



Univerzitet Singidunum
Departman za poslediplomske studije

Doktorski akademski program
Inteligentno softversko inženjerstvo

Doktorska disertacija

**Unapređenje detekcije abnormalne moždane aktivnosti
klasifikacijom vremenskih serija elektroencefalografskih
podataka korišćenjem modela dugoročne kratkoročne
memorije neuronskih mreža optimizovanih metaheuristikama**

Mentor:

prof. dr Miloš Stanković

Komentor:

prof. dr Angelina Njeguš

Student:

Branislav Radomirović
broj indeksa: 480191/2022

Beograd, 2025.



Singidunum University
Department of Doctoral Studies

Doctoral academic program
Intelligent Software Engineering

Doctoral dissertation

**Enhancement of Abnormal Brain Activity Detection Through
Time Series Classification of Electroencephalographic Data
Using Long Short-Term Memory Neural Network Models
Optimized by Metaheuristics**

Mentor:

prof. dr Miloš Stanković, PhD

Co-mentor:

prof. dr Angelina Njeguš, PhD

Candidate:

Branislav Radomirović
Index number: 480191/2022

Belgrade, 2025.

UNIVERZITET SINGIDUNUM
DEPARTMAN ZA POSLEDIPLOMSKE STUDIJE
Danijelova 32, Beograd

Kandidat: Branislav Radomirović

Broj indeksa: 480191/2022

Studijski program: Inteligentno softversko inženjerstvo

Tema:

Unapređenje detekcije abnormalne moždane aktivnosti klasifikacijom vremenskih serija elektroencefalografskih podataka korišćenjem modela dugoročne kratkoročne memorije neuronskih mreža optimizovanih metaheuristikama.

Mentor:

Prof. dr Miloš Stanković
Redovni profesor, Fakultet za informatiku i računarstvo, Beograd
Univerzitet Singidunum, Beograd

Članovi Komisije:

Prof. dr Angelina Njeguš
Redovni profesor, Fakultet za informatiku i računarstvo, Beograd
Univerzitet Singidunum, Beograd

Prof. dr Srđan Vukmirović
Redovni profesor, Fakultet Tehničkih Nauka, Novi Sad
Univerzitet Novi Sad

Unapređenje detekcije abnormalne moždane aktivnosti klasifikacijom vremenskih serija elektroencefalografskih podataka korišćenjem modela dugoročne kratkoročne memorije neuronskih mreža optimizovanih metaheuristikama

Apstrakt

Doktorska disertacija istražuje detekciju abnormalne moždane aktivnosti kod pacijenata poput epileptičkih napada, korišćenjem elektroencefalografskih podataka (EEG) i optimizovane dugoročne kratkoročne memorije neuronske mreže (LSTM). Istraživanja je motivisano činjenicom da tradicionalne metode analize EEG signala ne postižu zadovoljavajući nivo tačnosti, zbog inherentne složenosti podataka, nelinearnosti EEG signala, postojanja šuma u podacima koje je teško detektovati manuelnim pretragama. Uprkos brojnim pokušajima primene tradicionalnih algoritama mašinskog učenja, kao što su Support Vector Machines, k-Nearest Neighbors i drugi, ovi pristupi su davali ograničene rezultate kada su se bavili finim i suptilnim promenama u moždanoj aktivnosti pacijenata. To dovodi do pogrešnih ili nepotpunih medicinskih dijagnoza, a što ima direktan uticaj na izbor terapijskih mera i konačne zdravstvene ishode. Kao odgovor na ove izazove, predlaže se upotreba LSTM, koje su posebno dizajnirane za rad sa vremenskim serijama i koje mogu da zadrže informacije tokom dužih vremenskih perioda, nudeći poboljšanja u identifikaciji i klasifikaciji EEG obrazaca.

Ključni deo predloženog rešenja leži u optimizaciji hiperparametara LSTM primenom stohastičkog pristupa primenom metaheurističkih algoritama. Ovi algoritmi omogućavaju automatsko podešavanje parametara LSTM kao što su broj slojeva, veličina vremenskog prozora i broj neurona po sloju, čime se postiže inovativno i optimalno podešavanje modela u odnosu na karakteristike EEG podataka. Metodologija istraživanja obuhvata nekoliko faza. Prvo se vrši analiza EEG podataka kako bi se identifikovale karakteristike EEG signala koje su relevantne za detekciju epileptičkih napada. Nakon toga, LSTM se trenira na definisanom skupu podataka, korišćenjem metaheurističkog algoritma optimizacije pretrage susedstva radi optimizacije hiperparametara. Proces treniranja se iterativno sprovodi, gde se na svakom koraku meri tačnost, preciznost, osetljivost i specifičnost modela. Rezultati evaluacije pokazuju da predloženi model postiže značajno bolje performanse u odnosu na prethodno korišćene metode, kako u pogledu tačnosti detekcije epileptičkih napada, tako i u pogledu smanjenja lažnih pozitivnih detekcija.

Disertacija se osvrće i na praktičnu primenu rešenja u realnim kliničkim uslovima, gde efikasnost predloženog pristupa se ogleda kroz optimizovano vreme obrade i resursa potrebnih za treniranje, što omogućava analize EEG signala u realnom vremenu. Takođe disertacija ukazuje na buduće pravce razvoja u oblasti automatske analize biomedicinskih podataka i korišćenje multimodalnog pristupa. Dalja istraživanja treba da se fokusiraju na razvoj „lightweight“ modela koji su još efikasniji i manje zahtevni sa aspekta računarskih resursa. Zaključno, ova disertacija predstavlja sveobuhvatan pristup unapređenju detekcije abnormalne moždane aktivnosti kroz primenu naprednih tehnika analize EEG podataka kombinacijom LSTM i metaheurističke optimizacije hiperparametara.

Ključne reči: Elektroencefalografski podaci (EEG), Dugoročne kratkoročne memorije neuronskih mreža (LSTM), Epileptički napadi, Klasifikacija vremenskih serija, Metaheuristika, Stohastička optimizacija

Enhancement of Abnormal Brain Activity Detection Through Time Series Classification of Electroencephalographic Data Using Long Short-Term Memory Neural Network Models Optimized by Metaheuristics

Abstract

This dissertation explores the detection of abnormal a patient brain activity, such as epileptic seizures, using electroencephalography (EEG) data and optimized Long Short-Term Memory (LSTM) neural networks. The research is motivated by the fact that traditional methods of EEG signal analysis do not achieve a satisfactory level of accuracy due to the inherent complexity of the data, the non-linearity of EEG signals, and the presence of noise in the data that is difficult to detect through manual searches. Despite numerous attempts to apply traditional machine learning algorithms, such as Support Vector Machines, k-nearest Neighbors, and others, these approaches have yielded limited results when dealing with fine and subtle changes in patients' brain activity. This leads to incorrect or incomplete medical diagnoses, which directly impacts the choice of therapeutic measures and ultimate health outcomes. In response to these challenges, the use of LSTMs is proposed, which are specifically designed to work with time series data and can retain information over longer periods, offering improvements in the identification and classification of EEG patterns.

A key part of the proposed solution lies in the optimization of LSTM hyperparameters by applying a stochastic approach using metaheuristic algorithms. These algorithms enable the automatic optimization adjustment of LSTM parameters, such as the number of layers, time window size, and the number of neurons per layer, thereby achieving an innovative and optimal model configuration relative to the characteristics of EEG data. The research methodology encompasses several phases. First, EEG data is analyzed to identify the characteristics of EEG signals relevant to the detection of epileptic seizures. Subsequently, the LSTM is trained on a defined dataset, using a neighborhood search metaheuristic algorithm to optimize hyperparameters. The training process is carried out iteratively, with the accuracy, precision, sensitivity, and specificity of the model being measured at each step. The evaluation results demonstrate that the proposed model achieves significantly better performance compared to previously used methods, both in terms of the accuracy of epileptic seizure detection and in terms of reducing false positive detections.

The dissertation also addresses the practical application of the solution in real clinical settings, where the efficiency of the proposed approach is reflected in the optimized processing time and resources required for training, enabling real-time analysis of EEG signals. It also points to future directions of development in the field of automated biomedical data analysis and the use of a multimodal approach. Further research should focus on the development of lightweight models that are even more efficient and less demanding in terms of computational resources. In conclusion, this dissertation presents a comprehensive approach to improving the detection of abnormal brain activity through the application of advanced EEG data analysis techniques, combining LSTM and metaheuristic hyperparameter optimization.

Keywords: *Electroencephalography data (EEG), Long Short-Term Memory (LSTM) neural network model, Epileptic seizures, Time-series classification, Metaheuristics, Stochastic optimization*

Sadržaj

SPISAK SLIKA.....	VI
SPISAK TABELA	VIII
ALGORITMI	IX
1. UVOD	10
1.1. Metodološko-hipotetički okviri istraživanja.....	16
1.1.1. Problem istraživanja.....	16
1.1.2. Ciljevi i zadaci istraživanja	17
1.1.3. Hipoteze u istraživanju.....	17
1.1.4. Metode istraživanja	18
1.1.5. Naučna i društvena opravdanost istraživanja	19
1.2. Struktura rada	21
2. VEŠTAŠKA NEURONSKA MREŽA I PRIMENA U NEURODIJAGNOSTICI	23
2.1. Uvod u veštačke neuronske mreže	23
2.2. Matematički modeli u veštačkim neuronskim mrežama	27
2.2.1. Linearna algebra i primena u veštačkim neuronskim mrežama	28
2.2.2. Teorija verovatnoće i statistika sa primenom u veštačkim neuronskim mrežama	31
2.2.3. Informaciona teorija i primena u veštačkim neuronskim mrežama	35
2.2.4. Matematička analiza i primena u veštačkim neuronskim mrežama	38
2.2.5. Metode optimizacije i primena u veštačkim neuronskim mrežama	40
2.2.6. Teorija grafova i primena u veštačkim neuronskim mrežama	43
2.2.7. Matematičke teorije i prakse u primeni veštačkim neuronskim mrežama	45
2.2.8. Savremene veštačke neuronske mreže: Struktura i funkcionalnost	48
2.2.9. Primer primene veštačke neuronske mreže u klasifikaciji EEG Signala	56
2.2.10. Evaluacija i performanse veštačke neuronske mreže u neurodijagnostici EEG signala	77
2.3. Specijalizovane arhitekture neuronskih mreža za obradu EEG signala: RNN i LSTM	80
2.4. Pravci daljeg razvoja LSTM veštačkih neuronskih mreža	90
2.5. EEG tehnika i njen značaj u neurološkoj dijagnostici	92

3. DOSADAŠNJA ISTRAŽIVANJA I REGULATORNI OKVIR PRIMENE VEŠTAČKE INTELIGENCIJE U MEDICINSKOJ DIJAGNOSTICI EEG SIGNALA.....	96
3.1. Dosadašnja istraživanja u primeni veštačke inteligencije za analizu EEG signala	97
3.2. Industrijska primena LSTM modela u medicini	99
3.3. Regulatorni okviri i etički standardi	103
3.3.1. Evropski i međunarodni standardi	103
3.3.2. Regulatorni okviri u Republici Srbiji	105
3.3.3. Etika i tehničke inovacije u medicinskoj dijagnostici.....	110
3.3.4. Specifični etički izazovi u analizi EEG signala.....	112
3.3.5. Preporuke razvoja etičkih i regulatornih okvira u medicinskoj dijagnostici	113
3.4. Kontekstualna integracija istraživanja EEG tehnike	114
4. METODOLOGIJA ISTRAŽIVANJA ANOMALIJA EEG SIGNALA PUTEM LSTM I METAHEURISTIČKE OPTIMIZACIJE.....	118
4.1. Varijacije u interpretaciji medicinskih podataka i tehnički izazovi EEG signala	118
4.2. Opis skupa ulaznih podataka eksperimenta	119
4.3. Primena veštačke inteligencije u analizi EEG signala	125
4.3.1. LSTM neuronska mreža i primena u analizi EEG signala	128
4.3.2. Algoritam varijabilne pretrage susedstva sa dinamičkom promenom strategije	129
4.3.3. Osnovni algoritam pretrage varijabilnog susedstva.....	130
4.3.4. Nedostaci osnovnog algoritam pretrage varijabilnog susedstva i predložene izmene	131
4.4. Primeri primene LSTM-VNS iz kliničke prakse.....	143
5. EKSPERIMENTALNA EVALUACIJA – POSTAVKE, REZULTATI I POREĐENJE PERFORMANSI MODELA.....	146
5.1. Priprema eksperimenta	146
5.1.1. Opis i prethodna obrada skupa podataka	147
5.1.2. Metrike klasifikacije	150
5.1.3. Priprema simulacije	150
6. ANALIZA EKSPERIMENTALNIH REZULTATA I NAUČNI DOPRINOSI.....	152
6.1. Statistička validacija	169
6.2. Interpretacija najboljeg modela	173

7. ZAKLJUČAK I PERSPEKTIVE DALJEG RAZVOJA PRIMENE VEŠTAČKE INTELIGENCIJE U NEUROLOŠKOJ DIJAGNOSTICI	175
7.1. Oblici primene veštačke inteligencije u neurološkoj dijagnostici	178
7.1.1. Integracija multimodalnih podataka	179
7.1.2. Personalizovana medicina.....	179
7.1.3. Realno vremenska analiza i praćenje	179
7.1.4. Objašnjiva veštačka inteligencija (XAI)	179
7.1.5. Korišćenje transfer učenja	180
7.1.6. Razvoj integrisanih sistema za podršku odlučivanju	180
7.1.7. Razvoj AI alata za kućno praćenje	180
7.1.8. Razvoj AI modela za detekciju retkih neuroloških bolesti.....	180
7.1.9. Razvoj AI modela za predviđanje neuroloških bolesti.....	181
7.2. Inženjerske implikacije i primena optimizacionih algoritama	181
7.2.1. Optimizacija hiperparametara mašinskog učenja	181
7.2.2. Optimizacija raspoređivanja resursa	182
7.2.3. Optimizacija kontrolnih sistema.....	182
7.2.4. Optimizacija dizajna medicinskih uređaja	182
7.2.5. Optimizacija protoka podataka	182
7.3. Etička i regulatorna razmatranja.....	183
7.3.1. Privatnost i sigurnost podataka	183
7.3.2. Transparentnost i objašnjivost.....	183
7.3.3. Odgovornost i nadzor.....	183
7.3.4. Pristrasnost i pravičnost.....	184
7.3.5. Autonomija pacijenata	184
7.4. Zaključak	184
LITERATURA.....	187
SPISAK AKRONIMA.....	195

Spisak slika

Slika 1: Model veštačkog neurona McCulloh-Pitts, prilagođeno iz Hajaliasghari et al. (2020).	24
Slika 2: Šema Rozenblatovog Perceptron modela, prilagođeno iz Foreman i saradnici (2017).	25
Slika 3: Višeslojni Perceptron (MLP), preuzeto i prilagođeno iz Bendjoudi & Benyettou (2014).	26
Slika 4: Dijagram ReLU aktivacione funkcije veštačke neuronske mreže	50
Slika 5: Dijagram Sigmoid aktivacione funkcije veštačke neuronske mreže	51
Slika 6: Dijagram Tanh aktivacione funkcije veštačke neuronske mreže.....	52
Slika 7: Uticaj Min-Max normalizacije na EEG signale.....	57
Slika 8: Filtriranje šuma u EEG signalima <i>Butterworth</i> niskopropusnim filterom.....	60
Slika 9: Segmentacija podataka EEG signala na vremenske epohe.....	63
Slika 10: Spektrogram karakteristika EEG signal.....	66
Slika 11: Obrada EEG signala metodom zajedničkih prostornih modela (CSP).....	69
Slika 12: ReLU aktivaciona funkcija	73
Slika 13: Primena Softmax aktivacione funkcije u klasifikaciji	75
Slika 14: Poređenje RNN i LSTM predikcije	83
Slika 15: LSTM ćelija sa ažuriranjem stanja memorije	86
Slika 16: Primer LSTM modela u obradi EEG signala.....	88
Slika 17: Prikaz fokalnih i nefokalnih multikanalnih EEG signala eksperimenta	122
Slika 18: VNS-DS Optimizer GUI.....	134
Slika 19: Dijagram toka optimizacije matematičkog modela LSTM.....	148
Slika 20: Broj instanci uzoraka za podatke korišćene u eksperimentima 1, 2 i 3	148
Slika 21: Očitavanja moždane aktivnosti u skupovima podataka u eksperimentima 1, 2 i 3.	149
Slika 22: Dijagrami raspodele indikatorskih funkcija za Eksperiment 1	153

Slika 23: Dijagrami konvergencije indikatorskih funkcija za Eksperiment 1	154
Slika 24: Dijagrami raspodele funkcija cilja i indikatorskih funkcija za Eksperiment 2	160
Slika 25: Konvergencije funkcija cilja i indikatorskih funkcija za Eksperiment 3	162
Slika 26: Dijagrami raspodele funkcija cilja i indikatorskih funkcija za Eksperiment 3	167
Slika 27: Dijagrami konvergencije funkcije cilja i indikatorske funkcije za eksperiment 3	168
Slika 28: Dijagrami raznolikosti funkcije cilja roja za eksperiment 1, 2 i 3	170
Slika 29: Najbolji modeli sa PR krivama i matrica konfuzije za eksperiment 1, 2 i 3	172
Slika 30: Rezultati važnosti karakteristika u SHAP interpretaciji	173

Spisak tabela

Tabela 1: Pregled relevantnih naučnih istraživanja u oblasti analize EEG signala.....	99
Tabela 2: Parametri i njihovi odgovarajući rasponi za optimizaciju LSTM mreže.....	151
Tabela 3: Ukupne metrike funkcije cilja (stopa greške) za Eksperiment 1	152
Tabela 4: Najbolje određeni parametri za Eksperiment 1	155
Tabela 5: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 2	156
Tabela 6: Najbolje određeni parametri za Eksperiment 2	157
Tabela 7: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 3	158
Tabela 8: Najbolje određeni parametri za Eksperiment 3	163
Tabela 9: Detaljne metrike za Eksperiment 1	164
Tabela 10: Detaljne metrike za Eksperiment 2.....	165
Tabela 11: Detaljne metrike za Eksperiment 3.....	166
Tabela 12: Shapiro-Vilk testovi normalnosti.....	169
Tabela 13: Wilcoxon test potpisanih rangova: rezultati p-vrednosti za sva četiri scenarija (LSTM-VNS-DS vs ostali).....	171

Algoritmi

Algoritam 1: Python code ReLU aktivacione funkcije veštačke neuronske mreže	51
Algoritam 2: Python code Sigmoid aktivacione funkcije veštačke neuronske mreže.....	52
Algoritam 3: Python code Tanh aktivacione funkcije veštačke neuronske mreže	53
Algoritam 4: Python kod Min-Max normalizacije na EEG signale	59
Algoritam 5: Python kod filtriranje EEG signala <i>Butterworth</i> niskopropusnim filterom	62
Algoritam 6: Python kod segmentacije podataka u EEG signalima u vremenske epohe.....	65
Algoritam 7: Python kod za ekstrakciju karakteristika EEG signala	67
Algoritam 8: Python kod za obradu EEG signala zajedničkim prostornim modelom (CSP)..	71
Algoritam 9: Python kod za ReLU aktivacionu funkciju	74
Algoritam 10: Python kod Softmax aktivacione funkcije u klasifikaciji EEG signala	77
Algoritam 11: Poređenje RNN i LSTM predikcija	84
Algoritam 12: Python kod primene LSTM modela u obradi EEG signala	89
Algoritam 13: Python kod fokalnih multikanalnih i nefokalnih multikanalnih EEG signala	125
Algoritam 14: Pseudokod za VNS-DS optimizaciju	133
Algoritam 15: Python kod za Optimizer VNS-DS GUI	143

1. Uvod

Elektroencefalografija (EEG) predstavlja jednu od najvažnijih neurodijagnostičkih tehnika koja omogućava praćenje i analizu moždane aktivnosti. Ova tehnika se sprovodi pomoću seta elektroda koje su smeštene na površini glave pacijenta, gde tako postavljene elektrode beleže električne signale koji potiču iz neuronskih aktivnosti u mozgu pacijenta.

Električni impulsi koji su generisani sinhronizovanom aktivnošću velikih grupa neurona u mozgu pacijenta, detektuju se kao oscilacije električnih signala koje se prikazuju u obliku talasnih obrazaca. Svaka promena u ovim talasnim obrascima može ukazivati na neurološke poremećaje kod pacijenta, te shodno tome može implicirati potrebu za adekvatnim medicinskim tretmanom i monitoringom pacijenta.

Pošto je EEG metoda po svojoj prirodi dijagnostike neinvazivna metoda, ona predstavlja pre svega bezbedan i bezbolan način za otkrivanje i razlikovanje normalnih od abnormalnih električnih pražnjenja u mozgu pacijenta. Neinvazivnost kao glavna karakteristika ovog tipa medicinske dijagnostike, čini EEG dijagnostičku metodu izuzetno pogodnom za kontinuirano praćenje stanja pacijenata. Zahvaljujući ovoj izuzetno važnoj osobini neinvazivnosti, EEG dijagnostika se često koristi u rutinskim dijagnostičkim pregledima, omogućavajući kontinuirano praćenje funkcionalnog stanja mozga pacijenta bez ikakvog rizika od oštećenja tkiva ili pak mogućih komplikacija povezanih sa nekim drugim invazivnim metodama dijagnostike i lečenja.

Analiza EEG signala je jedan od ključnih medicinsko dijagnostičkih alata u identifikovanju epilepsije, bolesti u kojoj su napadi posledica abnormalnog električnog pražnjenja u grupama neurona pacijenta (Benbadis et al., 2020). Primena EEG dijagnostike omogućava ne samo identifikaciju epileptičkih napada, već i razgraničavanje različitih tipova epileptičkih napada, što je od izuzetne važnosti za pravilno planiranje terapije kod pacijenata.

Pored epilepsije, analiza EEG signala kao medicinski dijagnostički alat se široko koristi i za dijagnostiku drugih neuroloških stanja kod pacijenata. Na primer, metod analize EEG signala pomaže u identifikaciji poremećaja spavanja, kao što su apneja u snu i nesanica, jer putem analize EEG signala je moguće analizirati promene u moždanoj aktivnosti pacijenta tokom različitih faza spavanja. Takođe, analiza EEG signala je izuzetno korisna i u dijagnostici neurodegenerativnih bolesti poput Alzheimerove i Parkinsonove bolesti, gde se mogu uočiti karakteristični obrasci moždane aktivnosti, kao i u otkrivanju poremećaja svesti, što dodatno doprinosi sveobuhvatnoj dijagnozi i kasnijem lečenju pacijenata.

Osim dokazane dijagnostičke vrednosti, EEG dijagnostika se koristi i za praćenje efekata propisane terapije kod pacijenata. Kontinuirano praćenje EEG signala omogućava lekarima i kliničarima da procene efikasnost propisane i sprovedene terapije, te samim time prilagode lečenje u skladu sa promenama u moždanoj aktivnosti pacijenta. Na taj način, analiza EEG signala doprinosi dinamičkoj evaluaciji kliničkog stanja, što je posebno važno kod pacijenata kod kojih se sprovode dugotrajni terapijski režimi koji zahtevaju kontinuirani monitoring pacijenata.

