). GA-LDA Approach for Topic Modeling in Turkish Accounting and Finance Articles: Performance Optimization in Text Classification. *Spectrum of Operational Research*, 2(1), 346–363. <https://doi.org/10.31181/sor21202521>
- Pahuja, R., & Kumar, A. (2021). Sound-spectrogram based automatic bird species recognition using MLP classifier. *Applied Acoustics*, 180, 108077.
- Paldino, M. J., Hedges, K., & Zhang, W. (2014). Independent contribution of individual white matter pathways to language function in pediatric epilepsy patients. *NeuroImage: Clinical*, 6, 327–332.
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). On the difficulty of training recurrent neural networks. *International Conference on Machine Learning*, 1310–1318.
- Piczak, K. J. (2015). Environmental sound classification with convolutional neural networks. *2015 IEEE 25th International Workshop on Machine Learning for Signal Processing (MLSP)*, 1–6.
- Polap, D., & Woźniak, M. (2017). Polar bear optimization algorithm: Meta-heuristic with fast population movement and dynamic birth and death mechanism. *Symmetry*, 9(10). <https://doi.org/10.3390/sym9100203>
- Polap, D., & Woźniak, M. (2021). Red fox optimization algorithm. *Expert Systems with Applications*, 166, 114107. <https://doi.org/https://doi.org/10.1016/j.eswa.2020.114107>
- Predić, B., Jovanovic, L., Simic, V., Bacanin, N., Zivkovic, M., Spalevic, P., Budimirovic, N., & Dobrojevic, M. (2024). Cloud-load forecasting via decomposition-aided attention recurrent neural network tuned by modified particle swarm optimization. *Complex & Intelligent Systems*, 10(2), 2249–2269.
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Advances in Neural Information Processing Systems*, 31.

- Qamar, W. U. R., Lee, M.-H., & Abibullaev, B. (2025). Deep learning in intracranial EEG for seizure detection: advances, challenges, and clinical applications. *Frontiers in Neuroscience*, 19. <https://doi.org/10.3389/fnins.2025.1677898>
- Rao, C., Xu, Y., Xiao, X., Hu, F., & Goh, M. (2024). Imbalanced customer churn classification using a new multi-strategy collaborative processing method. *Expert Systems with Applications*, 247, 123251.
- Samek Wojciech and Müller, K.-R. (2019). Towards Explainable Artificial Intelligence. In G. and V. A. and H. L. K. and M. K.-R. Samek Wojciech and Montavon (Ed.), *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning* (pp. 5–22). Springer International Publishing. https://doi.org/10.1007/978-3-030-28954-6_1
- Sanchez, F. J. B., Hossain, M. R., English, N. B., & Moore, S. T. (2021). Bioacoustic classification of avian calls from raw sound waveforms with an open-source deep learning architecture. *Scientific Reports*, 11.
- Saroja, S., & Haseena, S. (2024). A metaheuristic harmony search optimization–based approach for hateful and offensive speech detection in social media. In *Computational Intelligence Methods for Sentiment Analysis in Natural Language Processing Applications* (pp. 251–264). Elsevier.
- Shapiro, S. S., & Francia, R. S. (1972). An Approximate Analysis of Variance Test for Normality. *Journal of the American Statistical Association*, 67(337), 215–216. <https://doi.org/10.1080/01621459.1972.10481232>
- Shi, Y. (2011). Brainstorm optimization algorithm. *Advances in Swarm Intelligence: Second International Conference, ICSI 2011, Chongqing, China, June 12-15, 2011, Proceedings, Part I* 2, 303–309.
- Shi, Y., & Eberhart, R. (1998). A modified particle swarm optimizer. *1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No.98TH8360)*, 69–73. <https://doi.org/10.1109/ICEC.1998.699146>
- Sinha, B. B., Ahsan, M., & Dhanalakshmi, R. (2023). LightGBM empowered by whale optimization for thyroid disease detection. *International Journal of Information Technology*, 15(4), 2053–2062.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, 15(1), 1929–1958.
- Stojkovic, A., Nikolic, B., Zivkovic, M., & Bacanin, N. (2025). Photovoltaic Farm Production Forecasting: Modified Metaheuristic Optimized Long Short-Term Memory Based Networks Approach. *IEEE Access*.
- Tatum, W. O., Rubboli, G., Kaplan, P. W., Mirsatari, S. M., Radhakrishnan, K., Gloss, D., Caboclo, L. O., Drislane, F. W., Koutroumanidis, M., Schomer, D. L., Kasteleijn-Nolst Trenite, D., Cook, M., & Beniczky, S. (2018). Clinical utility of EEG in diagnosing and monitoring epilepsy in adults. *Clinical Neurophysiology*, 129(5), 1056–1082.
- Van Doren, B. M., Farnsworth, A., Stone, K., Osterhaus, D. M., Drucker, J., & Van Horn, G. (2024). Nighthawk: Acoustic monitoring of nocturnal bird migration in the Americas. *Methods in Ecology and Evolution*, 15(2), 329–344.
- Villoth, J. P., Zivkovic, M., Zivkovic, T., Abdel-salam, M., Hammad, M., Jovanovic, L., Simic, V., & Bacanin, N. (2025). Two-tier deep and machine learning approach optimized by

- adaptive multi-population firefly algorithm for software defects prediction. *Neurocomputing*, 630, 129695.
- Villoth, S. J., Dabic, P., Zivkovic, T., Zivkovic, M., Andjelic, S., Mravik, M., Simic, V., Abdel-Salam, M., & Bacanin, N. (2026). Cardiovascular Disease Risk Prediction Utilizing Two-Tier Classification Framework Optimized with Adapted Variable Neighborhood Search Algorithm. *Algorithms*, 19(2), 130.
- Viswanathan, S., & Ravichandran, K. S. (2025). Gain-based Green Ant Colony Optimization for 3D Path Planning on Remote Sensing Images. *Spectrum of Operational Research*, 2(1), 92–113. <https://doi.org/10.31181/sor21202510>
- Wei, Y.-C., Chen, W.-L., Tuanmu, M.-N., Lu, S.-S., & Shiao, M.-T. (2024). Advanced montane bird monitoring using self-supervised learning and transformer on passive acoustic data. *Ecological Informatics*, 84, 102927.
- Wilcoxon, F. (1992). Individual comparisons by ranking methods. In *Breakthroughs in statistics* (pp. 196–202). Springer.
- Wolpert, D. H., & Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67–82.
- Woolson, R. F. (2005). Wilcoxon Signed-Rank Test. *Encyclopedia of Biostatistics*. <https://doi.org/https://doi.org/10.1002/0470011815.b2a15177>
- Xie, J., Zhong, Y., Zhang, J., Liu, S., Ding, C., & Triantafyllopoulos, A. (2023). A review of automatic recognition technology for bird vocalizations in the deep learning era. *Ecological Informatics*, 73, 101927.
- Yang, X.-S., & He, X. (2013a). Bat algorithm: literature review and applications. *International Journal of Bio-Inspired Computation*, 5(3), 141–149.
- Yang, X.-S., & He, X. (2013b). Firefly algorithm: recent advances and applications. *International Journal of Swarm Intelligence*, 1(1), 36–50.
- Yang, X.-S., & Slowik, A. (2020). Firefly algorithm. In *Swarm intelligence algorithms* (pp. 163–174). CRC Press.
- Yin, Y., & others. (2019). Speech emotion recognition based on optimized CNN parameters. *IEEE Transactions on Neural Networks and Learning Systems*, 30(8), 2541–2554.
- Zhang, Y., Kim, J., & Zha, H. (2022). A deep CNN-based acoustic model for the identification of sound events. *Journal of the Acoustical Society of America*, 152(1), 128–136.
- Zivkovic, M., Bacanin, N., Zivkovic, T., Strumberger, I., Tuba, E., & Tuba, M. (2020). Enhanced grey wolf algorithm for energy efficient wireless sensor networks. *2020 Zooming Innovation in Consumer Technologies Conference (ZINC)*, 87–92.
- Zivkovic, T., Nikolic, B., Simic, V., Pamucar, D., & Bacanin, N. (2023). Software defects prediction by metaheuristics tuned extreme gradient boosting and analysis based on Shapley Additive Explanations. *Applied Soft Computing*, 146, 110659.
- Zivkovic, T., Zivkovic, M., Jovanovic, L., Simic, V., Radomirovic, B., Mzili, T., Zeljkovic, V., & Bacanin, N. (2026). Applying metaheuristic optimization for insider-threat detection using natural language processing. *International Journal of Data Science and Analytics*, 22(1), 68.