Analiza EEG signala kao dijagnostička metoda, zahvaljujući kako svojoj neinvazivnosti, tako i dokazanoj kliničkoj praksi, omogućava praćenje i analizu moždane

aktivnosti pacijenta u realnom vremenu. Na taj način se otvara mogućnost za rano otkrivanje promena u moždanoj aktivnosti koje bi mogle biti indikatori progresije bolesti ili pak početka epileptičkih napada kod pacijenta. U kontekstu savremene medicine, analiza EEG signala se sve više integriše u automatizovane dijagnostičke sisteme za kontinuirano praćenje pacijenata, čime se omogućava brza intervencija u hitnim situacijama.

Jedna od glavnih prednosti EEG signala jeste njegova visoka vremenska rezolucija, što omogućava detekciju trenutnih promena u moždanoj aktivnosti pacijenta. Ovo znači da EEG signal može da detektuje i analizira vrlo brze i suptilne promene moždane aktivnosti kod pacijenta, poput onih aktivnosti koje se dešavaju u vremenskim okvirima od nekoliko milisekundi. Mogućnost detekcije i analize tako suptilnih i brzih promena moždane aktivnosti je ključno za praćenje trenutnih reakcija mozga pacijenata, kako na različite nadražaje i identifikaciju abnormalnosti, poput epileptičkih napada, tako i praćenje drugih poremećaja u moždanoj aktivnosti pacijenta.

Sa druge strane prostorna rezolucija EEG signala je ograničena u poređenju sa drugim tehnikama medicinske neurodijagnostike, kao što su magnetna rezonanca (*Magnetic Resonance Imaging*, MRI) ili pozitron-emisiona tomografija (*Positron Emission Tomography*, PET). Kao jedan od bitnijih problema primene analize EEG signala u medicinskoj neurodijagnostici jeste i činjenica da EEG signali mogu biti vrlo često ometeni različitim stimulusima, kao što su mišićni pokreti, treptanje, pa čak i spoljne elektromagnetne smetnje, što u konačnoj instanci otežavaju tumačenje rezultata EEG zapisa kod pacijenata.

Zbog mnogih faktora, ne samo gore navedenih, pouzdanost očitavanja EEG signala može značajno varirati od slučaja do slučaja, što pak može da oteža proces medicinske neurodijagnostike. Jedan od ključnih faktora koji utiču na preciznost očitavanja EEG zapisa jeste svakako subjektivnost interpretacije EEG podataka, što zavisi od iskustva, znanja i specifičnih metoda rada različitih medicinskih stručnjaka, specijalista za oblast medicinske neurodijagnostike. Različiti neurolozi i EEG tehničari mogu interpretirati iste EEG zapise na različite načine, jer se tumačenje podataka često oslanja na individualne procene, prethodna iskustva i subjektivno iskustvo kliničara (Benarous et al., 2019). Ova varijabilnost u interpretaciji dodatno komplikuje proces medicinske neurodijagnoze, naročito u slučajevima kada su abnormalnosti moždanih aktivnosti veoma suptilne ili prelazne, što zahteva izuzetno iskustvo i stručnost kliničara za pravilno prepoznavanje i interpretaciju EEG zapisa kod pacijenata.

Pored individualnih razlika među interpretatorima (neurolozi i EEG tehničari), pouzdanost očitavanja EEG signala zavisi i od faktora kao što su kvalitet dijagnostičke opreme, pravilno postavljanje elektroda, kao i uslovi u kojima se samo snimanje EEG zapisa vrši. Nedoslednosti u tehničkoj realizaciji EEG snimanja, kao što su loša povezanost elektroda ili pak prisustvo eksternih elektromagnetskih smetnji, mogu dodatno uticati na kvalitet EEG zapisa, te samim time i otežati samu interpretaciju EEG signala. U ovakvim uslovima, čak i najiskusniji neurolozi mogu doneti dijametralno različite zaključke, što definitivno dovodi do nesigurnosti u postavljenim dijagnozama i problema u kasnijim terapijskim terapijama.

Ova problematika ukazuje na potrebu za razvojem standardizovanih metoda interpretacije EEG signala, kao i na implementaciju automatizovanih dijagnostičkih sistema

koji mogu pružiti objektivne analize, smanjujući uticaj subjektivnosti i povećavajući doslednost rezultata medicinske neurodijagnostike.

Ono što je za očekivati da će se u bliskoj budućnosti pojaviti industrijski (ISO) standardi koji u potpunosti definišu korišćenje automatizovanih dijagnostičkih alata, koji kao osnovne mehanizme analize i interpretacije podataka koriste pre svega tehnologije veštačke inteligencije (*Artificial Intelligence*, AI) i mašinskog učenja podataka (*Machine Learning*, ML).

Tehnologije veštačke inteligencije i mašinskog učenja podataka imaju izuzetan potencijal da unaprede interpretaciju EEG podataka time što mogu identifikovati suptilne promene obrazaca u EEG zapisima, kao posledicu promena moždane aktivnosti pacijenata, koje ljudsko oko lako može prevideti, te samim time doneti pogrešnu dijagnozu. Ovakav pristup ne samo da bi omogućio preciznije i brže postavljanje dijagnoza, već bi povećala produktivnost kliničke prakse, smanjilo opterećenje neurologa i EEG tehničara, a što kao direktnu posledicu bi imalo bolju raspodelu resursa u zdravstvenim ustanovama i značajno poboljšanje obuhvata i kvaliteta zdravstvene zaštite u celini.

S obzirom na prethodno navedene izazove, automatizovani dijagnostički sistemi za analizu EEG signala, zasnovani na veštačkoj inteligenciji i metodama mašinskog učenja podataka, će se sve više koristiti za podršku kliničarima prilikom utvrđivanja dijagnoze. Ovi sistemi mogu doprineti pre svega standardizaciji tumačenja EEG zapisa, te samim time će se smanjiti varijabilnost i povećati preciznost dijagnoze kod pacijenata. Rana dijagnoza i lečenje epilepsije mogu značajno uticati na ishod bolesti, jer epileptični napadi imaju na žalost izuzetno izražen potencijal da trajno oštete mozak pacijenta ukoliko se ne kontrolišu na adekvatan način i sa propisanom terapijom (Benbadis et al., 2020).

Veštačka inteligencija već je pokazala značajan potencijal u brojnim industrijskim granama, a naročito u medicini, gde igra ključnu ulogu u medicinskoj dijagnostici (Kaur et al., 2021). Kroz primenu sofisticiranih algoritama veštačke inteligencije, procesi donošenja odluka u medicinskim ustanovama postaju brži, precizniji i efikasniji, što direktno utiče na poboljšanje zdravstvenih ishoda pacijenata (Saqlain & Saeed, 2024). Tehnologija kada se primenjuje na prethodno opisane načine, ne samo da omogućava bržu obradu podataka, već i integrisano (multimodalno) tumačenje kompleksnih obrazaca u medicinskim signalima, što može biti od presudne važnosti u kritičnim situacijama kod pacijenata.

Dok su mnoge oblasti u medicini već uspešno integrisale tehnologiju veštačke inteligencije i mašinskog učenja podataka u svoje radne procese, medicinska neurodijagnostika, posebno kada je reč o analizi moždane aktivnosti, ostaje relativno slabo istražena naučna oblast. Moždana aktivnost je inherentno dinamična i promenljiva tokom vremena, te zahteva specijalizovane pristupe za posmatranje i adekvatno tumačenje, a posebno je važno da se implicira integrisan princip neinvanzivnosti. U ovom kontekstu, primena tehnika klasifikacije vremenskih serija EEG signala postaje logično rešenje za obuku efikasnih matematičkih modela koji su sposobni da prepoznaju kako vremenske, tako i prostorne obrasce u kompleksnim podacima EEG signala koji opisuju moždane aktivnosti kod pacijenata (Devi et al., 2023; Tochaiwat et al., 2023).

Primena veštaštvačke inteligencije i mašinskog učenja podataka u medicinskoj neurodijagnostici omogućava automatsko otkrivanje i interpretaciju suptilnih promena u

moždanoj aktivnosti pacijenata koje bi inače mogle biti propuštene prilikom tradicionalnih, ručnih analiza.

Ovi napredni algoritmi mogu da integrišu i analiziraju različite izvore podataka, što pomaže u diferencijaciji između normalnih i patoloških obrazaca moždane aktivnosti kod pacijenata. Time se omogućava ne samo ranija dijagnoza, već i kontinuirano praćenje stanja pacijenata, što je posebno značajno u upravljanju hroničnim neurološkim poremećajima.

Razvoj tehnologija veštačke inteligencije i mašinskog učenja podataka u medicini otvara mogućnosti za personalizovanu medicinu, gde se terapijski pristupi mogu prilagoditi specifičnom obrascu moždane aktivnosti svakog pojedinačnog pacijenta. Automatizovani sistemi za dijagnostiku zasnovani na tehnologiji veštačke inteligencije i mašinskog učenja podataka, mogu pružiti kontinuirani nadzor i analizu kompleksnih podataka, što omogućava pravovremene intervencije i optimizaciju lečenja.

Uprkos svim pomenutim prednostima, immanentni su izazovi u implementaciji veštačke inteligencije i mašinskog učenja podataka u medicinskoj neurodijagnostici. Pre svega se tu misli na izazov u pogledu nedostatka adekvatnih i visoko kvalitetnih označenih podataka, kao i potreba za standardizacijom metoda akvizicije i analize podataka. Svi ovi izazovi ostaju značajni u modernoj medicinskoj neurodijagnostici, te zahtevaju dodatna istraživanja i razvoj.

U skladu sa prethodno opisanim izazovima, u prethodnom periodu se pristupilo primeni rekurentnih neuronskih mreža (*Recurrent Neural Networks*, RNN) kao jednog od najčešće korišćenih matematičkih modela za obradu vremenski zavisnih podataka. Arhitektura rekurentnih neuronskih mreža uključuje povratne veze koje omogućavaju prenošenje informacija između čvorova veštačke neuronske mreže u sukcesivnim vremenskim koracima. Ova sposobnost da zadrži informacije iz prethodnih stanja, sistemi rekurentnih neuronskih mreža dobijaju sposobnost neke vrste unutrašnje memorije neuorna, što je ključno za analizu podataka gde trenutne vrednosti podataka zavise od prethodnih, poput vremenskih serija. Poznato je da EEG signali često sadrže obrasce koji zavise od prethodnih uzoraka aktivnosti, a matematičkih modeli rekurentnih neuronskih mreža su u stanju da prepoznaju te obrasce, odnosno iz datih obrazaca izvuku korisne informacije.

Analiza sekvencijalnih podataka, podataka koji imaju dimenziju sekvencijalnosti poput vremenskih serija, putem rekurentnih neuronskih mreža omogućava bolji uvid u dinamičku prirodu EEG signala, te samim time čineći rekurentne neuronske mreže izuzetno pogodnim za zadatke kao što su predikcija, klasifikacija, i detekcija anomalija. Za trening rekurentnih veštačkih neuronskih mreža koristi se obično algoritam *Backpropagation Through Time* (BPTT), koji prilagođava težine matematičkog modela na osnovu prethodnih grešaka izračunatih za sekvencijalne podatke i različite vremenske trenutke. Primarna prednost rekurentnih neuronskih mreža leži u rekurentnim vezama, koje omogućavaju veštačkoj neuronskoj mreži da na nivou veštačkog neuorna „pamti“ ključne informacije iz dužih vremenskih perioda, čime pruža dodatnu analitičku dubinu za složene sekvencijalne podatke kao što su EEG signali.

Iako su rekurentne neuronske mreže pokazale određeni uspeh, u praksi se suočavaju sa značajnim izazovima. Jedan od glavnih problema je pojava eksplodirajućih i nestajućih gradijenata tokom procesa obuke (Pascanu, Mikolov, & Bengio, 2013), što otežava tačnu

analizu dugoročnih zavisnosti u podacima. Ovaj problem eksplodirajućih i nestajućih gradijenata može dovesti do lošijih performansi matematičkih modela, naročito kada se radi o složenim vremenskim serijama kao što su EEG podaci, koji najčešće sadrže izuzetno suptilne anomalije koje je izuzetno teško prepoznati.

Zbog ovih izazova, razvijene su naprednije tehnike modeliranja neuronskih mreža, kao što su Dugoročne-Kratkoročne Memorije veštačkih neuronskih mreža (*Long-Short Term Memory*, LSTM). LSTM veštačke neuronske mreže je specifična vrsta veštačke rekurentne neuronske mreže, koja koristi dodatne mehanizme kako bi zadržala relevantne informacije tokom dužeg vremenskog perioda, što omogućava efikasnije prepoznavanje obrazaca u vremenski zavisnim podacima. Ova tehnika pokazuje izuzetan potencijal u detekciji anomalija u EEG signalima, naročito kada je reč o epilepsiji, gde je cilj tačno identifikovati abnormalne moždane aktivnosti koje prethode ili prate epileptične napade kod pacijenta. Naučni cilj ove doktorske disertacije i samog naučnog istraživanja je razvoj matematičkih modela detekcije anomalija u EEG signalima, zasnovanog na LSTM veštačkim neuronskim mrežama, optimizovanog za analizu EEG podataka, kako bi se unapredila dijagnostika i olakšala identifikacija epileptičnih napada kod pacijenata.

Dalji napredak u ovoj oblasti mogao bi da omogući širu primenu tehnologija veštačke inteligencije u medicinskoj neurodijagnostici, ne samo za epilepsiju, već i za druge neurološke poremećaje, kao što su demencija ili Parkinsonova bolest, čime bi se značajno unapredili procesi donošenja dijagnostičkih odluka i samim time povećala preciznost u dijagnostici.

Cilj ovog naučno-istraživačkog rada je predlaganje i implementacija pristupa zasnovanog na klasifikaciji vremenskih serija EEG podataka koristeći matematičke modele LSTM veštačke neuronske mreže za detekciju nepravilne moždane aktivnosti, poput epileptičnih napada. Uzimajući u obzir složenost i dinamičku prirodu EEG podataka, matematički model LSTM veštačke neuronske mreže su odabrani zbog njihove sposobnosti da prepoznaju dugoročne zavisnosti u vremenskim serijama i efikasno detektuju abnormalnosti u signalima. Ovaj naučno-istraživački rad se fokusira na specifične izazove u analizi EEG podataka, naročito u kontekstu prepoznavanja epileptičnih napada, gde je pravovremena i tačna dijagnoza od suštinskog značaja za adekvatne zdravstvene ishode kod pacijenata.

Struktura LSTM veštačke neuronske mreže biće izabrana empirijski, gde pre sprovođenja glavnih eksperimenata, biće sprovedeni manji eksperimentalni testovi kako bi se matematički modeli LSTM veštačke neuronske mreže uporedili sa drugim osnovnim modelima rekurentnih neuronskih mreža, kao što su klasični RNN i *Gated Recurrent Units* (GRU). Cilj ovih poređenja je da se proceni prednost LSTM veštačke neuronske mreže u odnosu na druge modele (RNN/GRU) kada se primenjuju na EEG podatke, kao i da se ustanove optimalne konfiguracije hiperparametara za obuku matematičkog modela.

Kako bi se postigle poboljšane performanse matematičkog modela LSTM veštačke neuronske mreže, posebna pažnja biće posvećena optimizaciji izbora hiperparametara samog matematičkog modela. U ovom naučno-istraživačkom radu koristiće se metaheuristički algoritmi optimizacije, koji su poznati po svojoj sposobnosti da efikasno pretražuju velike prostore rešenja i pronalaze globalno optimalna rešenja u NP složenim problemima. Metaheuristički pristupi pružiće efikasne metode za podešavanje ključnih hiperparametara

LSTM veštačke neuronske mreže, kao što su broj slojeva, broj jedinica u slojevima, stope učenja, i veličina batch-a.

Dodatno, biće uvedena modifikovana varijanta algoritma varijabilne pretrage susedstva (*Variable Neighborhood Search*, VNS) (Mladenović i Hansen, 1997), koji je prilagođen specifičnim zahtevima ovog istraživanja. Klasični algoritam varijabilne pretrage susedstva se zasniva na ideji pretrage različitih susedstava radi pronalaženja boljih rešenja. U ovom naučno-istraživačkom radu, modifikovana verzija algoritma varijabilne pretrage susedstva biće prilagođena tako da unapredi performanse matematičkog modela LSTM veštačke neuronske mreže u kontekstu detekcije anomalne moždane aktivnosti pacijenta. Ova modifikacija omogućava dinamičku adaptaciju tokom procesa optimizacije, što dovodi do preciznijeg i bržeg pronalaženja optimalnih hiperparametara.

Predloženi pristup ima za cilj ne samo postizanje visoke tačnosti u detekciji epileptičnih napada, već i optimizaciju vremena potrebnog za obuku matematičkog modela, kao i smanjenje grešaka u klasifikaciji. Uspešno implementiran, ovaj matematički model mogao bi pružiti značajne prednosti u oblasti medicinske neurodijagnostike i pomoći neurolozima u pravovremenom prepoznavanju i lečenju epilepsije kod pacijenata.

Skup empirijskih podataka za potrebe ovog istraživanja sastojeće se od segmenata podataka koji su javno dostupni putem *NeuroTechnology and Systems Analysis* (NTSA) grupe sa Univerziteta Pompeu Fabra u Barseloni (<https://www.upf.edu>). Ovi podaci predstavljaju stvarne i već označene EEG snimke pacijenata, sa svim neophodnim atributima, koji su dostupni na njihovom sajtu (NTSA, <https://www.upf.edu/web/ntsa/downloads> 2024). Korišćenje ovog označenog seta podataka omogućava testiranje uvedenog pristupa sa relevantnim, stvarnim medicinskim zapisima anonimiziranih pacijenata, čime se doprinosi pouzdanosti i praktičnoj primenljivosti rezultata ovog istraživanja.

Testiranje matematičkog modela sprovedeće se kroz tri eksperimenta na osnovu modela LSTM veštačke neuronske mreže. Prvi eksperiment obuhvatiće osnovni matematički model LSTM veštačke neuronske mreže sa unapred podešenim hiperparametrima kako bi se odredila polazna tačka za dalju optimizaciju matematičkog modela. Drugi eksperiment fokusiraće se na primenu metaheurističkih algoritama za optimizaciju hiperparametara, uključujući veličinu batch-a, broj slojeva i jedinica u slojevima, kao i stopu učenja. Konačno, treći eksperiment uvodi modifikovanu varijantu algoritma varijabilne pretrage susedstva (Mladenović i Hansen, 1997), prilagođenu specifičnostima EEG podataka, kako bi se postigla dalja optimizacija i poboljšale performanse matematičkog modela. Ovi eksperimenti omogućavaju da se proceni uticaj različitih tehnika optimizacije na tačnost detekcije anomalne moždane aktivnosti, naročito u slučajevima epileptičnih napada kod pacijenata.

Očekivani naučni doprinosi ovog rada su:

- Formiranje sveobuhvatnog EEG skupa podataka radi olakšanja evaluacije detekcije epileptičnih napada i anomalija.
- Unapređenje postojeće tehnike klasifikacije za obradu EEG signala primenom klasifikacije vremenskih serija sa matematičkim modelom LSTM veštačke neuronske mreže, čime se doprinosi softverskoj detekciji abnormalne moždane aktivnosti kod pacijenata.

- Uvodi se modifikovani metaheuristički pristup za precizno prilagođavanje matematičkog modela LSTM veštačke neuronske mreže i optimizaciju hiperparametara modela, koji omogućava efikasnu klasifikaciju EEG signala.
- Biraju se efikasne klasifikacione veštačke neuronske mreže sa smanjenim brojem slojeva i neurona, čime se smanjuje potreba za brojem epoha treniranja i smanjuju se potrebni računarski resursi za treniranje.
- Ispituju se matematički modeli sa najboljim performansama kako bi se utvrdili značaj karakteristika u detekciji anomalija kada se koriste EEG podaci.
- Pruža se detaljno objašnjenje i istraživanje rada na ovu temu, adresirajući uočenu prazninu u postojećim naučnim istraživanjima vezanim za upotrebu rekurentnih veštačkih neuronskih mreža u detekciji anomalija u EEG signalima.

1.1. Metodološko-hipotetički okviri istraživanja

U okviru ovog rada postavlja se osnovno istraživačko pitanje: **Da li optimizacija LSTM veštačke neuronske mreže pomoću metaheurističkih algoritama može poboljšati tačnost detekcije epileptičkih napada na osnovu EEG podataka?**

Istraživanje se fokusira na testiranje hipoteze da kombinacija naprednih tehnika veštačkih neuronskih mreža, sa posebnim osvrtom na modele LSTM veštačkih neuronskih mreža, i primena metaheurističkih algoritama optimizacije hiperparametara može značajno poboljšati proces detekcije, čime se olakšava rano otkrivanje i klasifikacija epileptičkih napada kod pacijenata.

S obzirom na važnost tačne detekcije neuroloških poremećaja, cilj ovog naučno-istraživačkog rada je da potvrdi da optimizovani matematički modeli mogu značajno doprineti preciznosti i pouzdanosti u dijagnostici koristeći EEG signale. Kroz primenu specifičnih metaheurističkih pristupa za podešavanje hiperparametara modela LSTM veštačkih neuronskih mreža, očekuje se da će istraživanje pokazati poboljšanja u performansama matematičkog modela u poređenju s tradicionalnim metodama.

Ova istraživačka pitanja čine osnovu metodološkog okvira ovog naučno-istraživačkog rada, gde će predložena rešenja biti podvrgnuta sveobuhvatnoj analizi, implementaciji i rigoroznom testiranju kako bi se pružila validacija postavljene hipoteze.

1.1.1. Problem istraživanja

Ovaj naučno-istraživački rad se fokusira na problem koji proističe iz imanentnih ograničenja tradicionalnih metoda za detekciju epileptičkih napada kod pacijenata na osnovu EEG podataka. Tradicionalne metode vrlo često nisu pružale zadovoljavajuću tačnost, prvenstveno zbog složene prirode i inherentne nelinearnosti EEG signala. Kao što je poznato, EEG signale karakteriše visoki nivo inherentnog šuma koji po prirodi stvari može maskirati ključne obrasce EEG podataka u moždanoj aktivnosti pacijenta. Nelinearna dinamika EEG signala dodatno otežava modeliranje i otkrivanje zavisnosti u okviru EEG podataka, gde svakako treba spomenuti i visok stepen varijabilnosti između pacijenata.

Sve prethodno navedene činjenice dodatno otežavaju generalizaciju podataka i predstavljaju problem u implementaciji adekvatnog matematičkog modela neophodnog za pravilan rad sistema dijagnostika i analize EEG signala. Mnogi tradicionalni pristupi se i dalje oslanjaju na metode ručnog ekstrahovanja karakteristika EEG signala, za koje je potvrđeno da nisu u stanju u potpunosti da objasne izuzetno suptilne promene i obrasce u EEG podacima, a koji su opet izuzetno relevantni za detekciju epileptičkih aktivnosti kod pacijenata.