POPIS AKRONIMA


Akronim	Naziv na engleskom	Naziv na srpskom
ABC	<i>Artificial Bee Colony</i>	Algoritam veštačke pčelinje kolonije
AI	<i>Artificial Intelligence</i>	Veštačka inteligencija
AP	<i>Average Precision</i>	Prosečna preciznost
BSO	<i>Brainstorm Optimization</i>	Optimizacija olujom ideja
BVNS	<i>Basic Variable Neighborhood Search</i>	Osnovni algoritam pretrage promenljivog susedstva
CB	<i>CatBoost (Categorical Boosting)</i>	Algoritam pojačavanja gradijenta CatBoost
ChOA	<i>Chimp Optimization Algorithm</i>	Algoritam šimpanze
CNN	<i>Convolutional Neural Network</i>	Konvoluciona neuronska mreža
COA	<i>Crayfish Optimization Algorithm</i>	Algoritam rečnog raka
COLSHADE	<i>Constrained optimization algorithm based on SHADE</i>	Algoritam ograničene optimizacije zasnovan na SHADE
DADPSO	<i>Diversity Aware Dynamic PSO</i>	Dinamički PSO svestan raznovrsnosti populacije
DCT	<i>Discrete Cosine Transform</i>	Diskretna kosinusna transformacija
DWT	<i>Discrete Wavelet Transform</i>	Diskretna wavelet transformacija
EEG	<i>Electroencephalogram / Electroencephalography</i>	Elektroencefalogram / elektroencefalografija
EFB	<i>Exclusive Feature Bundling</i>	Grupisanje uzajamno isključivih obeležja (LightGBM)
EHO	<i>Elk Herd Optimization</i>	Optimizacija krdom jelena
EKG	<i>Electrocardiogram</i>	Elektrokardiogram
FA	<i>Firefly Algorithm</i>	Algoritam svica
FFE	<i>Function (Fitness) Evaluations</i>	Evaluacije funkcije cilja
FFT	<i>Fast Fourier Transform</i>	Brza Furijeova transformacija
FISA	<i>Fully Informed Search Algorithm</i>	Algoritam potpuno informisane pretrage
FN	<i>False Negative</i>	Lažno negativno
FP	<i>False Positive</i>	Lažno pozitivno
GA	<i>Genetic Algorithm</i>	Genetski algoritam