S obzirom na ove izazove, postoji potreba za unapređenjem metodološkog pristupa kroz primenu naprednih metoda medicinske neurodijagnostike baziranih na naprednim matematičkim modelima veštačke inteligencije i mašinskog učenja podataka, poput modela LSTM veštačke neuronske mreže, a koji su posebno pogodni za analizu vremenskih serija u EEG signalima, jer mogu „pamtiti“ relevantne informacije kroz duže vremenske intervale i ignorisati manje značajne šumove u podacima. Na taj način, unapređenje ovih novih metodoloških i naučnih pristupa pruža se potencijal za značajan doprinos u medicinskoj neurodijagnostici epilepsije i detekciji napada u realnom vremenu kod pacijenata.

1.1.2. Ciljevi i zadaci istraživanja

Cilj ovog naučno-istraživačkog rada je dvostruk: naučni i društveni. Naučni cilj ove disertacije je razvoj naprednog matematičkog modela za automatsku detekciju epileptičkih napada iz EEG zapisa koristeći matematički model LSTM veštačke neuronske mreže, čiji su hiperparametri optimizovani metaheurističkim tehnikama.

Društveni cilj ove disertacije je unapređenje dijagnostike epilepsije i pružanje dijagnostičkog alata koji bi omogućio bržu i precizniju analizu EEG signala, što može doprineti efikasnijem lečenju i boljoj kontroli epileptičnih napada kod pacijenata. Zadaci ovog naučno-istraživačkog rada obuhvataju sledeće naučne premise:

- Analizu postojećih metoda detekcije epileptičkih napada iz EEG podataka.
- Razvoj novog matematičkog modela LSTM veštačke neuronske mreže, specifično prilagođenog za analizu EEG signala.
- Implementaciju metaheurističkih algoritama za optimizaciju hiperparametara matematičkog modela LSTM veštačke neuronske mreže.
- Evaluaciju performansi matematičkog modela kroz eksperimentalno testiranje na relevantnim javnim skupovima medicinskih podataka.

1.1.3. Hipoteze u istraživanju

Na osnovu prethodno postavljenih naučnih i društvenih ciljeva ovog naučno-istraživačkog rada, formulisane su sledeće hipoteze koje su detaljno analizirane u okviru ove doktorske disertacije.

Opšta hipoteza: *Optimizacija LSTM veštačke neuronske mreže pomoću metaheurističkih algoritama može poboljšati tačnost detekcije epileptičkih napada kod pacijenata na osnovu EEG podataka.*

Pojedinačne hipoteze su:

H1: LSTM veštačke neuronske mreže mogu efikasno klasifikovati EEG podatke i detektovati anomalije u moždanoj aktivnosti kod pacijenata.

Ova hipoteza istražuje sposobnost modela LSTM veštačke neuronske mreže da prepozna složene obrasce u EEG signalima, a koji su ključni za identifikaciju neuroloških poremećaja, kao što su epileptični napadi kod pacijenata. Pretpostavka je da primena ovih matematičkih modela veštačke inteligencije može dovesti do značajnog unapređenja tačnosti detekcije abnormalnih moždanih aktivnosti kod pacijenata.

H2: Metaheuristički algoritmi mogu značajno unaprediti performanse modela LSTM veštačke neuronske mreže u detekciji epileptičnih napada kod pacijenata.

Ova hipoteza se fokusira na mogućnosti optimizacije modela LSTM veštačke neuronske mreže kroz primenu metaheurističkih algoritama, kao što su genetski algoritmi (*Genetic Algorithm*, GA) i optimizacija roja čestica (*Particle Swarm Optimization*, PSO). Cilj je da se istraži kako ovi algoritmi optimizacije mogu poboljšati preciznost i brzinu detekcije epileptičnih napada kod pacijenata optimizacijom hiperparametara LSTM veštačke neuronske mreže.

H3: Modifikovana pretraga putem algoritma varijabilne pretrage susedstva (VNS) može dodatno poboljšati prilagođavanje modela LSTM veštačke neuronske mreže specifičnostima EEG signala.

Ova hipoteza sugerise da primena modifikovane verzije algoritma varijabilne pretrage susedstva (*Variable Neighbourhood Search*, VNS) može povećati tačnost i efikasnost matematičkog modela LSTM veštačke neuronske mreže u analizi EEG podataka. Testira se kako ovaj pristup može optimizovati hiperparametre LSTM veštačke neuronske mreže, a samim time i proces detekcije epileptičnih napada kod pacijenata, posebno u situacijama sa ograničenom količinom podataka.

Predložene gore nevedene naučne hipoteze postavljaju okvir za razvoj naprednog matematičkog modela LSTM veštačke neuronske mreže radi analize EEG signala, a sa ciljem da se unapredi preciznost i brzina detekcije neuroloških poremećaja kod pacijenata i sa posebnim fokusom na epilepsiju kao jednu od najčešćih i najsloženijih neuroloških stanja kod pacijenata kod nas i u svetu.

1.1.4. Metode istraživanja

U ovom naučno-istraživačkom radu su primenjene sledeće naučno-istraživačke metode:

- **Analitičko-sintetička metoda:** Za analizu relevantne literature i dostupnih podataka o EEG signalima i epilepsiji, kao i za sintezu postojećih matematičkih modela i tehnika u svrhu razvijanja novog poboljšanog matematičkog modela.
- **Komparativna metoda:** Korišćena je za upoređivanje performansi razvijenog matematičkog modela sa postojećim rešenjima, kao i za evaluaciju različitih pristupa optimizaciji hiperparametara modela LSTM veštačke neuronske mreže.

- **Eksperimentalna metoda:** Ova metoda je primenjivana u fazi treniranja i testiranja modela LSTM veštačke neuronske mreže na stvarnim EEG podacima, gde su mereni ključni indikatori performansi, uključujući tačnost, preciznost i osetljivost.
- **Metaheurističke metode optimizacije:** U ovom naučno-istraživačkom radu primenjeni su algoritmi optimizacije kao što su genetski algoritam (*Genetic Algorithm*, GA) i algoritam optimizacije roja čestica (*Particle Swarm Optimization*, PSO), kako bi se optimizovali hiperparametri modela LSTM veštačke neuronske mreže, uključujući veličinu slojeva, broj neurona i dužinu vremenskog prozora.

Primena metaheurističkih algoritama optimizacije u ovom kontekstu je ključna za rešavanje problema visokog nivoa varijabilnosti u EEG podacima, pre svega jer omogućava dinamičnu optimizaciju hiperparametara veštačke neuronske mreže u skladu sa specifičnostima EEG signala (nelinearnost, šum,...).

Uvodnim delom naučno-istraživačkog rada postavljen je osnov za dalju analizu i istraživanje koje će se sprovesti u glavnim odeljcima ove doktorske disertacije. Identifikovan je problem detekcije epileptičkih napada kod pacijenata iz EEG signala, predložena su rešenja kroz primenu matematičkog modela LSTM veštačke neuronske mreže optimizovanog metaheurističkim algoritmima, a zatim su formulisani ciljevi i metodološki okvir istraživanja.

Dalji tok naučno-istraživačkog rada biće usmeren na analizu i implementaciju predloženih metoda optimizacije, kao i na eksperimentalnu evaluaciju performansi implementiranih metoda optimizacije matematičkog modela LSTM veštačke neuronske mreže koji je optimizovan metaheurističkim algoritmima.

1.1.5. Naučna i društvena opravdanost istraživanja

Činjenica je da primena veštačke inteligencije u medicinskoj dijagnostici neuroloških poremećaja u zemljama u razvoju, kao što je Republika Srbija, još uvek nije dostigla nivo razvijenih zemalja. Ovaj naučno-istraživački rad se temelji i na potrebama da se premoste postojeće praznine u znanju i tehnologiji, ka i da se izvrši adekvatna priprema za transfer tehnologije i znanje iz razvijenih zemalja u domenu primene moderne medicinske dijagnostike neuroloških poremećaja kod pacijenata.

Ovaj naučno-istraživački rad nije samo doprinos razvoju inovativnih metoda medicinske neurodijagnostike, već je i korak ka unapređenju celokupnog sistema zdravstva u Republici Srbiji. Ova doktorska disertacija, te naučno-društveni doprinosi iste, naravno mogu potencijalno dati doprinos u razvoju medisinke neurodijagnostike i u drugim zemljama sa sličnim izazovima u medicini i kliničkoj praksi. U naučnom smislu, ovaj naučno-istraživački rad istražuje mogućnosti primene i optimizacije hiperparametara matematičkog modela LSTM veštačke neuronske mreže za klasifikaciju EEG zapisa uz pomoć metaheurističkih algoritama, pružajući temelje za nove naučno-istraživačke radove u oblasti medicinske neurodijagnostike u Republici Srbiji.

Napredne metode veštačkih neuronskih mreža, naročito rekurentnih modela prilagođenih za vremenske serije, dopunjene su modifikovanim algoritmima optimizacije popute metode varijabilne pretrage susedstva koja će u svojoj modifikaciji detaljno biti opisana

u nastavku ove doktorske disertacije. Ove inovacije unapređuju preciznost detekcije abnormalnih EEG signala, što ima direktne implikacije na bolju dijagnostiku epilepsije kod pacijenata.

Razvijeni matematički modeli i pristupi ne samo da proširuju postojeće naučno znanje u oblasti primene veštačke inteligencije i mašinskog učenja podataka za medicinsku neurodijagnostiku, već predstavljaju metodološki okvir koji se može dalje razvijati i primenjivati na različite medicinske podatke (multimodalnost) i primeniti u široj medicinskoj praksi.

Društvena opravdanost ovog naučnog istraživanja ogleda se u sposobnosti da se značajno poboljša kvalitet života pacijenata kroz efikasniju dijagnostiku i kontinuirano praćenje efekata pripisane terapije. Preciznija i brža identifikacija neuroloških poremećaja kod pacijenata, pre svega kod oboljenja poput epilepsije, može imati pozitivne posledice na živote obolelih i njihovih porodica, smanjujući trajanje i intenzitet simptoma epilepsije i omogućavajući adekvatniji tretman pacijenata.

U Republici Srbiji, ali i zemljama na sličnom nivou ekonomske razvijenosti, gde su resursi za ovakvu verstu medicinske neurodijagnostike često ograničeni, implementacija naprednih matematičkih modela veštačke inteligencije i mašinskog učenja podataka može značiti transformaciju u kvalitetu zdravstvene nege na svim nivoima (primarni – sekundarni – tercijarni), doprinoseći ujedno povećanju iskorišćenosti postojećih resursa i smanjenju troškova zdravstvenog sistema u celini.

Pored direktnog uticaja na zdravstvenu praksu, rezultati ovog naučno-istraživačkog rada imaju potencijal da unaprede istraživačku i akademsku infrastrukturu u Republici Srbiji. Ovaj naučno-istraživački rad koristi rezultate i tehnologije razvijene u evropskim zemljama kao osnovu za lokalna istraživanja, olakšavajući na taj način institucijama Republike Srbije da usvoje inovativne pristupe u analizi EEG podataka i medicinskoj neurodijagnostici pacijenata. Ovaj aspekt naučne mobilnosti, odnosno usvajanja i transfera znanja iz razvijenih zemalja, omogućava brzo prilagođavanje domaće prakse svetskim standardima i otvara put ka daljem napretku medicinske neurodijagnostike u Republici Srbiji.

Disertacija takođe naglašava potrebu za strateškim investicijama i inovacijama u oblastima veštačke inteligencije i medicinske neurodijagnostike, podstičući saradnju između akademskih, istraživačkih i industrijskih aktera kako u Republici Srbiji tako i u regionu. Kroz razvoj inovativnih softverskih i hardverskih rešenja zasnovanih na veštačkoj inteligenciji i mašinskom učenju podataka, pogotovu u domenu medicinske dijagnostike, ovakva istraživanja mogu da služe kao primer kako dodatna ulaganja u zdravstvenu tehnologiju stvaraju pozitivan sistemski uticaj na društvo u celini.

U zaključku, ovaj naučno-istraživački rad pokazuje jasnu naučnu i društvenu opravdanost kroz značaj za unapređenje medicinske dijagnostičkih metoda u Republici Srbiji, poboljšanje kvaliteta života pacijenata, kao i postavljanje temelja za dalja istraživanja i primenu veštačke inteligencije i mašinskog učenja podataka u medicinskoj praksi u Republici Srbiji.

Rezultati ove doktorske disertacije čiji je deo objavljen u časopisu *Complex & Intelligent Systems* (M21 kategorije) u radu "*Optimizing Long-short Term Memory Neural Networks for Electroencephalogram Anomaly Detection using Variable Neighborhood Search*

with *Dynamic Strategy Change*" (Radomirovic et al., 2024), prošli su strogu verifikaciju eminentnih stručnjaka iz ove oblasti i značajni su za područje detekcije abnormalne moždane aktivnosti kod pacijenata.

1.2. Struktura rada

S obzirom na kompleksnost istraživanja u oblasti medicinske neurodijagnostike, kao i potrebe za detaljnim uvidom u različite aspekte primene veštačke inteligencije i mašinskog učenja podataka u analizi EEG signala, struktura ovog naučno-istraživačkog rada pažljivo je osmišljena kako bi pružila jasan tok naučno-istraživačke misli i omogućila bolji uvid u ciljeve i doprinose ovog naučnog istraživanja.

Rukovodeći se time, sadržaj ovog naučno-istraživačkog rada je podeljen na šest ključnih celina, pri čemu svaka celina (odjeljak) pruža neophodne informacije i rezultate, počevši od teorijskog osnova, preko prethodnih istraživanja, do detalja o naučno-istraživačkoj metodologiji, eksperimentalnim postavkama i postignutim rezultatima naučno-istraživačkog rada.

Zaključni deo ovog naučno-istraživačkog rada objedinjuje glavne nalaze i daje preporuke za buduća istraživanja u oblasti medicinske neurodijagnostike. Na taj način se zaokružuje kompletan naučno-istraživački rad jednom logičnom strukturom i celovitim prikazom kako matematički modeli LSTM veštačke neuronske mreže, sa optimizovanim hiperparametrima uz pomoć metaheurističkih algoritama, omogućavaju korišćenje veštačkih neuronskih mreža za detekciju anomalne moždane aktivnosti putem analize EEG signala.

- **Odeljak 1** predstavlja sveobuhvatnu teorijsku osnovu koja uvodi ključne pojmove i aktuelnosti u domenu veštačkih neuronskih mreža, sa posebnim fokusom na matematičke modele korišćene u naučnom eksperimentu ovog naučno-istraživačkog rada. U okviru ovog odeljka se diskutuje o osnovama EEG tehnike i njenom značaju za medicinsku dijagnostiku neuroloških poremećaja kod pacijenata. Detaljno su opisani svi faktori koji utiču na pouzdanost EEG očitavanja, uključujući varijabilnost među posmatračima (kliničarima), gde ujedno dat i opis sa tumačenjem izazova u interpretaciji EEG podataka. Ovo poglavlje pruža i svojevrsan uvid u ulogu veštačke inteligencije i mašinskog učenja podataka u analizi EEG signala, odnosno konačno definiše naučne i društvene ciljeve ovog naučno-istraživačkog rada.
- **Odeljak 2** izlaže dosadašnja naučna istraživanja koja čine osnovu ovog naučno-istraživačkog rada. Prikazana je sva neophodna matematička teorija potrebna za razumevanje modela veštačke inteligencije i mašinskog učenja podataka primenjenih u okviru ovog istraživanja. Detaljno su prikazana ključna dostignuća u primeni rekurentnih veštačkih neuronskih mreža (*Recurrent Neural Network*, RNN) i modela LSTM veštačkih neuronskih mreža u analizi vremenskih serija, sa naglaskom na izazove i ograničenja sa kojima se istraživači susreću u analizi vremenskih serija i nelinearnih signala. Navedeni su relevantni zakoni, regulative i protokoli koji se odnose na primenu veštačke inteligencije u medicinskoj neurodijagnostici na globalnom nivou, sa posebnim osvrtom na napredak u Republici Srbiji, te su posebno analizirani etički

izazovi u primeni veštačke inteligencije kao osnovne tehnologije u modernoj medicinskoj neurodijagnostici.

- **Odeljak 3** detaljno opisuje metodologiju istraživanja primenjenu u okviru ovog naučno-istraživačkog rada. U okviru ovog odeljka je prikazan detaljan pristup u detekciji anomalija u EEG signalima koji se zasniva na klasifikaciji vremenskih serija korišćenjem modela LSTM veštačke neuronske mreže. Objašnjena je struktura matematičkog modela LSTM veštačke neuronske mreže i postupak optimizacije hiperparametara uz pomoć metaheurističkih algoritama (*Genetic Algorithm* GA, *Particle Swarm Optimization* PSO). Takođe, navedena je i detaljno opisana optimizacija putem modifikovane varijante algoritma pretrage varijabilnog susedstva (*Variable Neighborhood Search*, VNS), razvijena posebno za potrebe ovog istraživanja.
- **Odeljak 4** prikazuje eksperimentalne postavke i krajnje rezultate ovog naučno-istraživačkog rada. Opisan je skup podataka korišćenih u istraživanju, uključujući segmente stvarnih i označenih podataka pacijenata iz javnog dostupnog repozitorija medicinskih podataka. Dati su detaljni rezultati eksperimenata sprovedenih korišćenjem modela LSTM veštačke neuronske mreže. Prikazano je poređenje performansi matematičkog modela LSTM veštačke neuronske mreže sa drugim rekurentnim modelima veštačkih neuronskih mreža radi omogućavanja boljeg uvida u prednosti predloženog pristupa. Opisane su metodološke i algoritamske metode, kao i mere koje su preduzete za povećanje tačnosti i efikasnosti matematičkog modela LSTM veštačke neuronske mreže korišćenjem metoda optimizacije hiperparametara korišćenjem metaheurističkog pristupa.
- **Odeljak 5** bavi se detaljnom analizom postignutih rezultata ovog naučno-istraživačkog rada. Prikazani su naučni doprinosi ovog naučno-istraživačkog rada, uključujući unapređenja u klasifikaciji vremenskih serija EEG podataka i predloženi modifikovani metaheuristički pristup za optimizaciju hiperparametara modela LSTM veštačke neuronske mreže. Analizirana je važnost karakteristika u detekciji anomalija na EEG podacima i date su preporuke za buduća istraživanja u ovoj izuzetno važnoj oblasti medicinske neurodijagnostike.
- **Odeljak 6** donosi zaključke doktorske disertacije sumiranjem ključnih nalaza istraživanja u odnosu na prvobitno usvojene hipoteze, razmatranjem ograničenja naučno-istraživačke studije i diskusijom o potencijalnim pravcima daljeg razvoja u oblasti primene veštačke inteligencije i mašinskog učenja podataka u medicinskoj neurodijagnostici. Naglašene su mogućnosti za dalja istraživanja i razvoj u ovoj oblasti, kao i preporuke za primenu predloženih rešenja u praksi, uz osvrt na specifične pravce razvoja medicinske neurodijagnostike u Republici Srbiji. Završni deo sumira glavne naučne doprinose i ističe društveni značaj ovog istraživanja za unapređenje medicinske dijagnostike neuroloških poremećaja primenom tehnologija veštačke inteligencije i mašinskog učenja podataka.

2. Veštačka neuronska mreža i primena u neurodijagnostici

Veštačke neuronske mreže (*Artificial Neural Network*, ANN) predstavljaju jedan od najznačajnijih metodoloških i naučnih dostignuća u domenu veštačke inteligencije i mašinskog učenja podataka, inspirisane biološkim neuronskim mrežama ljudskog mozga (Haykin, 2009).

Historijski gledano veštačke neuronske mreže razvijene su sa ciljem da imitiraju procese učenja i adaptacije koji se odvijaju u ljudskom mozgu, prenoseći ih u matematičke modele sposobne da distribuirano obrađuju i interpretiraju velike količine podataka.

Ovaj pristup omogućava automatsko otkrivanje i ekstrakciju skrivenih obrazaca u podacima, što je od ključnog značaja za rešavanje kompleksnih problema u različitim industrijskim i naučnim oblastima, od prepoznavanja slika i obrade prirodnog jezika, pa sve do biomedicinske dijagnostike (Goodfellow, Bengio, & Courville, 2016).


Veštačke neuronske mreže su se pokazale kao izuzetno korisne u biomedicinskoj dijagnostici, omogućavajući analizu medicinskih slika, genetskih podataka, EEG signala i drugih tipova podataka. Njihova sposobnost da automatski identifikuju karakteristike iz podataka, te da na bazi datih karakteristika uče i prepoznaju složene (suptilne) obrasce u samim podacima, čini ih idealnim za detekciju bolesti, predviđanje ishoda lečenja i personalizovanu medicinu.

2.1. Uvod u veštačke neuronske mreže

Prvi matematički modeli neuronskih mreža pojavili su se sredinom 20. veka, postavljajući temelje za razvoj matematičkih modela savremene veštačke inteligencije. Među pionirima ove oblasti svakako se ističu Warren McCulloch i Walter Pitts, koji su 1943. godine predložili prvi formalni model veštačkog neurona. Njihov rad se zasnivao na analogiji između funkcije biološkog neurona i matematičkih logičkih operacija. Ovaj rad je je imao za cilj da pokaže kako se kognitivni procesi mogu opisati formalnim jezikom matematike i logike (McCulloch & Pitts, 1943).

McCulloch-Pitts model veštačkog neurona bio je izuzetno jednostavan: predstavljao je binarnu jedinicu koja prima više ulaza, sabira ih i zatim primenjuje prag aktivacije (*threshold*) da bi generisala izlaz. Ulazi i izlazi su imali samo dve moguće vrednosti (0 i 1), što je model činio izuzetno pogodnim za izražavanje osnovnih logičkih operacija kao što su AND, OR i NOT. Na ovaj način McCulloch i Walter Pitts su demonstrirali da je moguće modelovati skoro bilo koju računsku funkciju korišćenjem kombinacije ovakvih veštačkih neurona što je bio revolucionaran uvid korišćenje matematičke logike u to vreme.

Iako je sam model veštačkog neurona bio ograničen, više teorijski model nego sa realnom praktičnom primenom, vrednost McCulloch i Walter Pitts veštačkog neurona leži u činjenici da je u ovom istraživanju prvi put formalno povezana neurobiologija sa matematičkom teorijom automata i računarstva. Naučni rad McCullocha i Pittsa je tako otvorio vrata za dalji razvoj veštačkih neuronskih mreža, ali i za širu oblast kognitivne nauke, gde je ideja da se kognitivni procesi mogu matematički modelovati, što je imalo ogroman filozofski i naučni odjek.



Slika 1: Model veštačkog neurona McCulloch-Pitts, prilagođeno iz Hajialiasghari et al. (2020).


Na Slici 1 prikazana je struktura McCulloch-Pitts veštačkog neurona, koja ilustruje osnovni princip funkcionisanja McCulloch-Pitts veštačkih neuronskih jedinica u okviru veštačke neuronske mreže. Model pokazuje kako se ulazne informacije (*stimul*) transformišu pomoću matematičkih logičkih funkcija i kako se kroz sabiranje ulaznih signala, u odnosu na definisani prag aktivacije (*threshold*), donosi odluka o aktivaciji veštačkog neurona. Iako ovaj model ne uključuje težinske faktore u savremenom smislu, njegova arhitektura je omogućila razvoj logičkog formalizma koji je postavio temelje za kasnije, naprednije modele veštačkih neuronskih mreža.

McCulloch-Pitts model veštačkog neurona je postao temelj za buduće arhitekture veštačkih neuronskih mreža i inspirisao kasnije mnogobrojne istraživače poput Franka Rosenblatta, koji je 1958. godine razvio perceptron model, prvi model sposoban za učenje putem podešavanja težina, čime je pak napravljen izuzetno važan pomak od teorijskih ka praktično primenljivim sistemima veštačkih neuronskih mreža.

Uprkos svojoj očiglednoj teorijskoj eleganciji, McCulloch-Pitts model veštačkog neurona je imao značajna ograničenja. Konkretno, nije bio sposoban da reprezentuje funkcije koje nisu linearno separabilne, poput XOR funkcije (isključivo ili), što znači da nije bilo moguće precizno razdvojiti klase podataka pomoću jednostavne linearne granice. Ovo ograničenje je postalo očigledno tek kasnije i motivisalo je razvoj složenijih arhitektura veštačkih neuronskih mreža koje uključuju više slojeva učenja i sofisticiranije mehanizme učenja, aktivacije veštačkih neurona.

Godine 1958, Frank Rosenblatt je predstavio *Perceptron* model, prvi operativni model veštačke neuronske mreže sposoban za učenje putem prilagođavanja težinskih koeficijenata i klasifikaciju binarnih podataka (Rosenblatt, 1958). Za razliku od McCulloch-Pitts modela, *Perceptron* model je uključivao koncept težina koje određuju značaj pojedinačnih ulaza, kao i mehanizam za njihovu iterativnu modifikaciju tokom procesa učenja. Osnovna struktura perceptrona sadrži ulazni sloj, jednostavan algoritam za sabiranje i primenu aktivacione funkcije veštačkog neurona, i izlaz koji odražava odluku veštačke neuronske mreže.

Perceptron je bio revolucionaran jer je pokazao da se mašine-automati mogu samostalno prilagođavati podacima bez eksplicitnog programiranja, otvarajući vrata za razvoj oblasti mašinskog učenja. Primena *Perceptron* modela u prepoznavanju obrazaca, jednostavnim klasifikacionim zadacima i rešavanju problema linearno separabilnih klasa bila je dokaz da veštačke neuronske mreže imaju praktičan potencijal. Iako je kasnije pokazano da klasični perceptron ne može rešiti nelinearno separabilne probleme (npr. XOR funkciju), ovaj matematički model je poslužio kao važna prekretnica koja je inspirisala razvoj višeslojnih perceptrona (*Multilayer Perceptron*, MLP) i algoritama kao što je propagacija unazad (*Backpropagation*).




Slika 2: Šema Rozenblatovog Perceptron modela, prilagođeno iz Foreman i saradnici (2017).

Na Slici 2 je prikazana šema koja prikazuje strukturu *Perceptron* matematičkog modela Frenka Rozenblata, koji se sastoji od tri sloja: ulaznih jedinica (S-jedinice), asocijativnih jedinica (A-jedinice) i izlaznih jedinica (R-jedinice) (Foreman et al. (2017)). Dati matematički model veštačkog neurona demonstrira osnovnu arhitekturu ranih veštačkih neuronskih mreža i predstavlja temelj za razvoj savremenih modela mašinskog učenja.

Istorijska je činjenica da *Perceptron* je imao značajna ograničenja, naročito u rešavanju nelinearnih problema, što je dovelo do određenog razočaranja kod istraživača u to vreme. Bez obzira na uočene nedostatke u pogledu obrade i analize nelinearnih podataka koje poseduje *Perceptron* model, Rosenblatt naučni rad je postavio temelje za dalji razvoj složenijih matematičkih modela veštačke inteligencije koji će se pojaviti u drugoj polovini XX veka.

Tokom 1960-ih i 1970-ih, istraživanje u oblasti veštačkih neuronskih mreža je donekle stagniralo zbog ograničenja *Perceptron* modela i nedostatka odgovarajućih algoritama za obuku složenijih matematičkih modela. Ovaj period se često naziva "zima veštačke inteligencije", jer su ograničenja *Perceptron* modela doveli do smanjenog interesovanja kako naučne zajednice tako i industrije za dalje istraživanja u ovoj oblasti, odnosno kasniju potencijalnu primenu u industrijskoj praksi.



Slika 3: Višeslojni Perceptron (MLP), preuzeto i prilagođeno iz Bendjoudi & Benyettou (2014).

Na Slici 3 je prikazana tipična arhitektura višeslojnog *Perceptron* modela, koja obuhvata ulazni sloj, skrivene slojeve sa više veštačkih neurona, kao i izlazni sloj. Svaki veštački neuron u okviru veštačke neuronske mreže je povezan sa svim veštačkim neuronima prethodnog i narednog sloja putem težinskih veza, koje određuju relativni značaj ulaznih podataka.

Kao što je opisano, 1980-e su donele značajan napredak, pre svega razvoj višeslojnih *Perceptron* modela (*Multilayer Perceptron*, MLP) i algoritma propagacije unazad (*Backpropagation*) (Rumelhart, Hinton, & Williams, 1986) što je omogućilo veštačkim neuronskim mrežama da efikasno uče složene nelinearne funkcije, što to tada nije bilo moguće sa osnovnim *Perceptron* modelom. Algoritam propagacije unazad je omogućio optimizaciju

težina u veštačkim neuronskim mrežama kroz iterativno prilagođavanje grešaka, što je značajno unapredilo mogućnosti učenja i kasniju primenu veštačkih neuronskih mreža u različitim oblastima industrije i nauke.

Tokom 1980-ih, višeslojni *Perceptron* modeli (MLP) su postali dominantni u istraživanju veštačkih neuronskih mreža, omogućavajući modeliranje kompleksnih nelinearnih funkcija. U otprilike isto vreme, pojavio se koncept *Representation Learning* (učenje reprezentacija) koji je postao centralni deo naučnog istraživanja u oblasti veštačke inteligencije. Ovaj koncept se odnosi na sposobnost veštačkih neuronskih mreža da automatski uče osobine (karakteristike) iz sirovih podataka, bez potrebe za manuelnim definisanjem ulaznih karakteristika. Ovo je bio ključni korak ka razvoju dubokog učenja (*Deep Learning*), jer je omogućio matematičkim modelima da sami otkrivaju relevantne obrasce u podacima, čime se smanjila potreba za ljudskom ekspertizom u domenu (Goodfellow, Bengio, & Courville, 2016).

2.2. Matematički modeli u veštačkim neuronskim mrežama

Matematički modeli koji se primenjuju u veštačkim neuronskim mrežama predstavljaju složenu mrežu matematičkih teorija i koncepata, ali se posebno ističu određene matematičke oblasti koje su ključne za razumevanje funkcionisanja veštačkih neuronskih mreža. Te oblasti omogućavaju da se pronikne u samu srž veštačkih neuronskih mreža, od njihovog osnovnog koncepta do složenih mehanizama učenja i prilagođavanja (generalizacija).

Linearna algebra igra fundamentalnu ulogu u predstavljanju i manipulaciji podacima unutar veštačkih neuronskih mreža. Vektori i matrice koriste se kako za kodiranje ulaznih podataka tako i težinskih faktora veza između neurona veštačke neuronske mreže. Operacije sa vektorima i matricama, kao što je množenje matrica, omogućava propagaciju signala kroz veštačku neuronsku mrežu, dok sabiranje i oduzimanje vektora služe za ažuriranje težinskih faktora tokom procesa učenja. Dekompozicija sopstvenih vrednosti i sopstvenih vektora pruža uvid u stabilnost i konvergenciju veštačke neuronske mreže, što je pak od suštinskog značaja za pravilno funkcionisanje veštačke neuronske mreže.

Matematička analiza omogućava da se razumeju koncepti kako se veštačke neuronske mreže optimizuju i prilagođavaju podacima. Izvodi i gradijenti, kao fundamentalni alati za računanje brzine promene (konvergencije) funkcije, koriste se za izračunavanje gradijenta funkcije gubitka, koji predstavlja meru greške matematičkog modela. Ovaj gradijent se zatim koristi za optimizaciju težinskih faktora matematičkog modela, čime se minimizira greška i poboljšava performansa matematičkog modela veštačke neuronske mreže. Integrali se koriste za regularizaciju matematičkog modela veštačke neuronske mreže, što sprečava prekomerno prilagođavanje trening podacima (*overfitting*). Teorija optimizacije pruža alate za pronalaženje optimalnih vrednosti težinskih faktora, što je ključno za postizanje najboljih rezultata, odnosno optimizaciju resursa neophodnih za treniranje i korišćenje sistema veštačke inteligencije.

Teorija verovatnoće i statistika omogućavaju da se modelira neizvesnost u podacima i predviđanjima veštačkih neuronskih mreža. Distribucije verovatnoće koriste se za opisivanje verovatnoće različitih ishoda događaja, dok Bayesova statistika omogućava ažuriranje verovanja o parametrima matematičkog modela na osnovu novih podataka. Statističko učenje

omogućava metode za procenu performansi matematičkog modela i sposobnost generalizacije matematičkog modela na nove podatke.

Informaciona teorija pruža alate za merenje i razumevanje informacija koje se obrađuju unutar veštačkih neuronskih mreža. Entropija se koristi za merenje neizvesnosti u podacima i matematičkim modelima, dok informaciona divergencija omogućava merenje razlike između distribucija verovatnoće. Teorija kodiranja omogućava kompresiju i rekonstrukciju podataka, što je korisno za efikasno skladištenje i prenos informacija u okviru veštačkih neuronskih mreža.

Teorija grafova omogućava da se modelira struktura veštačkih neuronskih mreža i odnosi između neurona. Grafovi se koriste za predstavljanje veštačke neuronske mreže, dok algoritmi pretrage grafova omogućavaju pronalaženje optimalnih puteva za propagaciju signala kroz veštačku neuronsku mrežu. Teorija mreža definiše alate za analizu složenih veštačkih neuronskih mreža i njihovih svojstava.

Metode optimizacije igraju ključnu ulogu u obuci i funkcionisanju veštačkih neuronskih mreža. Gradijentni spust i njegove varijante (*Stochastic Gradient Descent* SGD, *Adaptive Moment Estimation* Adam, *Root Mean Square Propagation* RMSProp, *Adaptive Gradient Algorithm* AdaGrad, *Adaptive Delta* AdaDelta, *Nesterov-accelerated Adaptive Moment Estimation* Nadam, *Adam with Adaptive Moment Scheduling* AMSGrad) omogućavaju iterativno ažuriranje parametara matematičkog modela (težine, pristrasnost) u smeru minimizacije funkcije greške. Metode drugog reda poput Njutnove (*Newton*) metode, *Broyden-Fletcher-Goldfarb-Shanno* (BFGS) metode koriste informacije o drugom izvodu funkcije za bržu konvergenciju, dok metaheuristički algoritmi (npr. genetski algoritmi) rešavaju složene probleme optimizacije, gde regularizacija sprečava prekomerno prilagođavanje matematičkog modela.

Ove matematičke oblasti čine temelj za razumevanje i razvoj veštačkih neuronskih mreža a njihova primena omogućava da se modeliraju složene odnosi u podacima, optimizujemo performanse matematičkog modela i analiziramo ponašanje veštačke neuronske mreže. U nastavku ovog naučno-istraživačkog rada opisani su detaljnije prethodno navedene oblasti matematike kao i njihova primena u modernim veštačkim neuronskim mrežama.

2.2.1. Linearna algebra i primena u veštačkim neuronskim mrežama

Linearna algebra predstavlja temelj za predstavljanje i manipulaciju podacima u veštačkim neuronskim mrežama. Ova grana matematike omogućava da se ulazni podaci, težinski faktori, prag aktivacije neurona i ostale numeričke vrednosti matematičkog modela veštačke neuronske mreže predstavljaju pomoću vektora i matrica, čime se obezbeđuje sistematski i efikasan način prikaza i obrade informacija.

U veštačkim neuronskim mrežama, operacije poput matričnog množenja, sabiranja i skalarnog množenja su ključne za transformaciju podataka kroz veštačku neuronsku mrežu i za prenos informacija između slojeva veštačkih neurona. Ovi koncepti omogućavaju precizno izračunavanje ulaznih vrednosti svakog veštačkog neurona, čime se postiže pravilno "širenje", odnosno propagacija informacija kroz veštačku neuronsku mrežu.

Razvoj linearne algebre prošao je kroz nekoliko ključnih istorijskih i evolutivnih faza, gde raniji doprinosi velikih matematičara, kao što su Gauss, Hamilton i Strang, su postavili temelje za moderne matematičke metode koje se danas koriste u obradi podataka.

Gauss je značajno unapredio koncept rešavanja sistema linearnih jednačina, dok je Hamilton uveo teoriju kvaterniona, što je uticalo na razvoj višedimenzionalnih algebarskih operacija. Gilbert Strang, jedan od vodećih autoriteta u ovoj oblasti, svojim radom i knjigama, kao što je *Introduction to Linear Algebra* (Strang, 1993), pružio je jasan i sveobuhvatan pregled osnovnih principa koji se primenjuju danas u veštačkim neuronskim mrežama.

U nastavku su opisani osnovni gradivni elementi linearne algebre kao matematičke discipline i primena elemenata linearne algebre u domenu veštačkih neuronskih mreža:

- **Vektori** se definišu kao uređene n -dimenzionalne liste skalara. Oni služe za predstavljanje ulaznih podataka, kao i izlaza pojedinačnih neurona u veštačkoj neuronskoj mreži. Ulazni podaci u veštačkim neuronskim mrežama mogu biti predstavljeni kao vektor x čiji su elementi pojedinačne karakteristike signala, u našem slučaju to su pojedinačne karakteristike EEG signala.
- **Matrice** su dvodimenzionalni nizovi brojeva i koriste se za predstavljanje težinskih parametara i pragova aktivacije veštačkog neurona između slojeva. Težinska matrica W povezuje ulazne vektore sa skrivenim slojevima veštačke neuronske mreže, a njeni elementi određuju jačinu veze između neurona u okviru veštačke neuronske mreže.
- **Matrično množenje** je ključna operacija koja omogućava transformaciju ulaznih podataka kroz veštačku neuronsku mrežu. Kada se ulazni vektor x pomnoži sa težinskom matricom W i doda se vektor pristrasnosti b (*bias*) koji omogućava matematičkom modelu veštačke neuronske mreže da pomeri izlaz aktivacione funkcije f tako da se bolje uklopi sa stvarnim podacima, čime se poboljšava tačnost matematičkog modela, dobija se transformisani ulaz koji se zatim prosleđuje aktivacionoj funkciji f veštačke neuronske mreže:

$$h = f(Wx + b) \quad (1)$$

gde h predstavlja izlaz skrivenog sloja, a f je aktivaciona funkcija veštačke neuronske mreže.

- **Sabiranje i oduzimanje matrica** vrši se element-po-element i koriste se za kombinovanje informacija iz različitih izvora podataka, na primer, prilikom dodavanja vektora pristrasnosti b u proizvod težinske matrice W i ulaznog vektora x .
- **Skalarno množenje** uključuje množenje svih elemenata vektora ili matrice određenim brojem (skalarnom). Ovo je korisno za skaliranje podataka, što može biti neophodno u procesu normalizacije podataka pre njihove obrade u samoj veštačkoj neuronskoj mreži.

Matematički modeli u veštačkim neuronskim mrežama se oslanjaju na kombinaciju operacija linearne algebre za transformaciju podataka i njihove pripreme za obradu kroz veštačku neuronsku mrežu. U veštačkoj neuronskoj mreži skriveni slojevi predstavljaju osnovu veštačke neuronske mreže, gde se odvija sva obrada podataka i učenja, a sastoje se od veštačkih neurona koji primaju podatke iz ulaznog sloja, vrše se nelinearne transformacije i prenos

rezultate dalje kroz potpuno povezanu veštačku neuronsku mrežu (*feedforward neural network*).

Svaki veštački neuron u skrivenim slojevima veštačke neuronske mreže ima težinske parametre i aktivacionu funkciju, koji omogućavaju da veštačka neuronska mreža nauči kompleksne obrasce u podacima, gde se ulazni podaci predstavljaju kao vektor x , težinske matrice kao W , a pristrasnosti u okviru samih podataka kao vektor pristrasnosti b .

Izračunavanje izlaza skrivenog sloja veštačke neuronske mreže se vrši pomoću sledeće formule:

$$h = f(Wx + b) \quad (2)$$

gde f predstavlja aktivacionu funkciju (npr. *ReLU*, Sigmoid funkcija ili hiperbolička tangens funkcija *Tanh*). Ova formula demonstrira kako se ulazni podaci transformišu kroz linearnu kombinaciju i zatim obrađuju nelinearnom aktivacionom funkcijom, čime se omogućava modelu da "nauči" složene obrasce i odnose između ulaznih podataka. Više detalja o samim aktivacionim funkcijama veštačkih neuronskih mreža će biti prikazano u nastavku disertacije, odnosno konkretno u okviru sledećih poglavlja ovog naučno-istraživačkog rada koji definiše matematičke modele naprednih veštačkih neuronskih mreža.

Kroz operacije matričnog množenja, sabiranja i skalarnog množenja, veštačke neuronske mreže mogu da obrađuju visoko-dimenzionalne podatke i efikasno ih prenose između različitih slojeva veštačke neuronske mreže. Bez ovih matematičkih osnova, ne bi bilo moguće implementirati algoritme za učenje kao što je propagacija unazad (*Backpropagation*), koji se oslanja na izračunavanje gradijenata funkcije greške i optimizaciju parametara veštačke neuronske mreže.

Optimizacija u veštačkim neuronskim mrežama, koja je ključna za proces učenja, oslanja se na operacije linearne algebre. Prilikom ažuriranja težina u veštačkoj neuronskoj mreži, između velikog broja tehnika, koristi se i stohastički gradijentni spust (*Stochastic Gradient Descent*, SGD), a koji se zasniva na sledećoj formuli:

$$W_{novi} = W_{stari} - \eta \cdot \nabla E(W) \quad (3)$$

gde η predstavlja stopu učenja, a $\nabla E(W)$ je gradijent funkcije greške u odnosu na težine. Gradijent $\nabla E(W)$ se izračunava koristeći operacije diferencijalnog računa, a zatim se primenjuje na težine koje se predstavljaju kao vektori i matrice. Efikasnost ovih operacija direktno zavisi od sposobnosti linearne algebre da rukuje velikim količinama podataka kroz precizne matrične operacije gde veliki izazov predstavlja činjenica da se date operacije matričnog množenja velikog skupa podataka sprovode na računarskim resursima sa ograničenom numeričkom preciznošću, jer se ipak radi o kontinuiranim matematičkim operacijama nad realnim brojevima u okviru računarskog procesora koji podržava diskretne matematičke operacije. Potrebno je samim time pažljivo odabrati adekvatne algoritme koji su numerički stabilni i otporni na očekivane greške zaokruživanja. Takođe je potrebno implementirati i tehnike za kontrolu i minimizaciju gubitka preciznosti operacija linearne algebre tokom obrade tako velikih količina podataka.

Razumevanje ovih osnovnih koncepata omogućava ne samo dublje razumevanje funkcionisanja veštačkih neuronskih mreža, već i mogućnost razvoja naprednih matematičkih

modela koji su sposobni da reše kompleksne probleme kako u različitim industrijskim tako i u naučnim oblastima poput medicinske neurodijagnostike. Linearna algebra, zajedno sa teorijom verovatnoće i informacionom teorijom, predstavlja temelj za kreiranje i optimizaciju veštačkih neuronskih mreža, čime se otvaraju nove mogućnosti u razvoju i primeni veštačke inteligencije u različitim industrijskim i naučnim oblastima.

2.2.2. Teorija verovatnoće i statistika sa primenom u veštačkim neuronskim mrežama

Teorija verovatnoće i statistike imaju dugu i bogatu istoriju, a sami počeci sežu još od doba 17. veka. Prvi koraci u razvoju teorije verovatnoće vezani su uz igre na sreću, gde su značajan doprinos dali su matematičari kao što su Blaise Pascal i Pierre de Fermat. U 18. veku, Jacob Bernoulli je postavio temelje Zakona velikih brojeva, a Abraham de Moivre je otkrio normalnu raspodelu slučajne promenljive.

Razvoj statistike kao naučne discipline usko je povezan sa radovima Carl Friedrich Gauss, koji je razvio matematičku metodu najmanjih kvadrata te ujedno dao i značajan doprinos teoriji grešaka. U 19. veku, statistika se počela primenjivati u različitim društvenim i naučnim oblastima, uključujući biologiju i medicinu, gde je Karl Pearson bio jedan od utemeljivača statistike kao moderne naučne discipline. Tokom 20. veka, teorije verovatnoće i statistike su se nastavile razvijati, a Andrey Kolmogorov je predstavio aksiomatsku definiciju verovatnoće. U današnje vreme ove dve grane matematike imaju široku primenu u različitim oblastima kako nauke i tehnologije, tako i društva u celini.

Teorija verovatnoće i statistika kao ključne matematičke discipline se koriste kako za modeliranje slučajnih događaja koji nisu deterministički određeni, odnosno poseduju nesigurnost kao atribut događaja, tako i za analizu varijacija i donošenje odluka na osnovu prikupljenih podataka u okviru datog eksperimenta. Teorija verovatnoće i statistike je od izuzetne važnosti za veliki broj kako društvenih aktivnosti tako i naučnih oblasti koje uključuju kvantitativnu i kvalitativnu analizu izuzetno masovnih skupova podataka.

U kontekstu veštačkih neuronskih mreža, koncepti koji su definisani u okviru teorije verovatnoće i statistike, omogućavaju kreiranje matematičkih modela koji kvantifikuju nesigurnost u svojim predviđanjima, definišu funkcije greške i poboljšaju robusnost sistema u celini. U nastavku ovog naučno-istraživačkog rada su predstavljeni osnovni koncepti iz teorije verovatnoće i statistike, odnosno pokazano je kako se ovi matematički principi primenjuju u različitim domenima veštačkih neuronskih mreža. Teorija verovatnoće i statistike pruža okvir za kvantifikovanje i analizu slučajnosti i nesigurnosti u podacima, pa tako i u podacima koje koristi veštačka neuronska mreža. Esencijalni pojmovi teorije verovatnoće i statistike pre svega uključuju definicije i pojmove verovatnoća, slučajna promenljiva, distribucija verovatnoća i statistički model. Verovatnoća predstavlja meru šanse da se određeni slučajni događaj desi, gde u matematičkom smislu, verovatnoća se definiše kao broj između 0 i 1, pri čemu 0 označava nemoguć događaj, a 1 siguran događaj. Slučajan događaj je događaj koji se dešava sa neizvesnim ishodom i ne može se predvideti unapred sa sigurnošću dešavanja. Teorija verovatnoće i statistike, definiše slučajan događaj kao deo skupa svih mogućih ishoda u jednom eksperimentu. U kontekstu veštačkih neuronskih mreža, verovatnoća se koristi za modeliranje

nesigurnosti, stohastike u ulaznim podacima i pri donošenju odluka, kao i za procenu performansi samog matematičkog modela veštačke neuronske mreže.