Akronim	Naziv na engleskom	Naziv na srpskom
GOSS	<i>Gradient-based One-Side Sampling</i>	Jednostrano uzorkovanje zasnovano na gradijentu (LightGBM)
GPU	<i>Graphics Processing Unit</i>	Grafička procesorska jedinica
GRU	<i>Gated Recurrent Unit</i>	Rekurentna jedinica sa kapijama
GWO	<i>Grey Wolf Optimizer</i>	Optimizator sivog vuka
IAVNS	<i>Iteration Aware Variable Neighborhood Search</i>	Iteraciono svestan VNS
KDE	<i>Kernel Density Estimation</i>	Procena gustine raspodele jezgrom
LGBM	<i>LightGBM (Light Gradient Boosting Machine)</i>	Algoritam pojačavanja gradijenta LightGBM
LSTM	<i>Long Short-Term Memory</i>	Duga kratkoročna memorija
MCC	<i>Matthews Correlation Coefficient</i>	Matthews-ov koeficijent korelacije
MFCC	<i>Mel Frequency Cepstral Coefficients</i>	Mel-kepstalni koeficijenti
NFL	<i>No Free Lunch (hypothesis/theorem)</i>	Hipoteza o nepostojanju besplatnog ručka
NRS	<i>Number of Replaced Solutions</i>	Broj zamenjenih (najlošijih) jedinki
PR	<i>Precision-Recall (curve)</i>	Kriva preciznost-osetljivost
PSO	<i>Particle Swarm Optimization</i>	Optimizacija rojem čestica
RAM	<i>Random Access Memory</i>	Memorija sa slučajnim pristupom
RGB	<i>Red Green Blue</i>	Model boja crvena-zelena-plava
RNN	<i>Recurrent Neural Network</i>	Rekurentna neuronska mreža
RSA	<i>Reptile Search Algorithm</i>	Algoritam pretrage reptila
RVNS	<i>Reduced Variable Neighborhood Search</i>	Redukovani VNS
SASS	<i>Self-Adaptive Spherical Search</i>	Smoadaptivna sferna pretraga
SCA	<i>Sine Cosine Algorithm</i>	Algoritam sinusa i kosinusa
SCHO	<i>Sinh Cosh Optimizer</i>	Optimizator zasnovan na hiperboličkim funkcijama sinh i cosh
SHAP	<i>SHapley Additive exPlanations</i>	Objašnjenja zasnovana na Šapijevim vrednostima
SVC	<i>Support Vector Classifier</i>	Klasifikator potpornih vektora


Akronim	Naziv na engleskom	Naziv na srpskom
SVR	<i>Support Vector Regression</i>	Regresija potpornih vektora
TN	<i>True Negative</i>	Tačno negativno
TP	<i>True Positive</i>	Tačno pozitivno
TreeSHAP	<i>Tree SHAP</i>	SHAP varijanta za modele zasnovane na stablima odlučivanja
VND	<i>Variable Neighborhood Descent</i>	Silazna pretraga promenljivog susedstva
VNDS	<i>Variable Neighborhood Decomposition Search</i>	Dekompozicioni VNS
VNS	<i>Variable Neighborhood Search</i>	Pretraga promenljivog susedstva
WOA	<i>Whale Optimization Algorithm</i>	Algoritam optimizacije kitova
XAI	<i>Explainable Artificial Intelligence</i>	Objašnjiva veštačka inteligencija
XGBoost	<i>Extreme Gradient Boosting</i>	Algoritam ekstremnog pojačavanja gradijenta

PRILOZI

Prilog 1: Koraci postupka izdvajanja MFCC obeležja iz audio signala




Prilog 2: Struktura veštačkog neurona: ulazni signali, ponderisana suma, aktivaciona funkcija i izlaz




Struktura veštačkog neurona: ulazni signali, ponderisana suma, aktivaciona funkcija i izlaz

Prilog 3: Arhitektura konvolucione neuronske mreže: konvolucioni, aktivacioni i pooling slojevi, flatten i potpuno povezani sloj




Prilog 4: Struktura GRU ćelije



Izvor: *fdeloche, Gated Recurrent Unit, Wikimedia Commons, 2017, dostupno pod licencom CC BY-SA 4.0.*

Prilog 5: Iterativni proces pojačavanja gradijenta




U svakoj iteraciji m , novi bazni model $h_m(x)$ obučava se da aproksimira pseudo-rezidual (negativan gradijent) r_m , prema jednačini (15)

$$\text{jednačina (14): } F_m(x) = F_{m-1}(x) + v \cdot h_m(x)$$


Izvor: *autorska izrada, prema Friedman, 2001.*

Prilog 6: Simetrično (oblivious) stablo u CatBoost algoritmu



Izvor: autorska izrada, prema Prokhorenkova et al., 2018.

Prilog 7: Ključne tehnike LightGBM-a - GOSS i EFB



Izvor: autorska izrada, prema Ke et al., 2017.

Prilog 8: Eksploracija i eksploatacija prostora pretrage