Slučajne promenljive su promenljive čije vrednosti zavise od ishoda slučajnog događaja, gde slučajne promenljive mogu biti diskretne (npr. broj uspešnih eksperimenata) ili neprekidne (npr. vreme do pojave događaja). Za diskretne slučajne promenljive, verovatnoća da slučajna promenljiva X uzme određenu vrednost x opisuje se funkcijom raspodele verovatnoće (*Probability Mass Function*, PMF), često obeleženom sa $p(x)$ ili $P(X = x)$. Ova funkcija dodeljuje verovatnoću svakoj mogućoj vrednosti slučajne promenljive X , pri čemu zbir svih verovatnoća mora biti jednak 1. Za neprekidne slučajne promenljive, verovatnoća da slučajna promenljiva X uzme određenu vrednost x (u stvari, verovatnoća da se nađe u nekom infinitezimalnom intervalu oko x) opisuje se funkcijom gustine verovatnoće (*Probability Density Function*, PDF), često obeleženom sa $f(x)$. Ova funkcija ne predstavlja direktno verovatnoću, već "gustinu" verovatnoće u datoj tački. Verovatnoća da se X nađe u nekom intervalu (a, b) izračunava se kao određeni integral funkcije gustine verovatnoće u datom intervalu.

Osnovna razlika između funkcije raspodele verovatnoće (PMF) i funkcije gustine verovatnoće (PDF) je u tome što se PMF koristi za diskretne slučajne promenljive, a PDF za neprekidne. Kod diskretnih promenljivih, PMF direktno daje verovatnoću za svaku vrednost, dok kod neprekidnih promenljivih, PDF daje "gustinu" verovatnoće, a verovatnoća se izračunava integracijom, odnosno primenom određenog integrala na funkcije gustine verovatnoće u datom intervalu (a, b) . Razumevanje funkcija raspodele verovatnoće i funkcija gustine verovatnoće ključno je za analizu podataka i modeliranje slučajnih pojava. Ove funkcije omogućavaju da se opišu varijacije u podacima, da se izračunaju verovatnoće različitih ishoda i da se donose informisani zaključci na osnovu podataka. U kontekstu primene funkcija raspodele verovatnoće i funkcija gustine verovatnoće kod veštačkih neuronskih mreža, ove funkcije se koriste za modeliranje ulaznih podataka, za definisanje funkcija gubitka i za procenu nesigurnosti u predikcijama matematičkog modela.

U analizi podataka, slučajne promenljive omogućavaju matematičkim modelima da predstave varijacije u podacima i da kvantifikuju nesigurnost. Na primer, u medicinskoj neurodijagnostici, vreme između epileptičkih napada kod pacijenata može se modelovati kao slučajna promenljiva čija distribucija pruža detaljan uvid u dinamiku bolesti. Distribucije verovatnoće se opisuju kako su vrednosti slučajnih promenljivih raspoređene. Najčešće korišćene distribucije u okviru matematičkih modela koji su primenjuju u sistemima veštačke inteligencije su:

- **Normalna distribucija** (Gaussova distribucija) opisuje raspodelu podataka koja je simetrična oko proseka. Često se koristi u statističkim modelima zbog Centralne granične teoreme, koja kaže da će zbir velikog broja nezavisnih slučajnih promenljivih težiti ka normalnoj distribuciji (Draper & Smith, 1998).
- **Binomnu distribuciju:** Koristi se za modeliranje broja uspeha u fiksiranom broju nezavisnih Bernoullijevih eksperimenata.
- **Poasonovu distribuciju:** Primenjuje se kada se modeluje broj događaja u fiksnom vremenskom intervalu ili prostoru, naročito kada su događaji retki.

Statistički modeli su matematičke reprezentacije odnosa između slučajnih promenljivih i koriste se za identifikaciju obrazaca u podacima i donošenje predviđanja događaja. U domenu veštačkih neuronskih mreža, statistički modeli pomažu u definisanju funkcija greške, regulaciji matematičkog modela i u optimizaciji samog procesa učenja u okviru veštačke neuronske mreže. Kroz upotrebu statističkih metoda, matematički (statistički) modeli mogu bolje generalizovati na nove podatke (proces učenja), što je ključno za primene veštačkih neuronskih mreža u industriji i nauci.

Bayes teorija predstavlja statistički pristup koji omogućava ažuriranje verovanja o parametrima matematičkog modela na osnovu novih podataka. Bayesova teorema se formalno izražava prema sledećoj formuli:

$$P(w|D) = \frac{P(D|w) \times P(w)}{P(D)} \quad (4)$$

gde je:

- $P(w|D)$ posteriorna verovatnoća parametara w nakon što se uzmu u obzir podaci D ,
- $P(D|w) \times P(w)$ verodostojnost, odnosno verovatnoća podataka datih parametrima w ,
- $P(w)$ apriorna verovatnoća parametara,
- $P(D)$ normalizaciona konstanta.

U sklopu *Bayes* teorije apriorna verovatnoća predstavlja naše početno uverenje o vrednostima parametara matematičkog modela, pre nego što su prikazni bilo kakvi podaci. U slučaju veštačkih neuronskih mreža, apriorna verovatnoća omogućava da matematički model veštačke neuronske mreže ugradi prethodno znanje ili pretpostavke.

Sa druge strane prema *Bayes* teoriji posteriorna verovatnoća predstavlja naše ažurirano uverenje o vrednostima parametara nakon što su uzeti u obzir podaci, praktično to znači da posteriorna verovatnoća daje uvid u to koliko su sigurne naučene vrednosti težina i pragova aktivacije veštačkih neurona u okviru veštačke neuronske mreže.

Bayesova statistika za potrebe matematičkog modela veštačkih neuronskih mreža se koristi za:

- **Procenu nesigurnosti u težinama i pragovima:** Umesto da se težine i pragovi aktivacije veštačkih neurona tretiraju kao fiksne vrednosti, Bayesov pristup ih tretira kao distribucije verovatnoće. To omogućuje procenu nesigurnosti u tim parametrima, što je posebno korisno u situacijama gde se ima ograničeni ili pak nepotpuni skup podataka.
- **Odabir najboljeg matematičkog modela:** Kada se ima više kandidata za matematički model veštačke neuronske mreže, Bayesova teorija omogućuje poređenje posteriornih verovatnoća i odabir onog matematičkog modela koji najbolje odgovara podacima.
- **Regularizaciju:** *Bayes* statistika omogućuje ugradnju apriornih verovatnoća o parametrima matematičkog modela, što može delovati kao oblik regularizacije i sprečava pretreniranosti veštačke neuronske mreže kada se matematički model previše prilagodi podacima i time na primer usvoji šum ulaznih podataka kao deo samog matematičkog modela veštačke neuronske mreže (*overfitting*).

- **Kvantifikaciju nesigurnosti predviđanja:** Bayesov pristup omogućuje kvantifikaciju nesigurnosti predviđanja veštačke neuronske mreže, što je ključno u aplikacijama gde je važno znati pouzdanost predviđanja.

Primena statističkih metoda u veštačkim neuronskim mrežama omogućava razvoj robusnih matematičkih modela koji su sposobni da se nose sa nesigurnošću i varijabilnošću ulaznih podataka. Jedan od ključnih aspekata je definisanje funkcije greške koja meri odstupanje između predviđenog izlaza matematičkog modela i stvarne vrednosti. Najčešće korišćena funkcija greške je srednja kvadratna greška (*Mean Squared Error*, MSE), koja se definiše prema sledećoj formuli:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

gde su:

- y_i stvarna vrednost,
- $\hat{y}_i$ predviđena vrednost,
- n broj uzoraka.

Ova funkcija je osnova za proces optimizacije učenja u okviru veštačke neuronske mreže, jer se minimizacijom srednje kvadratne greške (MSE) postiže bolja aproksimacija podataka. Kroz proces učenja, veštačke neuronske mreže koriste metode optimizacije kao što je stohastički gradijentni spust (*Stochastic Gradient Descent*, SGD) da bi prilagodile parametre veštačke neuronske mreže i smanjile vrednost funkcije greške.

Matematičke modele optimizacije veštačkih neuronskih mreža su detaljnije opisane u okviru [Poglavlja 2.2.5 Metode optimizacije i primena u veštačkim neuronskim mrežama](#).

Statistički modeli, sa svojim inherentnim pretpostavkama o raspodeli podataka i odnosima između slučajnih promenljivih, igraju ključnu ulogu u regularizaciji matematičkog modela veštačkih neuronskih mreža. Umesto da slepo prate svaki detalj u trening podacima, statistički modeli nameću određenu strukturu i ograničenja na složenost prethodno naučenih odnosa. Moguće je u okviru matematičkog modela nametnuti koncept regularizacije, gde na primer ako uvedemo model linearne regresije koja pretpostavlja linearan odnos između ulaznih i izlaznih varijabli, time se ograničava fleksibilnost matematičkog modela i smanjuje rizik od preprilagođavanja kompleksnim nelinearnim šumovima u podacima. Ova ugrađena regularizacija, koja proizlazi iz same prirode statističkog modela, često je suptilnija od eksplicitnih tehnika regularizacije, ali je podjednako važna za osiguravanje dobre generalizacije.

Metode poput L1 (*Lasso*) i L2 (*Ridge*) regularizacije predstavljaju eksplicitne tehnike koje se primenjuju, posebno u kontekstu složenijih modela kao što su veštačke neuronske mreže, pre svega kako bi se direktno kontrolisala veličina i raspodela težina u okviru samog matematičkog modela. Dodavanjem kaznenog člana u funkciju gubitka (engl. *loss function*) tokom treninga, ove metode efektivno "kažnjavaju" matematički model za korišćenje prevelikih težinskih faktora. Na taj način se primorava da model pronađe rešenje sa manjim i/ili

ređim (u slučaju L1) težinskim faktorima, što ga čini manje osetljivim na fluktuacije i šum u trening podacima. Regularizacija osigurava da matematički model veštačke neuronske mreže ne nauči previše specifičnih, a često irelevantnih detalja iz trening skupa podataka, već umesto toga da izdvaja suštinske obrasce i efikasno generalizuje naučeno znanje na potpuno nove, neviđene podatke. Putem regularizacije se postiže bolja prediktivna moć i robusnost matematičkog modela veštačke neuronske mreže u realnim industrijskim i naučnim aplikacijama.

Generalizacija na novim podacima zapravo predstavlja osnovni cilj učenja veštačke neuronske mreže i teži se tome da veštačke neuronske mreže postignu visok stepen generalizacije kroz tehnike optimizacije i regularizacije. Ove tehnike su ključne za održavanje ravnoteže između tačnosti i esencijalne sposobnosti matematičkog modela veštačke neuronske mreže da se prilagodi novim podacima kroz generalizaciju.

2.2.3. Informaciona teorija i primena u veštačkim neuronskim mrežama

Informaciona teorija bavi se kvantifikovanjem informacija i merenjem neizvesnosti unutar podataka. Ova oblast je od izuzetnog značaja u razvoju veštačkih neuronskih mreža, jer omogućava istraživačima da analiziraju koliko informacija se prenosi kroz sistem, u ovom slučaju sistem veštačke neuronske mreže. Na taj način se optimizuju matematički modeli tako da minimizuju gubitak informacija prilikom transformacije podataka.

Informacionu teoriju utemeljio je Klod Šenon 1948. godine svojim naučnim radom "*A Mathematical Theory of Communication*". Ovaj naučni rad je postavio temelje za modernu teoriju informacija, uvodeći koncepte entropije i međusobne informacija koji su kasnije postali osnova za razvoj različitih komunikacionih sistema, odnosno kasnije za primenu u oblasti veštačke inteligencije i veštačkih neuronskih mreža. Praktično Šenonov naučni rad omogućio je sistematsko merenje količine informacije i postavio je teorijski okvir koji se danas koristi za optimizaciju procesa učenja u veštačkim neuronskim mrežama (Shannon, 1948).

Informaciona teorija pruža alate za merenje količine informacije koja se prenosi kroz sistem. Ključni pojmovi uključuju entropiju (*Entropy*), koja meri nesigurnost ili neizvesnost podataka, kao i međusobnu informaciju (*Mutual Information*), koja kvantifikuje količinu informacije koju jedna promenljiva pruža o drugoj u okviru sistema. Entropija $H(X)$ se definiše prema sledećoj formuli:

$$H(X) = - \sum_{i=1} P(x_i) \log P(x_i) \quad (6)$$

gde $P(x_i)$ predstavlja verovatnoću da slučajna promenljiva X će poprimiti vrednost x_i . Veća entropija ukazuje na veći stepen neizvesnosti u podacima. Međusobna informacija $I(X; Y)$ između dve promenljive X i Y definiše prema sledećoj formuli:

$$I(X; Y) = \sum_{x,y} P(x, y) \log \frac{P(x, y)}{P(x)P(y)} \quad (7)$$

gde $P(x, y)$ predstavlja zajedničku verovatnoću promenljivih X i Y . Ovi koncepti omogućavaju istraživačima da identifikuju koje osobine podataka su najrelevantnije za donošenje odluka u okviru veštačkih neuronskih mreža, što je od ključne važnosti u optimizaciji procesa učenja koje se dešava u okviru samih veštačkih neuronskih mreža.

Unakrsna entropija funkcija greške (*Cross-Entropy Loss*) se široko koristi u zadacima klasifikacije, pri čemu unakrsna entropija meri razliku između stvarne distribucije kategorija kojoj posmatrani podatak pripada, i predviđene distribucije matematičkog modela. Formula za unakrsnu entropiju $H(y, \hat{y})$ se definiše prema sledećoj formuli:

$$H(y, \hat{y}) = \sum_i y_i \log(\hat{y}_i) \quad (8)$$

gde y_i predstavlja stvarne oznake, a $\hat{y}_i$ predviđene verovatnoće. Minimiziranje unakrsne entropije funkcija greške omogućava da predviđanja matematičkog modela se približe stvarnoj distribuciji verovatnoće, što je ključno za postizanje visoke tačnosti u klasifikacionim zadacima.

Informaciona teorija ima višestruke primene u razvoju i optimizaciji veštačkih neuronskih mreža gde neki od ključnih načina na koje se ovi koncepti primenjuju uključuju:

- **Merenje nesigurnosti i optimizacija matematičkog modela:** Entropija se koristi za merenje stepena neizvesnosti u podacima i matematičkim modelima. Visoka entropija izlaza može ukazivati na to da matematički model nije siguran u svoje predviđanje, što može biti signal za dodatno podešavanje samog matematičkog modela. Kroz minimizaciju entropije, matematički modeli mogu postići bolju preciznost u predviđanjima i generalizaciji.
- **Redukcija dimenzionalnosti:** Korišćenje koncepta međusobne informacije omogućava se identifikacija onih ključnih osobina koje sadrže najviše informacija. Ovo je od presudnog značaja za optimizaciju veštačkih neuronskih mreža, posebno kada se radi sa visokodimenzionalnim podacima, kao što su EEG signali. Preko ovih tehnika moguće je eliminisati suvišne ili redundantne informacije, čime se poboljšava efikasnost učenja, smanjuje kompleksnost matematičkog modela, te samim time optimizuju potrebni računarski resursi za treniranje i korišćenje veštačkih neuronskih mreža.
- **Definisanje funkcija greške:** Funkcija greške, kao što je unakrsna entropija, igra ključnu ulogu u procesu treniranja veštačkih neuronskih mreža. Minimiziranje unakrsne entropije omogućava matematičkim modelima da prilagode svoje težine i pragove aktivacije veštačkih neurona tako da predviđanja budu što preciznija, što je posebno važno u zadacima klasifikacije. Ova funkcija greške koristi se za iterativno prilagođavanje parametara težina veštačke neuronske mreže, što omogućava kontinuirano poboljšanje matematičkog modela tokom treninga same veštačke neuronske mreže.
- **Informaciona efikasnost:** Pojmovi iz informacione teorije omogućavaju istraživačima da kvantifikuju koliko informacija se efektivno prenosi kroz veštačku neuronsku mrežu. Ova analiza može pomoći u dizajniranju matematičkih modela koji minimiziraju

gubitak informacije tokom transformacija podataka, čime se postiže veća efikasnost u treniranju veštačke neuronske mreže.

Kao što je prethodno objašnjeno informaciona teorija se primenjuje u metodama za redukciju dimenzionalnosti, gde se cilja da se odredi minimalna količina informacija koja je potrebna za opis podataka i bez gubitka značajnih karakteristika. Ovakvi pristupi su posebno korisni u analizi visokodimenzionalnih podataka, kao što su EEG signali, gde je važno izdvojiti samo one informacije koje su najrelevantnije za određeni zadatak i izbeći inherentne šumove u ulaznim podacima.

Jedan od praktičnih primera primene informacione teorije u veštačkim neuronskim mrežama može se videti u zadacima prepoznavanja slika (*Computer Vision*, CV). U ovakvim sistemima veštačke inteligencije, ulazni podaci se transformišu kroz niz skrivenih slojeva veštačke neuronske mreže, a svaka transformacija može biti analizirana pomoću entropije. Praktično to znači da analiza entropije može otkriti koje slojeve veštačka neuronska mreže karakteriše veća nesigurnost, što može ukazivati na to da matematički model nije uspeo da otkrije sve relevantne osobine iz ulaznih podataka. Korišćenjem ovih informacija, istraživači mogu dodatno optimizovati arhitekturu veštačke neuronske mreže i poboljšati njenu sposobnost da precizno klasifikuje slike.

Sličan pristup primenjuje se i u analizi EEG signala, gde pošto su EEG signali često veoma kompleksni i sadrže veliki broj varijacija koje se manifestuju kroz različite vremenske i frekvencijske komponente, primena informacione teorije omogućava da se kvantifikuje količina informacije u svakom segmentu EEG zapisa, i time identifikuju ključne karakteristike, odnosno eliminiše inherentni šum. Ovo omogućava veštačkim neuronskim mrežama da se fokusiraju na relevantne aspekte EEG signala prilikom donošenja odluka, što direktno utiče na tačnost i pouzdanost medicinske neurodijagnostike.

Informaciona teorija, u kombinaciji sa linearnom algebrom i teorijom verovatnoće, pruža sveobuhvatan okvir za razvoj i optimizaciju veštačkih neuronskih mreža. Operacije nad matricama i vektorima (linearna algebra) omogućavaju efikasno predstavljanje i manipulaciju podacima, dok teorija verovatnoće omogućava matematičkim modelima da kvantifikuju nesigurnost u svojim predviđanjima. Informaciona teorija potom doprinosi identifikaciji relevantnih osobina kroz merenje entropije i međusobne informacije. U procesu treniranja veštačke neuronske mreže, gradijenti funkcije greške se izračunavaju pomoću diferencijalnog računa, a zatim se vrednost funkcije greške može dodatno analizirati korišćenjem koncepta entropije, kako bi se osigurala efikasnost učenja.

Ova sinergija matematičkih disciplina omogućava kreiranje matematičkih modela koji su robusni, precizni i sposobni da se prilagode složenim, dinamičnim podacima. Sveobuhvatan i multimodalan pristup omogućava matematičkim modelima da minimiziraju gubitak informacije i time optimizuju performanse samog matematičkog modela, što je ključno za primenu u realnim zadacima, kao što je analiza EEG signala u biomedicinskoj neurodijagnostici.

Informaciona teorija predstavlja ključnu komponentu u razvoju savremenih veštačkih neuronskih mreža. Kroz primenu osnovnih koncepata kao što su entropija, međusobna

informacija i unakrsna entropija, istraživači mogu kvantifikovati količinu informacije u podacima i optimizovati matematičke modele kako bi postigli što veću preciznost.

Istorijski razvoj Informacione teorije, od revolucionarnog rada Kloda Šenona do savremenih primena u *Deep Learning* modelima, pokazuje koliko su ovi koncepti postali integralni deo modernih algoritama veštačke inteligencije i mašinskog učenja podataka. Ovi matematički alati su neophodni za kreiranje robusnih matematičkih modela koji mogu da generalizuju na nove podatke, što je posebno važno u kritičnim aplikacijama, kao što su medicinska neurodijagnostika.

U integraciji sa drugim matematičkim osnovama, informaciona teorija pruža temelj za dalju optimizaciju veštačkih neuronskih mreža. Razumevanje ovih koncepata omogućava istraživačima da razviju napredne matematičke modele koji mogu da se nose sa složenim i visokodimenzionalnim podacima, otvarajući put ka novim inovacijama u oblastima veštačke inteligencije i mašinskog učenja podataka.

2.2.4. Matematička analiza i primena u veštačkim neuronskim mrežama

Matematička analiza se razvijala kroz vekove, počevši od rane primene infinitezimalnog računa. Ključni doprinosi u ovoj oblasti dali su matematičari kao što su Blaise Pascal, Pierre de Fermat i Jakob Bernoulli, čiji su radovi postavili temelje modernog diferencijalnog i integralnog računa.

Kasniji doprinosi Isaka Njutna i Gottfrieda Wilhelma Lajbnica dodatno su razvili ove koncepte, omogućavajući precizno modeliranje promena u funkcijama, što je postalo neophodno za razvoj teorijskih osnova u mnogim disciplinama, uključujući naravno i veštačku inteligenciju (Rudin, 1976; Stewart, 2015).

Matematička analiza, koja obuhvata koncepte kao što su izvodi i integrali, predstavlja osnovu za razumevanje i implementaciju procesa učenja u veštačkim neuronskim mrežama. Ovi koncepti omogućavaju precizno izračunavanje promena funkcija, optimizaciju težinskih parametara kao i analizu performansi samog matematičkog modela veštačke neuronske mreže.

Matematička analiza za potrebe treninga veštačke neuronske mreže se koristi za definisanje funkcija greške, izračunavanje gradijenata a koji se zatim koriste u algoritmima optimizacije parametara, kao što je stohastički gradijentni spust (*Stochastic Gradient Descent*, SGD). Integralni račun igra značajnu ulogu u modelovanju akumuliranih vrednosti i može se primeniti u arhitekturama koje koriste sekvencijalno procesiranje podataka, kao što su na primer rekurentne neuronske mreže (*Recurrent Neural Network*, RNN). Osnovni koncepti matematičke analize u domenu treniranja veštačkih neuronskih mreža su:

- **Izvod funkcije** predstavlja meru trenutne brzine promene funkcije, gde se izvod u okviru sistema veštačke inteligencije koristi za izračunavanje gradijenta funkcije greške veštačke neuronske mreže. Na taj način se omogućava prilagođavanje težinskih parametara u veštačkoj neuronskoj mreži kako bi se minimizirao gubitak i optimizovala sama funkcija greške. Na primer, ako se posmatra funkcija greške $E(w)$ u odnosu na težine w , gradijent $\nabla E(w)$ daje informacije o tome u kojem smeru se funkcija greške najbrže menja.

- **Gradijent:** Gradijent je vektor parcijalnih izvoda funkcije u odnosu na svaku od njenih promenljivih. Gradijent pokazuje smer najvećeg porasta funkcije i ključan je za algoritme optimizacije težinskih parametara veštačke neuronske mreže, kao što je stohastički gradijentni spust, koji koristi negativan gradijent za ažuriranje težinskih parametara u veštačkoj neuronskoj mreži, a prema sledećoj formuli:

$$w_{novi} = w_{stari} - \eta \cdot \nabla E(w) \quad (9)$$

gde η predstavlja stopu učenja. Ova formula omogućava iterativno smanjenje funkcije greške kroz prilagođavanje parametara veštačke neuronske mreže.

- **Integral funkcije** predstavlja meru površine ispod krive funkcije greške i koristi se za određivanje akumulirane vrednosti. U nekim arhitekturama veštačkih neuronskih mreža, integrali mogu biti korisni za modeliranje agregiranih efekata ili za formulisanje specifičnih regularizacionih tehnika.
- **Lančano pravilo** je tehnika za izračunavanje izvoda složenih funkcija koje se sastoje od kompozicija više funkcija. U veštačkim neuronskim mrežama, lančano pravilo omogućava propagaciju greške unazad kroz veštačku neuronsku mrežu (*Backpropagation*), čime se ažuriraju parametri težine veštačke neuronske mreže. Na primer, ukoliko je L funkcija greške, z_j izlaz neurona j , a_i aktivacija neurona i , i w_i težina između neurona i i j , lančano pravilo se može izraziti prema sledećoj formuli:

$$\frac{\partial L}{\partial w_i} = \frac{\partial L}{\partial z_j} \cdot \frac{\partial z_j}{\partial a_i} \cdot \frac{\partial a_i}{\partial w_i} \quad (10)$$

pri čemu ova formula je ključna za razumevanje kako se greška propagira kroz veštačku neuronsku mrežu i kako se podešavaju težinski parametri veštačke neuronske mreže kako bi se postigla minimizacija funkcije greške.

Linearna algebra, teorija verovatnoće i informaciona teorija zajedno sa diferencijalnim računom omogućavaju realizaciju procesa treniranja veštačkih neuronskih mreža. Pored osnovnih operacija, primena diferencijalnog računa u kontekstu veštačkih neuronskih mreža omogućava da se funkcija greške, na primer srednja kvadratna greška (MSE), minimizira kroz iterativno ažuriranje parametara težina veštačke neuronske mreže. Korišćenjem stohastičkog gradijentnog spusta, veštačka neuronska mreža prilagođava svoje parametre težina tako da se smanji greška između predviđenih i stvarnih vrednosti. Ovaj proces se oslanja na izračunavanje gradijenata funkcije greške, što je ključno za pravilno treniranje veštačkih neuronskih mreža (Pascanu, Mikolov, & Bengio, 2013).

U praktičnoj primeni, prethodno opisana matematička teorija i primenjeni matematički koncepti omogućavaju razvoj robustnih matematičkih modela koji mogu da generalizuju na nove podatke. Kroz iterativni proces treniranja, veštačke neuronske mreže koriste principe diferencijalnog računa da minimiziraju funkciju greške, a operacije linearne algebre omogućavaju efikasno rukovanje podacima čak i u slučajju veoma visokih dimenzija.

Matematička teorija, sa svim svojim aspektima, od linearne algebre do teorije verovatnoće i diferencijalnog računa, predstavlja temelj za razumevanje i primenu veštačkih neuronskih mreža u praksi. Ovi koncepti omogućavaju precizno modeliranje podataka,

definisanje funkcija greške i optimizaciju procesa učenja, što je neophodno za efikasnu primenu veštačkih neuronskih mreža u realnim industrijskim aplikacijama i naučnim istraživanjima. Razumevanje matematičkih osnova pruža istraživačima i inženjerima mogućnost da razviju napredne matematičke modele sposobne za rešavanje kompleksnih problema, kao što je analiza EEG signala u medicinskoj neurodijagnostici.

Kroz ovaj pregled matematičke teorije, jasno je da su linearna algebra, teorija verovatnoće, matematička analiza i informacijska teorija međusobno povezani i ključni za kreiranje robusnih i preciznih veštačkih neuronskih mreža. Ovi matematički alati ne samo da omogućavaju matematičkim modelima da uče i generalizuju, već i da se prilagode promenama u podacima, čime se otvaraju nove mogućnosti za unapređenje tehnologije i nove koncepte učenja (treniranja) veštačkih neuronskih mreža.

2.2.5. Metode optimizacije i primena u veštačkim neuronskim mrežama

Optimizacija predstavlja ključni deo procesa učenja veštačkih neuronskih mreža, jer je efikasno prilagođavanje matematičkog modela direktno povezano sa sposobnošću veštačke neuronske mreže da minimizira funkciju greške i time generalizuje (uči) dobro na novim podacima. U ovom poglavlju se detaljno razmatra osnovne metode optimizacije koje se primenjuju prilikom treniranja veštačkih neuronskih mreža, njihove varijante, matematičke osnove, kao i praktične primene u kontekstu rešavanja problema kao što je klasifikacija slika ili analiza EEG signala.

Gradijentni spust je iterativni algoritam koji se koristi za pronalaženje minimuma funkcije greške. Osnovna ideja je da se matematički model postepeno prilagođava tako što se u svakom koraku pomera u smeru suprotnom od gradijenta funkcije greške. Ova metoda omogućava matematičkim modelima da minimiziraju razliku između predviđenih i stvarnih vrednosti.

- **Batch gradijentni spust** (*Batch Gradient Descent*): Ova varijanta izračunava gradijent funkcije greške koristeći čitav skup podataka za obuku. Iako pruža stabilnije i tačnije gradijente, batch pristup je često spor, jer zahteva obradu celokupnog skupa podataka pre svakog ažuriranja parametara težina veštačke neuronske mreže.
- **Stohastički gradijentni spust** (*Stochastic Batch Gradient Descent*): Za razliku od batch gradijentnog spusta, stohastički gradijentni spust ažurira parametre težina nakon obrade svakog pojedinačnog uzorka. Ovaj pristup ubrzava proces obuke, ali može dovesti do većih oscilacija u vrednosti funkcije greške zbog varijabilnosti gradijenata po uzorcima.
- **Mini-batch gradijentni spust** (*Mini-batch gradient Descent*): Ova metoda predstavlja kompromis između batch i stohastičkog pristupa. Umesto da se gradijent izračunava na osnovu celokupnog skupa podataka ili samo jednog uzorka, mini-batch metoda koristi male grupe uzoraka (*mini-batches*) za izračunavanje gradijenta. Ovo omogućava stabilnije ažuriranje parametara težina veštačke neuronske mreže nego kod čistog stohastičkog gradijentnog spusta, dok se istovremeno povećava brzina obuke u poređenju sa batch gradijentnim spustom.

- **Momentum:** Momentum je tehnika koja se koristi za ubrzavanje konvergencije gradijentnog spusta i smanjenje oscilacija u procesu obuke. Osnovna ideja je da se pri ažuriranju parametara težina uzme u obzir prethodni gradijent, čime se "nakuplja" brzina u smeru konstantnog gradijenta. Matematički, momentum se može izraziti kao:

$$v_t = \gamma v_{t-1} + \eta \nabla L(w_t) \quad (11)$$

$$w_{t+1} = w_t - v_t \quad (12)$$

gde v_t predstavlja trenutni moment, γ je koeficijent momenta, η je stopa učenja, a $\nabla L(w_t)$ gradijent funkcije greške. Ovaj metod pomaže da se stabilizuju promene težina i ubrza proces konvergencije.

Adaptivne metode učenja prilagođavaju stopu učenja svakom parametru težine pojedinačno, što omogućava efikasnije ažuriranje parametara težina veštačke neuronske mreže i bržu konvergenciju matematičkog modela veštačke neuronske mreže.

- **Adaptive Gradient** (*Adagrad*) je metod koji prilagođava stopu učenja na osnovu istorijskih kvadratnih gradijenata. On smanjuje stopu učenja za parametre težina koji imaju česte i velike gradijente, dok onemogućava prevelika ažuriranja za retko ažurirane parametre težina. Ovo omogućava matematičkom modelu da se koncentriše na važnije karakteristike podataka, ali može dovesti do prebrzog smanjenja brzine učenja što ograničava dugoročno učenje.
- **Root Mean Square Propagation** (*RMSprop*) je unapređena verzija *Adagrada*, koja koristi eksponencijalno opadajući prosek kvadratnih gradijenata kako bi se sprečilo prebrzo smanjenje stope učenja. Ovaj metod omogućava da se stopa učenja prilagodi na dinamičan način, što rezultira stabilnijim i bržim konvergencijama funkcija u mnogim praktičnim aplikacijama.
- **Adaptive Moment Estimation** (*Adam*) kombinuje ideje momenta i RMSprop pristupa. On održava eksponencijalno opadajući prosek prvih i drugih momenata gradijenata, što omogućava adaptivno podešavanje stope učenja za svaki parametar. *Adam* je postao jedan od najpopularnijih optimizacionih algoritama zbog svoje sposobnosti da brzo konvergira i efikasno se nosi sa bučnim podacima (inherentni šum). Osnovna formula ažuriranja težina u *Adam* algoritmu (pojednostavljeno) je:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \nabla L(w_t) \quad (13)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) [\nabla L(w_t)]^2 \quad (14)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (15)$$

$$w_{t+1} = w_t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (16)$$

gde su β_1 i β_2 parametri koji određuju eksponencijalno opadajuće proseke, ϵ je mali broj koji sprečava deljenje sa nulom, m_t predstavlja prvi moment (srednja vrednost) gradijenata, a v_t drugi moment (varijansa). *Adam* je poznat po svojoj sposobnosti da se efikasno nosi sa visoko dimenzionalnim problemima i bučnim podacima (npr. EEG signal), odnosno

podacima koji imaju veliku količinu inheretnog šuma što otežava proces učenja i generalizacije na nove podatke.

Izbor odgovarajućeg algoritma optimizacije je ključan za efikasnu obuku veštačkih neuronskih mreža. Različiti algoritmi imaju svoje prednosti i nedostatke, a njihov izbor zavisi od specifičnih karakteristika problema i skupa podataka. Kao primer se može navesti da prilikom obuke matematičkog modela veštačkih neuronskih mreža za klasifikaciju slika, cilj je minimizacija razlike između predviđenih vrednosti i stvarnih oznaka. U ovom slučaju, algoritmi kao što je *Adam* mogu vrlo brzo prilagoditi parametre težine veštačke neuronske mreže i postići brzu konvergenciju, dok metode poput *mini-batch* gradijentnog spusta pružaju stabilnost u iterativnom ažuriranju parametara težina veštačke neuronske mreže.

U praksi se vrlo često prilikom obuke veštačke neuronske mreže primenjuje pravilo ažuriranja gradijentnog spusta:

$$w_{t+1} = w_t - \eta \cdot \nabla L(w_t) \quad (17)$$

gde w_t predstavlja težine u trenutnom koraku, η , a $\nabla L(w_t)$ gradijent funkcije greške. Kroz iterativno ažuriranje parametra težina, matematički model veštačke neuronske mreže postepeno uči da minimizira funkciju greške i da poboljša svoje predikcije. Primena adaptivnih metoda, kao što su *Adagrad*, *RMSprop* i *Adam*, omogućava da se stopa učenja dinamički prilagođava specifičnostima podataka. Ovi algoritmi omogućavaju brže i preciznije prilagođavanje matematičkog modela veštačkih neuronskih mreža, čime se poboljšava sposobnost modela da generalizuje na nove, nepoznate podatke.

Metode optimizacije, kao što su gradijentni spust i njegove adaptivne varijante, imaju brojne prednosti, ove metode omogućavaju brzu konvergenciju, automatsko prilagođavanje parametara težina veštačkih neuronskih mreža i efikasno minimiziranje funkcije greške, što je ključno za uspešnu obuku veštačkih neuronskih mreža. Bez obzira na očigledne benefite metoda optimizacije, postoji takođe i nekoliko izazova koji se javljaju prilikom primena opisanih metoda optimizacije:

- **Nestabilnost gradijenata:** Standardni gradijentni spust može biti podložan problemima poput nestajućih ili eksplodirajućih gradijenata, što otežava učenje u dubokim neuronskim mrežama.
- **Odabir stope učenja:** Previsoka stopa učenja može dovesti do oscilacija u funkciji greške, dok preniska stopa učenja može značajno usporiti proces konvergencije funkcije.
- **Računarska složenost i resursi:** Adaptivne metode, poput *Adam* algoritma, zahtevaju dodatne proračune za održavanje prvih i drugih momenata gradijenata, što povećava računarsku složenost i potrebu za značajnim računarskim resursima što samim time poskupljuje proces treniranja veštačke neuronske mreže i njenu eksploataciju u praksi.
- **Generalizacija i *overfitting*:** Iako su adaptivne metode veoma efikasne na trening skupu, postoji rizik da matematički model veštačke neuronske mreže postane previše prilagođen specifičnostima podataka, praktično da kao svoj sastavni deo matematički model usvoji i inheretni šum u podacima, što samim time može negativno uticati na sposobnost veštačke neuronske mreže da generalizuje nove podatke.

Svakako treba naglasiti da su optimizacione metode od suštinskog značaja za obuku veštačkih neuronskih mreža. Kroz primenu gradijentnog spusta, njegovih varijanti (*Batch*, *Stochastic*, *Mini-Batch*) i adaptivnih algoritama (*Adagrad*, *RMSprop*, *Adam*), moguće je efikasno minimizirati funkciju greške i postepeno poboljšavati performanse matematičkog modela.

Matematički modeli zasnovani na diferencijalnom računu i operacijama linearne algebre omogućavaju precizno prilagođavanje težina i praga aktivacije funkcije u okviru veštačkih neuroan, čime se otvara put ka razvoju robusnih matematičkih modela veštačkih neuronskih mreža koji mogu da generalizuju na nove podatke. Iako se suočavaju sa izazovima kao što su nestabilnost gradijenata i potreba za finim podešavanjem težinskih parametara, napredne metode optimizacije predstavljaju ključni alat u savremenoj primeni veštačkih neuronskih mreža. Ovi pristupi omogućavaju ne samo bržu i efikasniju obuku matematičkog modela veštačkih neuronskih mreža, već i povećanje njihove sposobnosti da precizno prepoznaju i klasifikuju kompleksne obrasce u podacima.

2.2.6. Teorija grafova i primena u veštačkim neuronskim mrežama

Teorija grafova je grana matematike koja proučava strukture nazvane grafovima, odnosno skupove pojedinačnih čvorova povezanih ivicama. Ova oblast ima široku primenu u mnogim disciplinama, od računarstva i operacionih istraživanja, preko komunikacionih mreža, pa sve do modeliranja arhitektura veštačkih neuronskih mreža. U domenu veštačkih neuronskih mreža, grafovi se koriste za predstavljanje arhitekture veštačke neuronske mreže, gde svaki čvor simbolizuje veštački neuron, a ivice predstavljaju veze između veštačkih neurona. Ova reprezentacija omogućava analizu strukture veštačke neuronske mreže, identifikaciju ključnih čvorova, ispitivanje povezanosti, kao i proučavanje protoka informacija kroz veštačku neuronsku mrežu.

Teorija grafova ima dugu i bogatu istoriju koja seže do 18. veka, gde je značajan doprinos u oblikovanju moderne teorije grafova dao Leonard Ojler, čiji su radovi postavili temelje za sistematsko proučavanje struktura grafova. Od tada, teorija grafova se razvijala kroz radove mnogih matematičara, a danas predstavlja ključnu disciplinu koja se primenjuje u mnogim tehnološkim i naučnim oblastima. Osnovni koncepti teorije grafova su:

- **Graf** : Osnovni objekat u teoriji grafova je graf, koji se definiše kao skup čvorova V i skup ivica E koje povezuju parove čvorova. Graf može biti reprezentovan kao neusmereni ili usmereni. U neusmerenom grafu, ivice nemaju definisan smer (npr. $A \leftrightarrow B$), dok u usmerenom grafu svaka ivica ima određen smer (npr. $A \rightarrow B$), što omogućava modeliranje asimetričnih veza.
- **Težinski graf**: U mnogim aplikacijama, ivice grafova mogu imati pridružene težine koje kvantifikuju jačinu ili važnost veze. Težinski grafovi omogućavaju detaljniju analizu, na primer, pri određivanju važnosti pojedinačnih veza neurona u veštačkoj neuronskoj mreži.
- **Matrica susedstva**: Graf se može predstaviti matricom susedstva A , gde se svaki element a_{ij} postavlja na vrednost koja označava postojanje (eventualno težinu) ivice

između čvorova i i j . Ovaj pristup omogućava primenu algebarskih tehnika za analizu strukture grafova, kao što je izračunavanje spektra (*eigen* vrednosti) koje se dalje koriste u analizi mreže grafa.

- **Laplasijeva matrica:** Jedna od najvažnijih matrica u teoriji grafova je Laplasijeva matrica, definisana kao:

$$L = D - A \quad (18)$$

gde je D dijagonalna matrica stepena čvorova (svaki element d_i predstavlja broj ivica povezanih sa čvorom i), a A je matrica susedstva. Laplasijeva matrica se koristi za analizu strukture grafova, identifikaciju klastera, kao i za spektralno klasterisanje. Spektralno razlaganje Laplasijeva matrice omogućava da se otkriju važne karakteristike strukture, poput povezanosti i centralnosti pojedinačnih čvorova. Ova tehnika koristi svojstvene vektore Laplasijeve matrice za redukciju dimenzionalnosti podataka i klasterovanje čvorova u grafu.

U domenu veštačkih neuronskih mreža, spektralno klasterisanje Laplasijeve matrice može se koristiti za analizu i optimizaciju arhitekture veštačke neuronske mreže, omogućavajući identifikaciju grupa veštačkih neurona koje su međusobno veoma povezane i koje mogu obavljati specifične funkcije u obradi informacija.

Praktično to znači da se veštačka neuronska mreža korišćenjem teorije grafova može modelovati kao graf, gde su veštački neuroni čvorovi, a sinaptičke veze u okviru veštačke neuronske mreže ivice grafa. Ova reprezentacija omogućava detaljnu analizu arhitekture veštačke neuronske mreže, što uključuje:

- **Analizu povezanosti:** Proučavanje kako su veštački neuroni međusobno povezani može otkriti koje oblasti veštačke neuronske mreže imaju ključnu ulogu u prenošenju informacija u okviru same veštačke neuronske mreže.
- **Identifikaciju centralnih čvorova:** Analizom centralnosti, moguće je identifikovati čvorove koji su najvažniji za funkcionisanje veštačke neuronske mreže, što može biti ključno za optimizaciju i interpretaciju matematičkog modela veštačke neuronske mreže.
- **Spektralno klasterisanje:** Zasnovano na svojstvenim vrednostima Laplasijeve matrice, omogućava da se otkriju podgrupe veštačkih neurona koje imaju slične funkcije ili obrađuju slične informacije. Ove tehnike mogu pomoći u dizajniranju novih arhitektura, kao što su graf veštačke neuronske mreže (*Graph Neural Network*, GNN), koje direktno rade sa podacima predstavljenim kao grafovi.

U konvolucionim veštačkim neuronskim mrežama (*Convolutional Neural Network*, CNN), teorija grafova može se koristiti za modeliranje prostornih odnosa između piksela na slici, čime se omogućava automatsko otkrivanje lokalnih karakteristika kao što su ivice i texture. Sličan princip primenjuje se u potpuno povezanim (*feedforward*) veštačkim neuronskim mrežama za analizu strukture interne arhitekture veštačke neuronske mreže, što omogućava identifikaciju ključnih grupa veštačkih neurona koje su odgovorne za prenos specifičnih informacija kroz potpuno povezanu (*feedforward*) veštačku neuronsku mrežu. Teorija grafova se ne može posmatrati izolovano, njeni koncepti se integrišu sa drugim

matematičkim disciplinama koje se koriste u modeliranju veštačkih neuronskih mreža, kao na primer:

- **Sa linearnom algebrim:** Reprezentacija grafa putem matrice susedstva i Laplasijeve matrice omogućava primenu algebarskih tehnika za analizu strukture veštačke neuronske mreže. Matrične operacije, kao što je množenje i inverzija, pomažu u pronalaženju ključnih svojstava grafova, što može biti direktno primenjeno na optimizaciju same arhitekture veštačke neuronske mreže.
- **Sa teorijom verovatnoće:** Statistički modeli i distribucije verovatnoće se mogu koristiti za kvantifikovanje verovatnoće u strukturi grafa, na primer, u slučajevima kada su veze između čvorova neodređene ili promenljive.
- **Sa informacionom teorijom:** Pojmovi entropije i međusobne informacije mogu se primeniti na grafove kako bi se odredilo koliko su informacije efikasno prenete kroz veštačku neuronsku mrežu. Ovo je od izuzetne važnosti za optimizaciju performansi veštačke neuronske mreže, jer omogućava dizajniranje arhitektura koje maksimalno iskorišćava raspoloživu informaciju.

Sinergija između ovih oblasti omogućava razvoj sofisticiranih matematičkih modela koji mogu da analiziraju i interpretiraju kompleksne strukture podataka. Teorija grafova predstavlja moćan alat za modeliranje i analizu strukture veštačkih neuronskih mreža. Kroz definisanje grafa kao skupa čvorova povezanih ivicama, istraživači mogu precizno analizirati arhitekturu veštačke neuronske mreže, identifikovati ključne čvorove i klastere, te optimizovati protok informacija.

Povezivanje ovih koncepta sa osnovama linearne algebre, teorije verovatnoće i informacione teorije omogućava stvaranje robusnih matematičkih modela veštačkih neuronskih mreža koji se mogu efikasno trenirati i primenjivati u različitim industrijskim i naučnim oblastima.

Integrisana primena ovih matematičkih disciplina stvara temelj za razvoj inovativnih arhitektura veštačkih neuronskih mreža, uključujući grafovske neuronske mreže (*Graph Neural Networks*, GNN), koje direktno modeliraju podatke kao grafove. Ova sinergija omogućava bolje razumevanje unutrašnjih mehanizama veštačkih neuronskih mreža i otvara nove mogućnosti za unapređenje performansi matematičkih modela veštačkih neuronskih mreža, čime se direktno utiče na kvalitet i efikasnost primene veštačke inteligencije u kompleksnim aplikacijama poput medicinske neurodijagnostike.

2.2.7. Matematičke teorije i prakse u primeni veštačkim neuronskim mrežama

Veštačke neuronske mreže predstavljaju sintezu više matematičkih disciplina čija se međusobna integracija odražava u sposobnosti matematičkog modela da uči iz podataka, da generalizuje složene obrasce i donosi precizne odluke.

Naravno da nije bilo moguće u okviru ovog naučno-istraživačkog rada detaljno prikazati sve pojedinačne matematičke discipline koje se primenjuju u oblasti veštačke inteligencije, tako da su čak i određene matematičke discipline izostavljene iz sadržaja samog naučno-

istraživačkog rada. Pre svega ideja je bila da se prikaže osnovni teorijski prikaz fundamentalnih matematičkih disciplina koje se koriste za potrebe matematičkih modela veštačke inteligencije i kasnije u toku ove disertacije se po potrebi referencira na konkretna poglavlja tokom izvođenja samog eksperimenta i prikaza zaključaka ovog naučno-istraživačkog rada.

Naučni cilj ove doktorske disertacije jeste da se na osnovu predstavljenih javno dostupnih informacija o EEG signalima pacijenata razvije napredni matematički model za detekciju epileptičkih napada iz EEG podataka. U nastavku je detaljno opisano kako se ovo naučno istraživanje oslanja na prethodno opisane osnovne matematičke koncepte, kao što su linearna algebra, teorija verovatnoće, statistika, matematička analiza, informaciona teorija, optimizacione metode i teorija grafova, koje zajedno čine temelj ekosistema veštačkih neuronskih mreža. Međutim, s obzirom na obim i kompleksnost ovih disciplina, nije moguće u ovom naučno-istraživačkom radu detaljno obraditi svaku pojedinačnu oblast. Stoga, u daljim istraživanjima i nekom budućem razvoju projekta započetog u okviru ovog naučno-istraživačkog rada, bilo bi korisno razmotriti i dodatne matematičke discipline koje doprinose unapređenju veštačkih neuronskih mreža, kao što su numerička analiza, teorija diferencijalnih jednačina, Bayesova statistika i napredne metode učenja reprezentacija.

Kroz integraciju ovih matematičkih osnova i metodoloških pristupa, ovaj naučno-istraživački rad nastoji da ispuni oba cilja, da doprinese unapređenju naučnog znanja u oblasti primene veštačkih neuronskih mreža za medicinsku neurodijagnostiku, odnosno kao izuzetno važan društveni cilj obezbedi alate za bržu, precizniju i pouzdaniju detekciju epileptičkih napada kod pacijenata. Ovim pristupom, cilj je ne samo unaprediti tehnologiju, već i značajno poboljšati kvalitet zdravstvene zaštite u celini na teritoriji Republike Srbije. Razvoj i primena veštačkih neuronskih mreža oslanjaju se na sinergiju linearne algebre, teorije verovatnoće i statistike, informacione teorije, matematičke analize, teorije grafova i metode optimizacije. Ova interdisciplinarna integracija predstavlja temelj za funkcionisanje veštačkih neuronskih mreža u raznim oblastima, od biomedicinskih istraživanja, istraživanja i razumevanje jezika, pa sve do sistema autonomnog upravljanja.

Linearna algebra pruža osnovu za predstavljanje i transformaciju podataka unutar veštačke neuronske mreže. Podaci, kao i parametri matematičkog modela (težine i vrednosti pristrasnosti), predstavljeni su pomoću vektora i matrica. Operacije poput matričnog množenja omogućavaju prenos informacija između slojeva veštačke neuronske mreže, dok se dodavanje vrednosti pristrasnosti (*bias*) koristi za podešavanje izlaza. Bez ovih osnovnih algebarskih operacija, implementacija složenih arhitektura veštačkih neuronskih mreža bila bi neizvodljiva (Strang, 1993).

Teorija verovatnoće i statistika ključna je za modeliranje nesigurnosti u podacima i definisanje funkcija greške. Primena statističkih modela omogućava kvantifikaciju varijabilnosti podataka, dok metode poput srednje kvadratne greške (MSE) služe za evaluaciju razlike između stvarnih i predviđenih vrednosti. Bayesove metode, koje omogućavaju ažuriranje verovanja o parametrima matematičkog modela na osnovu novih informacija, posebno su korisne u aplikacijama gde su ulazni podaci inherentno neizvesni, kao što su EEG signali (Ross, 2014).

Informaciona teorija se bavi kvantifikacijom količine informacije i nesigurnosti u podacima. Koncepti poput entropije i međusobne informacije omogućavaju istraživačima da

identifikuju ključne karakteristike podataka te da dizajniraju funkcije greške koje minimizuju gubitke informacija tokom obuke matematičkog modela. Minimizacija unakrsne entropije osigurava da izlaz matematičkog modela što preciznije odražava stvarnu distribuciju podataka (Cover & Thomas, 2006).

Matematička analiza, posebno diferencijalni račun, omogućava izračunavanje gradijenata funkcije greške, što je kritični korak u procesima optimizacije matematičkog modela veštačke neuronske mreže. Algoritmi poput propagacije unazad (*backpropagation*) oslanjaju se na principe diferencijacije kako bi iterativno prilagođavali parametre težina veštačke neuronske mreže u cilju minimizacije greške. Ovaj proces, koji koristi lančano pravilo, omogućava da veštačka neuronska mreža poboljša svoju preciznost kroz kontinuirano učenje i generalizaciju na novim podacima (Pascanu, Mikolov, & Bengio, 2013).

Optimizacione metode su primenjene kako bi se postigla efikasno podešavanje i prilagođavanje parametara težina matematičkog modela. Standardni algoritmi poput gradijentnog spusta, zajedno sa adaptivnim varijantama kao što su *Adam* i *RMSprop*, omogućavaju balansiranje brzine učenja i stabilnosti konvergencije funkcije. Efikasna optimizacija je presudna za obuku dubokih neuronskih mreža, jer se na taj način osigurava minimizacija funkcije greške ali isto tako se povećava tačnost matematičkog modela (Goodfellow, Bengio, & Courville, 2016).

Sinergija matematičkih disciplina ogleda se u načinu na koji se ovi koncepti međusobno nadopunjuju u okviru veštačkih neuronskih mreža. Linearna algebra omogućava predstavljanje i transformaciju podataka, dok teorija verovatnoće i statistika kvantifikuju nesigurnost i varijabilnost. Matematička analiza osigurava precizno izračunavanje gradijenata, a informaciona teorija doprinosi maksimizaciji efikasnosti prenosa informacija. Optimizacione metode koriste sve ove alate za prilagođavanje parametara matematičkog modela veštačke neuronske mreže, čime se postiže robustan sistem sposoban za automatsko učenje i generalizaciju složenih obrazaca u podacima koji predstavljaju ulaz u veštačku neuronsku mrežu.

U obradi EEG zapisa, linearne operacije omogućavaju transformaciju ulaznih EEG signala kroz veštačku neuronsku mrežu, dok se statistički modeli koriste za procenu nesigurnosti u podacima. Diferencijalni račun omogućava prilagođavanje težina veštačke neuronske mreže kroz iterativnu minimizaciju funkcije greške, a informaciona teorija pomaže u identifikaciji najrelevantnijih karakteristika EEG signala koje treba sačuvati. Ovakva integracija matematičkih koncepata omogućava da se podaci u okviru EEG signala, čak i kada sadrže visok nivo inheretnog šuma i varijacija (nelinearnosti), transformišu u pouzdane informacije za donošenje preciznih odluka iz domena medicinske neurodijagnostike.

Iako su teorija verovatnoće i statistika temelj za modeliranje veštačkih neuronskih mreža, njihova primena nije bez izazova. Ključni problemi uključuju izbor odgovarajućih modela i metoda za kvantifikaciju nesigurnosti u podacima, što je posebno kritično u slučajevima kada su ulazni podaci neizvesni, kao što su EEG signali. Implementacija Bayesovih pristupa zahteva precizno definisanje apriornih verovatnoća, što može biti zahtevno u dinamičnim okruženjima. Pored toga, regularizacija matematičkog modela veštačkih neuronskih mreža, koja sprečava pretreniranost, često se rešava primenom statističkih tehnika poput L1 (*Lasso*) i L2 (*Ridge*) regularizacije, čime se postiže balans između tačnosti

matematičkog modela veštačkih neuronskih mreža i njegove sposobnosti da generalizuje na nove podatke.

Budući razvoj u kontekstu veštačkih neuronskih mreža usmeren je na unapređenje algoritama učenja i povećanje interpretabilnosti matematičkog modela. Istraživači se fokusiraju na razvoj adaptivnih matematičkih modela koji automatski prilagođavaju svoje parametre težina modela veštačkih neuronskih mreža na osnovu promena u podacima, kao i na integraciju Bayesovih metoda za precizniju procenu nesigurnosti. Primena hibridnih modela, koji kombinuju konvolucione neuronske mreže (*Convolutional Neural Network*, CNN) i veštačke neuronske mreže bazirane na transformerima (*Transformer*), otvara mogućnost za bolju ekstrakciju i obradu informacija. Sveobuhvatna integracija ovih matematičkih koncepata, linearne algebre, teorije verovatnoće, matematičke analize, informacione teorije i optimizacionih metoda, omogućava veštačkim neuronskim mrežama da funkcionišu kao koherentan sistem za obradu podataka. Ova sinergija omogućava matematičkim modelima veštačkih neuronskih mreža ne samo da uče iz podataka, već i da se adaptiraju na promene u okruženju, što je od ključne važnosti za primenu u realnim zadacima. U okviru ovog poglavlja je prikazana integrisana perspektiva fundamentalnih matematičkih disciplina koje predstavljaju ključ veštačke inteligencije na čijem kontinuiranom razvoju se i dalje rade. Kao primer treba spomenuti da se očekuje u budućnosti unapređenje metoda optimizacije koje će doprineti stvaranju matematičkih modela veštačkih neuronskih mreža koji su precizniji, brži i prilagodljiviji na promene u podacima, a čime će se dodatno poboljšati performanse veštačkih neuronskih mreža u realnim industrijskim aplikacijama i naučnim istraživanjima. Naredna poglavlja ove disertacije posvećena su istraživanju i unapređenju različitih tipova veštačkih neuronskih mreža, naročito rekurentnih neuronskih mreža (*Recurrent Neural Network*, RNN), konvolucionih neuronskih mreža (*Convolutional Neural Network*, CNN) i modela dugoročne kratkoročne memorije (*Long Short Term Memory*, LSTM).

U nastavku su predstavljeni ključni pravci razvoja koji će biti obrađeni, uz naglasak na unapređenje performansi, efikasnosti, multimodalnosti i interpretabilnosti ovih matematičkih modela. Ovi pravci istraživanja imaju za cilj ne samo unapređenje teorijskih modela i algoritama, već i njihovu primenu u realnim, kritičnim aplikacijama. Integracija naprednih arhitektura veštačkih neuronskih mreža sa modernim optimizacionim tehnikama predstavlja obećavajući pravac koji će doprineti daljem razvoju veštačke inteligencije i njenoj primeni u industriji, posebno u oblasti medicinske neurodijagnostike.


2.2.8. Savremene veštačke neuronske mreže: Struktura i funkcionalnost

Veštačke neuronske mreže predstavljaju jedno od najznačajnijih tehnoloških dostignuća u savremenoj veštačkoj inteligenciji koje su pak inspirisane biološkim neuronskim mrežama ljudskog mozga (Haykin, 2009). One su razvijene s ciljem da imitiraju procese učenja i adaptacije u ljudskom mozgu, prenoseći ih u matematičke modele sposobne da obrađuju i interpretiraju ogromne količine podataka, te na osnovu uočenih obrazaca vrše proces generalizacije na novim podacima. Ovaj pristup omogućava automatsko otkrivanje i ekstrakciju skrivenih obrazaca podataka, što je od ključnog značaja za rešavanje kompleksnih problema u raznim oblastima, kao što su prepoznavanje slika, obrada prirodnog jezika i biomedicinska

dijagnostika (Goodfellow, Bengio, & Courville, 2016). Veštačke neuronske mreže su složeni sistemi koji se sastoje od tri glavna sloja: ulaznog sloja, skrivenih slojeva i izlaznog sloja veštačkih neurona. Svaki od ovih slojeva veštačkih neurona ima specifičnu ulogu u obradi podataka i učenju kompleksnih obrazaca podataka, te zbog toga veštačka neuronska mreža predstavlja izuzetno moćan alat sa vrlo različitim primenama u industrijskim i naučnim oblastima.

Ulazni sloj veštačke neuronske mreže predstavlja početnu tačku u procesu obrade podataka. Dati početni sloj veštačke neuronske mreže prima sirove ulazne podatke, koji mogu biti različite prirode, kao što su na primer vremenske tačke EEG signala, pikseli slike, reči u tekstu ili pak bilo koja druga vrsta podataka koji se u okviru veštačke neuronske mreže transformišu u adekvatnu numeričku formu. Glavna uloga ulaznog sloja veštačkih neurona je da prihvati ove podatke i da ih distribuirati na sledeće slojeve veštačke neuronske mreže. Važno je napomenuti da ulazni sloj veštačke neuronske mreže ne vrši nikakvu transformaciju podataka, jedina funkcija ulaznog sloja veštačkih neurona je da prenese podatke dalje u sledeće slojeve veštačke neuronske mreže. Konkretno u slučaju EEG signala, ulazni sloj bi primio podatke koji se odnose na vremenske sekvence EEG signala i prosledio ih skrivenim slojevima veštačke neuronske mreže na dalju obradu. Skriveni slojevi su osnova veštačke neuronske mreže, gde se odvija većina obrade podataka i učenja, odnosno kasnija generalizacija na nove podatke. Ovi slojevi se sastoje od veštačkih neurona koji primaju podatke iz ulaznog sloja veštačke neuronske mreže, vrše nelinearne transformacije i prenose rezultate dalje u okviru veštačke neuronske mreže. Svaki neuron u skrivenim slojevima veštačke neuronske mreže ima težinske parametre i aktivacionu funkciju, koji omogućavaju veštačkoj neuronskoj mreži da nauči kompleksne obrasce u podacima i kasnije vrši generalizaciju na novim podacima. Osnovni elementi veštačkih neuronskih mreža su:

- **Težinski parametri:** Ovi parametri određuju koliko će svaki ulazni podatak uticati na izlaz veštačkog neurona u okviru veštačke neuronske mreže. Tokom procesa učenja, težine se prilagođavaju kako bi se minimizirala funkcija greška u predviđanjima veštačke neuronske mreže.
- **Aktivacione funkcije:** Aktivacione funkcije uvode nelinearnost u veštačku neuronsku mrežu, što joj omogućava da matematički modelira složene odnose u podacima. Neke od najčešće korišćenih aktivacionih funkcija uključuju:
 - **Rectified Linear Unit (ReLU):** *ReLU* je popularna zbog svoje jednostavnosti i efikasnosti u učenju dubokih veštačkih neuronskih mreža. *ReLU* funkcija vraća ulaznu vrednost x ako je pozitivna, a nulu ako je negativna. Ova jednostavnost čini *ReLU* vrlo efikasnom za računanje i široko se koristi u dubokim neuronskim mrežama. Takođe, *ReLU* pomaže u ublažavanju problema nestajućih gradijenata, koji se često javlja kod drugih aktivacionih funkcija.



Slika 4: Dijagram ReLU aktivacione funkcije veštačke neuronske mreže

Grafikon *ReLU* funkcije prikazuje horizontalnu liniju na nuli za $x < 0$ i linearno rastuću liniju za $x \geq 0$. Ova jasna razlika između negativnih i pozitivnih vrednosti omogućava intuitivno razumevanje *ReLU* funkcije i njenih efekata na prenos signala kroz veštačku neuronsku mrežu. U nastavku je Python code za *ReLU* aktivacionu funkciju.


```
import numpy as np
import matplotlib.pyplot as plt
def relu(x):
    """ReLU aktivacijska funkcija."""
    return np.maximum(0, x)
# Stvaranje niza ulaznih vrednosti
x = np.linspace(-5, 5, 100)

# Izračunavanje izlaznih vrednosti primenom ReLU funkcije
y = relu(x)
# Crtanje grafikona
plt.plot(x, y)
plt.xlabel("Ulaz (x)")
plt.ylabel("Izlaz (y)")
```

```
plt.title("ReLU aktivacijska funkcija")
plt.grid(True)
plt.show()
```

Algoritam 1: Python code ReLU aktivacione funkcije veštačke neuronske mreže

- **Sigmoidalna funkcija (Sigmoid):** Ova funkcija se često koristi u binarnim klasifikacionim zadacima. Sigmoidna funkcija pretvara ulaz u opseg između 0 i 1, što je čini pogodnom za binarne klasifikacione zadatke. Glatka S-oblikovana kriva sigmoidne funkcije omogućava diferencijabilnost, što je važno za algoritme treniranja veštačke neuronske mreže, ali može dovesti do problema sa nestajanjem gradijenata kod velikih vrednosti ulaza.



Slika 5: Dijagram Sigmoid aktivacione funkcije veštačke neuronske mreže

Na grafikonu *Sigmoid* funkcije, primetićete S-oblikovanu krivu koja za vrlo negativne vrednosti x teži nuli, dok za vrlo pozitivne vrednosti x teži 1. Ova tranzicija osigurava da se izlaz aktivacione funkcije može interpretirati kao verovatnoća, što je izuzetno korisno u zadacima klasifikacije. U nastavku je Python code za Sigmoidnu aktivacionu funkciju.

```
import numpy as np
import matplotlib.pyplot as plt
def sigmoid(x):
    """Sigmoid aktivacijska funkcija."""
```


```

return 1 / (1 + np.exp(-x))
# Stvaranje niza ulaznih vrednosti
x = np.linspace(-10, 10, 100) # Raspon od -10 do 10 za bolji prikaz sigmoid funkcije
# Izračunavanje izlaznih vrednosti primenom Sigmoid funkcije
y = sigmoid(x)
# Crtanje grafikona
plt.plot(x, y)
plt.xlabel("Ulaz (x)")
plt.ylabel("Izlaz (y)")
plt.title("Sigmoid aktivacijska funkcija")
plt.grid(True)
plt.show()

```

Algoritam 2: Python code Sigmoid aktivacione funkcije veštačke neuronske mreže

- **Hiperbolički tangens (Tanh):** Slična *Sigmoid* aktivacionoj funkciji je hiperbolična tangens funkcija (Tanh), gde su izlazne vrednosti u opsegu $[-1, 1]$, što omogućava simetričniji raspored vrednosti u poređenju sa sigmoidnom aktivacionom funkcijom. Ovo može doprineti bržoj konvergenciji matematičkog modela i boljem balansiranju podataka u veštačkoj neuronskoj mreži.



Slika 6: Dijagram Tanh aktivacione funkcije veštačke neuronske mreže

Grafikon Tanh funkcije pokazuje glatku S-oblikovanu krivu centriranu oko nule. Za velike pozitivne vrednosti x , funkcija se približava 1, dok za velike negativne vrednosti, približava se -1. Ova simetrija omogućava veštačkoj neuronskoj mreži da bolje procesira podatke koji su centrirani oko nulte vrednosti. U nastavku je Python code za *Tanh* aktivacionu funkciju.

```
import numpy as np
import matplotlib.pyplot as plt
def tanh(x):
    """Hiperbolička tangens funkcija."""
    return np.tanh(x)

# Stvaranje niza ulaznih vrijednosti
x = np.linspace(-5, 5, 100) # Raspon od -5 do 5 za bolji prikaz tanh funkcije
# Izračunavanje izlaznih vrednosti primenom Tanh funkcije
y = tanh(x)

# Crtanje grafikona
plt.plot(x, y)
plt.xlabel("Ulaz (x)")
plt.ylabel("Izlaz (y)")
plt.title("Hiperbolička tangens funkcija (tanh)")
plt.grid(True)
plt.show()
```

Algoritam 3: Python code Tanh aktivacione funkcije veštačke neuronske mreže

Aktivacione funkcije su ključne u veštačkim neuronskim mrežama jer omogućavaju uvođenje nelinearnosti, što je neophodno za modeliranje složenih odnosa u podacima. *ReLU*, *Sigmoid* i *Tanh* funkcije predstavljaju tri primarna izbora, pri čemu svaki ima specifične prednosti i primene. Dok *ReLU* omogućava brzu i efikasnu obradu podataka, *Sigmoid* se idealno koristi u binarnim zadacima, a *Tanh* pruža simetričan izlaz koji olakšava učenje veštačke neuronske mreže.

Gore navedeni grafički prikazi aktivacionih funkcija veštačkih neuronskih mreža, gde *ReLU* pokazuje jasan linearni rast za pozitivne ulazne vrednosti, *Sigmoid* funkcija pokazuje S-oblikovanu krivu koja transformiše ulazne vrednosti u opseg između 0 i 1, odnosno *Tanh* aktivaciona funkcija simetrično raspoređuje vrednosti oko nule, pomažu u vizuelnom razumevanju uticaja različitih aktivacionih funkcija na prenos signala u veštačkoj neuronskoj mreži.

Izbor odgovarajuće aktivacione funkcije zavisi od specifičnih zahteva zadatka koji se rešava korišćenjem veštačke neuronske mreže i same prirode podataka, a pravilna primena ovih funkcija direktno utiče na performanse i preciznost matematičkog modela same veštačke neuronske mreže. Dalji razvoj u ovoj oblasti usmeren je na kreiranje novih aktivacionih funkcija koje mogu još bolje balansirati brzinu učenja i stabilnost matematičkog modela, kao i na

adaptivno podešavanje aktivacionih funkcija tokom procesa treniranja veštačke neuronske mreže. Ono što se može očekivati da buduća istraživanja dodatno doprinesu razvoju efikasnijih i robusnijih veštačkih neuronskih mreža, sa direktnim uticajem na primenu u kritičnim oblastima poput medicinske neurodijagnostike, kao i prepoznavanja obrazaca, posebno kod podataka sa izraženim šumom u podacima i nelinearnosti u samim podacima, što je ekletantna primer sa EEG signalima.

Veštačke neuronske mreže su sistemi visoke složenosti čiji skriveni slojevi igraju ključnu ulogu u automatskom učenju i ekstrakciji hijerarhijskih reprezentacija iz podataka. U okviru ovog naučno-istraživačkog rada detaljno je razmotrena uloga skrivenih slojeva veštačkih neurona, njihove matematičke osnove, arhitekturu i primenu, sa posebnim osvrtom na primere iz medicinske neurodijagnostike.

Skriveni slojevi veštačkih neurona se nalaze između ulaznog i izlaznog sloja veštačkih neurona u veštačkoj neuronskoj mreži. Njihova osnovna funkcija je da transformišu ulazne podatke iz prvobitnog, često sirovog oblika, u apstraktne reprezentacije koje bolje odražavaju attribute relevantne za zadatak koji se rešava. Ovo se postiže kroz niz nelinearnih transformacija, koje omogućavaju veštačkoj neuronskoj mreži da uhvati i modelira složene obrasce i odnose između podataka. Na primer, u kontekstu prepoznavanja slika, niži skriveni slojevi mogu otkriti osnovne karakteristike kao što su ivice, linije i teksture, dok dublji slojevi mogu naučiti da identifikuju komplekse strukture poput oblika, objekata ili čak scena (LeCun, Bengio, & Hinton, 2015).

Ovako opisana hijerarhijska struktura učenja je osnova tzv. „*representation learning*“ (učenje predstavljenih karakteristika), omogućava veštačkoj neuronskoj mreži da sama generiše relevantne osobine, eliminišući potrebu za manuelnim definisanjem atributa na bazi nekog domenskog znanja, kao i prepoznavanjem potrebnih hijerarhija u okviru datih podataka.

Skriveni slojevi se sastoje od velikog broja veštačkih neurona, pri čemu svaki veštački neuron u jednom sloju prima ulaz iz prethodnog sloja, gde primenjujući težinske parametre i neku od prethodno opisanih aktivacionih funkcija, izvršava nelinearnu transformaciju podataka. Tokom procesa učenja, težinski parametri se prilagođavaju kako bi se minimizirao zbir funkcije greške između predviđenih i stvarnih izlaza, čime se postepeno usavršava sposobnost veštačke neuronske mreže da prepozna relevantne obrasce u okviru dostupnih podataka. U matematičkim modelima višeslojnog perceptrona (*Multilayer Perceptron*, MLP) i dubljim veštačkim neuronskim mrežama (*Deep Neural Network*, DNN), skriveni slojevi omogućavaju transformaciju ulaznih podataka x kroz sledeću operaciju:

$$h = f(Wx + b) \quad (19)$$

gde W predstavlja matricu težina veštačke neuronske mreže, b je pristrasnost (*bias*), a f je aktivaciona funkcija koja uvodi nelinearnost. Ova formula ilustruje osnovni princip propagacije podataka kroz skriveni sloj veštačkih neurona u okviru veštačke neuronske mreže, gde se ulaz pretvara u apstraktnu reprezentaciju koja se potom prosleđuje dalje kroz veštačku neuronsku mrežu (Goodfellow, Bengio, & Courville, 2016). U oblasti medicinske neurodijagnostike, skriveni slojevi veštačkih neurona imaju posebnu važnost prilikom analize složenih podataka kao što su EEG signali. U medicinskoj neurodijagnostici epilepsije, EEG signali sadrže brojne informacije o električnoj aktivnosti mozga, ali su često zagađeni šumom i varijabilnošću zbog

različitih faktora, kao što su pokreti pacijenta ili interferencije sa spoljnih izvora. Skriveni slojevi veštačkih neurona u veštačkoj neuronskoj mreži mogu automatski naučiti da izdvoje relevantne obrasce iz ovih podataka EEG signala, identifikujući suptilne promene koje ukazuju na epileptičke napade kod pacijenata. Ovakav pristup omogućava bržu i precizniju dijagnozu, smanjujući mogućnost grešaka koje se javljaju prilikom ručne interpretacije EEG signala (Acharya et al., 2018).

Još jedan primer primene skrivenih slojeva, odnosi se na analizu snimaka magnetne rezonance mozga (*Magnetic Resonance Imaging*, MRI) u medicinskoj dijagnostici Alzheimerove bolesti. U ovom slučaju, arhitekture dubokih neuronskih mreža mogu naučiti da prepoznaju strukturalne promene u mozgu pacijenta, kao što su smanjenje volumena hipokampusa i amigdale. Ovi apstraktni obrasci, koji se ne mogu lako otkriti ručnom analizom, omogućavaju ranu identifikaciju Alzheimerove bolesti i pomoć u planiranju terapije kod pacijenata (Zhang et al., 2020).

Hijerarhijsko učenje kroz skrivene slojeve veštačkih neurona omogućava veštačkim neuronskim mrežama da postepeno apstrahuju sve više informacija iz dostupnih ulaznih i obrađenih podataka. Ova sposobnost je posebno važna u industrijskim i naučnim aplikacijama kao što je prepoznavanje obrazaca u slikama ili analizi vremenskih serija, gde se sirovi podaci moraju transformisati u forme koje su pogodnije za donošenje odluka. U kontekstu medicinske neurodijagnostike, automatsko učenje hijerarhijskih karakteristika omogućava preciznije otkrivanje abnormalnosti koje mogu biti presudne za ranu dijagnozu i pravovremeno lečenje pacijenata.

Skriveni slojevi veštačkih neurona u okviru veštačke neuronske mreže ne funkcionišu izolovano, već se oslanjaju na prethodno opisane matematičke koncepte, gde se ovde samo pomenuti neki od njih, dok kompletan opis je dat u okviru prethodnih poglavlja:

- [Linearna algebra](#) omogućava predstavljanje podataka kroz vektore i matrice, kao i transformacije podataka kroz operacije množenja matrica.
- [Teorija verovatnoće i statistika](#) omogućava matematičkim modelima da kvantifikuju nesigurnost i varijabilnost podataka, što je posebno važno u aplikacijama sa visokim nivoom šuma, kao što su EEG signali.
- [Matematička analiza](#) omogućava izračunavanje gradijenata funkcije greške, što je osnova za algoritme optimizacije kao što je *backpropagation*.
- [Informaciona teorija](#) pomaže u identifikaciji ključnih informacija u podacima kroz merenje entropije i međusobne informacije, što doprinosi efikasnijem učenju i minimizaciji gubitaka informacija.

Primena skrivenih slojeva u veštačkim neuronskim mrežama praktično omogućava efikasnu analizu medicinskih podataka. U obradi EEG signala kod pacijenata sa epilepsijom, skriveni slojevi mogu automatski identifikovati suptilne promene u električnoj aktivnosti koje ukazuju na početak epileptičkog napada. Ove informacije se dalje prenose kroz veštačku neuronsku mrežu, gde se na osnovu kombinacije različitih nivoa apstrakcije donosi konačna dijagnoza. Sličan pristup se koristi i u analizi snimaka magnetne rezonance, gde skriveni slojevi omogućavaju identifikaciju abnormalnosti u strukturi mozga pacijenta koje mogu biti indikatori neurodegenerativnih bolesti.

Razumevanje i primena skrivenih slojeva u veštačkim neuronskim mrežama predstavlja ključni korak ka razvoju efikasnih matematičkih modela za automatsku analizu podataka. Kroz hijerarhijsko učenje, veštačke neuronske mreže mogu automatski otkriti i ekstrahovati relevantne karakteristike podataka, čime se značajno unapređuje preciznost u rešavanju kompleksnih zadataka. Primena ovih metoda u medicinskoj neurodijagnostici, kao što su detekcija epileptičkih napada i identifikacija neurodegenerativnih bolesti, pokazuje potencijal ovih tehnologija da unaprede kliničku praksu i doprinesu ranijoj dijagnozi, što je od izuzetnog značaja za pravovremenu intervenciju i poboljšanje zdravstvenih ishoda kod pacijenata.

2.2.9. Primer primene veštačke neuronske mreže u klasifikaciji EEG Signala

U kontekstu medicinske neurodijagnostike, klasifikacija EEG signala predstavlja jedan od najvažnijih izazova zbog inherentne složenosti, varijabilnosti i prisustva šuma u podacima koji se koriste za treniranje matematičkog modela veštačke neuronske mreže. Savremene veštačke neuronske mreže postaju ključni alat u ovoj oblasti medicinske neurodijagnostike, jer omogućavaju automatsko otkrivanje skrivenih obrazaca u okviru EEG signala koji mogu biti presudni za identifikaciju abnormalne moždane aktivnosti kod pacijenata, kao što su epileptički napadi, a potencijalno i neka druga stanja (npr. poremećaji spavanja).

U nastavku je dat primer primene korišćenja veštačkih neuronskih mreža u klasifikaciji EEG signala koji po definiciji arhitekture samih veštačkih neuronskih mreža obuhvata nekoliko ključnih komponenti: ulazni sloj, skriveni slojevi i izlazni sloj, pri čemu svaki od ovih slojeva ima specifičnu ulogu u procesu obrade EEG zapisa i donošenju odluka tokom obrade EEG signala. Ulazni sloj veštačke neuronske mreže je prva tačka kontakta sa sirovim EEG podacima koji se dobijaju iz EEG signala. Opšte je poznato da EEG signal, koji se često sastoji od vremenskih serija sa visokim stepenom šuma i fluktuacija, zahteva efikasnu predobradu kako bi se podaci transformisali u odgovarajući numerički format. U ovoj fazi, podaci EEG signala se mogu normalizovati, filtrirati upotrebom *Butterworth* ili *Chebyshev* filtera, odnosno na taj način segmentirati u manje vremenske epohe. Segmentacija omogućava matematičkom modelu da obrađuje manje, homogenije jedinice EEG zapisa, čime se olakšava identifikacija ključnih karakteristika podataka ekstrahovanih iz EEG signala.


Kao ekletantan primer transformacije podataka iz ulaznih kroz skrivene slojeve veštačkih neurona, navodi se primer kako prilikom analize EEG signala za detekciju epileptičkih napada ulazni sloj veštačke neuronske mreže prima serije EEG podataka koje sadrže informacije o frekvencijama i amplitudama EEG signala, a nakon toga ovi sirovi EEG podaci se zatim prosleđuju skrivenim slojevima veštačke neuronske mreže, koji će izvršiti dalju ekstrakciju osobina EEG signala. U nastavku ovog naučno-istraživačkog rada su detaljno prikazani razrađeni primeri prethodno opisanih obrada podataka sa opisima grafikona koji ilustruju svaki korak.

Primer 1: Normalizacija podataka EEG signala

Proces normalizacije obezbeđuje da svi EEG kanali imaju podatke u istom skalarnom rasponu. U slučaju da se ne primeni proces normalizacije može se desiti da matematički model

veštačke neuronske mreže može davati prioritet kanalima sa većim amplitudama (npr. frontalni kanali) umesto onima sa manjim ali informativnijim signalima (npr. potiljačni alfa talasi).

U tom smislu proces normalizacije obezbeđuje da svi EEG kanali imaju podatke u istom skalarnom rasponu i na taj način se izbegava mogućnost da matematički model veštačke neuronske mreže daje prioritet kanalima sa većim amplitudama.



Slika 7: Uticaj Min-Max normalizacije na EEG signale

- **Levi panel:** Na levom panelu grafikona su prikazani nenormalizovani EEG signali za četiri kanala: F_z , C_z , P_z i O_z . Na X -osi je vreme od 0 do 5 sekundi, dok je Y -os izražen u mikrovoltima (μV) sa opsegom od -150 do $150 \mu V$. Primetićete da kanali F_z i C_z imaju veće amplitude, dok su amplitude kanala P_z i O_z znatno niže. Ova razlika može dovesti do pristrasnosti u modelima za analizu podataka.
 - **Podaci:** Nenormalizovani EEG signal sa 4 kanala (F_z , C_z , P_z i O_z).
 - **Osi:** X -osa Vreme (0–5 s), Y -osa Amplituda (μV) u rasponu $[-150, 150] \mu V$.
 - **Zapažanje:** Kanali O_z i P_z imaju niže amplitude (-50 do $50 \mu V$) u odnosu na F_z i C_z (-150 do $150 \mu V$).
- **Desni panel:** Na desnom panelu prikazani su isti signali nakon primene *Min – Max* normalizacije. Svi kanali su skalirani tako da su njihove vrednosti unutar opsega $[0, 1]$. Ova standardizacija omogućava da svaki kanal ima jednak uticaj prilikom obrade EEG signala, čime se smanjuje mogućnost da matematički model veštačke neuronske mreže favorizuju kanale sa većim amplitudama.
 - **Podaci:** Normalizovani signal koristeći Min-Max metod (raspon $[0, 1]$).
 - **Osi:** X -osa Vreme (0–5 s), Y -osa Normalizovana amplituda.
 - **Zapažanje:** Amplitude svih kanala EEG signala su skalirane na isti raspon, što olakšava poređenje.

Normalizacija smanjuje uticaj varijabilnosti uređaja i povećava stabilnost gradijenata tokom obuke matematičkog modela veštačke neuronske mreže. Prethodno su diskutovane aktivacione funkcije, ali u ovom kontekstu, ključni je grafikon koji ilustruje efekat

normalizacije EEG signala. Na grafikonu se jasno vidi kako se amplituda svih kanala izjednačava, što omogućava precizniju obradu podataka.

Min – Max normalizacija je esencijalna u obradi EEG podataka jer omogućava uniformnost u ulaznim EEG signalima, čime se matematičkim modelima veštačke neuronske mreže osigurava da svi kanali doprinose jednako. Ovo je naročito važno u aplikacijama medicinske neurodijagnostike, gde preciznost u detekciji abnormalnosti direktno utiče na kvalitet dijagnoze i, posredno, na zdravstvene ishode pacijenata.

Prethodno prikazni grafikon *Min – Max* normalizacije EEG signala, generisan je na osnovu simuliranih sintetičkih podataka, te pruža vizuelnu potvrdu važnosti normalizacije u analizi EEG signala, "Slika 7. Uticaj *Min – Max* normalizacije na EEG signale (adaptirano prema eksperimentalnoj simulaciji, Radomirovic, 2025)."

Izvorni Python kod za „Slika 7. Uticaj *Min – Max* normalizacije na EEG signale (adaptirano prema eksperimentalnoj simulaciji, Radomirovic, 2025)“.

```
import numpy as np
import matplotlib.pyplot as plt

# Generisanje vremenskog vektora (0 do 5 sekundi)
t = np.linspace(0, 5, 500)

# Simulacija EEG signala:
# Kanali Fz i Cz imaju veće amplitude (multiplikator 150)
Fz = 150 * np.sin(2 * np.pi * 1 * t)
Cz = 150 * np.cos(2 * np.pi * 1 * t)
# Kanali Pz i Oz imaju niže amplitude (multiplikator 50)
Pz = 50 * np.sin(2 * np.pi * 1 * t)
Oz = 50 * np.cos(2 * np.pi * 1 * t)

# Kreiranje levog panela: Nenormalizovani EEG signali
plt.figure(figsize=(14, 6))
plt.subplot(1, 2, 1)
plt.plot(t, Fz, label='Fz')
plt.plot(t, Cz, label='Cz')
plt.plot(t, Pz, label='Pz')
plt.plot(t, Oz, label='Oz')
plt.xlabel('Vreme (s)')
plt.ylabel('Amplituda (μV)')
plt.title('Nenormalizovani EEG signali')
plt.ylim([-150, 150])
```

```

plt.legend()

# Funkcija za Min-Max normalizaciju
def min_max_normalize(x):
    return (x - np.min(x)) / (np.max(x) - np.min(x))

# Normalizacija signala za svaki kanal
Fz_norm = min_max_normalize(Fz)
Cz_norm = min_max_normalize(Cz)
Pz_norm = min_max_normalize(Pz)
Oz_norm = min_max_normalize(Oz)

# Kreiranje desnog panela: Normalizovani EEG signali
plt.subplot(1, 2, 2)
plt.plot(t, Fz_norm, label='Fz')
plt.plot(t, Cz_norm, label='Cz')
plt.plot(t, Pz_norm, label='Pz')
plt.plot(t, Oz_norm, label='Oz')
plt.xlabel('Vreme (s)')
plt.ylabel('Normalizovana amplituda')
plt.title('Min-Max Normalizovani EEG signali')
plt.ylim([0, 1])
plt.legend()

plt.tight_layout()
plt.show()

```

Algoritam 4: Python kod Min-Max normalizacije na EEG signale

Primer 2: Filtriranje šuma u EEG signalima


Opšte je poznata činjenica da su EEG signali podložni šumu iz više izvora, gde na primer u okviru EEG signala mogu se javiti artefakti pokreta očiju (*Electrooculography*, EOG), mišićni šum (*Electromyography* EMG) ili elektromrežni šum od 50/60 Hz, koji se često detektuje kao periodični impulsi u EEG signalu. Ovi šumovi mogu znatno otežati analizu EEG podataka, posebno u aplikacijama poput onih u domenu medicinske neurodijagnostike, gde su preciznost i pouzdanost ključni. Da bi se smanjio uticaj neželjenih visokofrekventnih komponenti, često se primenjuju digitalni filteri.

Butterworth filter je jedan od najčešće korišćenih filtera zbog svoje glatke frekventne karakteristike. Niskopropusni *Butterworth* filter, sa graničnom frekvencijom od 40 Hz, izuzetno

efikasno uklanja visokofrekventne komponente iz EEG signala. Nasuprot tome, *Chebyshev* filter može pružiti strmiji pad u frekventnom domenu, ali uz mogućnost pojave oscilacija u propusnom opsegu EEG signala, što pak može biti neželjeno u nekim primenama.

U kontekstu filtriranja EEG signala, cilj je očuvati bitne informacije, kao što su alfa talasi, koji se obično javljaju u frekventnom opsegu oko 8–12 Hz, dok se eliminišu neželjeni šumovi. Na dole prikazanom grafikonu „Slika 8: Filtriranje šuma u EEG signalima *Butterworth* niskopropusnim filterom“, gornji deo prikazuje sirovi EEG signal sa vidljivim 50 Hz šumom, dok donji deo prikazuje isti EEG signal nakon primene *Butterworth* filtera četvrtog reda.

Ovaj pristup omogućava bolju vizuelizaciju relevantnih talasnih obrazaca, jer se amplituda EEG signala normalizuje kroz sve kanale, čime se smanjuje pristrasnost prema kanalima sa većim amplitudama.



Slika 8: Filtriranje šuma u EEG signalima *Butterworth* niskopropusnim filterom

- **Gornji panel:** Prikazuje sirovi EEG signal sa dodatim 50 Hz šumom. Ovaj šum se manifestuje kao periodični imuplsi koji mogu preplaviti EEG signal i samim time otežati detekciju obrazaca bitnih za kasnije procese obrade a koji se nalaze u samom EEG zapisu.
- **Donji panel:** Prikazuje filtrirani EEG signal nakon primene *Butterworth* filtera četvrtog reda sa graničnom frekvencijom od 40 Hz. Filtrirani EEG signal pokazuje značajno smanjenje visokofrekventnog šuma, što pak omogućava jasnije prepoznavanje relevantnih talasnih obrazaca kao što su alfa talasi.

Ovakav proces filtriranja je ključan u obradi EEG signala, jer normalizacija EEG podataka omogućava da matematički modeli veštačke neuronske mreže i drugi analitički alati preciznije detektuju promene u moždanoj aktivnosti, čime se poboljšava tačnost dijagnoze neuroloških poremećaja kod pacijenata.

Primena digitalnih filtera, kao što su *Butterworth* i *Chebyshev* filteri, omogućava istraživačima da eliminišu neželjene komponente EEG signala, čime se fokus prebacuje na važne komponente EEG signala koji su bitni za kliničku interpretaciju EEG zapisa (Oppenheim & Schafer, 2010).

Izvorni Python kod za "Slika 8. Filtriranje šuma u EEG signalima *Butterworth* niskopropusnim filterom (adaptirano prema eksperimentalnoj simulaciji, Radomirović, 2025)."

```
import numpy as np
import matplotlib.pyplot as plt
from scipy.signal import butter, filtfilt

# Definisanje funkcije za kreiranje pip
def butter_lowpass(cutoff, fs, order=4):
    nyq = 0.5 * fs # Nyquist frekvencija
    normal_cutoff = cutoff / nyq
    b, a = butter(order, normal_cutoff, btype='low', analog=False)
    return b, a

# Funkcija za primenu filtera
def lowpass_filter(data, cutoff, fs, order=4):
    b, a = butter_lowpass(cutoff, fs, order=order)
    y = filtfilt(b, a, data)
    return y

# Parametri simulacije
fs = 500 # Frekvencija uzorkovanja u Hz
t = np.linspace(0, 5, fs * 5) # Vremenski vektor za 5 sekundi

# Kreiranje sintetičkog EEG signala: osnovni signal + 50 Hz šum
# Osnovni EEG signal: sinusoidni signal koji predstavlja alfa talase (10 Hz)
eeg_signal = 100 * np.sin(2 * np.pi * 10 * t)
# Šum: sinusoidna komponenta na 50 Hz koja simulira mrežni šum
noise = 50 * np.sin(2 * np.pi * 50 * t)
# Kombinovani signal: EEG signal sa šumom
raw_signal = eeg_signal + noise

# Primena Butterworth niskopropusnog filtera sa cutoff frekvencijom 40 Hz
filtered_signal = lowpass_filter(raw_signal, cutoff=40, fs=fs, order=4)

# Kreiranje grafikona
```

```

plt.figure(figsize=(14, 8))

# Gornji panel: Sirovi EEG signal sa šumom
plt.subplot(2, 1, 1)
plt.plot(t, raw_signal, label='Sirovi EEG signal')
plt.xlabel('Vreme (s)')
plt.ylabel('Amplituda (μV)')
plt.title('Sirovi EEG signal sa 50 Hz šumom')
plt.legend()
plt.grid(True)

# Donji panel: Filtrirani EEG signal
plt.subplot(2, 1, 2)
plt.plot(t, filtered_signal, color='orange', label='Filtrirani EEG signal')
plt.xlabel('Vreme (s)')
plt.ylabel('Amplituda (μV)')
plt.title('EEG signal nakon primene Butterworth niskopropusnog filtera (cutoff=40 Hz)')
plt.legend()
plt.grid(True)

plt.tight_layout()
plt.show()

```

Algoritam 5: Python kod filtriranja EEG signala *Butterworth* niskopropusnim filterom

U gornjem Python kodu, sintetički EEG signal se kreira kao sinusoidna komponenta od 10 Hz, koja predstavlja osnovnu frekvenciju alfa talasa, uz dodatak sinusoidnog šuma na 50 Hz koji simulira elektromrežni šum. Primena *Butterworth* niskopropusnog filtera četvrtog reda sa *cutoff* frekvencijom od 40 Hz omogućava da se uklone visokofrekventne komponente (50 Hz šum), dok se osnovni EEG signal zadržava. Rezultat filtriranja je EEG signal koji ima značajno smanjen šum, čime se olakšava dalja analiza i interpretacija podataka u kontekstu medicinske neurodijagnostike.

Grafikoni generisani ovim Python kodom ilustruju pre i posle filtriranja: gornji panel prikazuje sirovi EEG signal sa izraženim 50 Hz šumom, dok donji panel prikazuje filtrirani EEG signal, gde su visoke frekvencije uspešno uklonjene. Ovakav pristup filtriranja omogućava da se analiziraju samo relevantni EEG signali, čime se poboljšava tačnost daljih analiza, kao što je automatska detekcija abnormalnih obrazaca u EEG signalu kod pacijenata.


Primer 3: Segmentacija podataka

Segmentacija podataka predstavlja ključnu tehniku u analizi EEG signala, posebno kada je cilj detekcija kratkotrajnih događaja kao što su epileptički impulsi kod pacijenata. Ova

metoda podrazumeva deljenje kontinuiranog EEG signala u manje epohe, koje obično traju od 1 do 4 sekunde. Takva podela omogućava detaljniju analizu dinamike EEG signala, jer se u svakoj vremenskoj epohi mogu preciznije identifikovati promene u amplitudi, frekvenciji i obrascima koji se javljaju tokom kratkih vremenskih intervala.

Segmentacija je naročito značajna jer EEG signale karakterišu visoka varijabilnost i prisustvo inherentnog šuma, što otežava analizu kada se gleda ceo kontinuirani zapis EEG signala. Deljenjem EEG signala na manje vremenske epohe, moguće je izolovati specifične obrasce i prilagoditi obradu podataka tako da se istaknu dominantne frekvencije, poput alfa talasa koji se obično javljaju u intervalu od 8 do 12 Hz.

Primer segmentacije, gde se ulazni EEG signal deli u segmente dužine od jedne sekunde, omogućava matematičkim modelima veštačkih neuronskih mreža da bolje „razumeju“ lokalne karakteristike EEG signala. Ovo je posebno korisno u medicinskoj neurodijagnostici, gde precizno određivanje promena u EEG zapisima može ukazati na početak epileptičkih napada ili drugih abnormalnosti kod pacijenata.



Slika 9: Segmentacija podataka EEG signala na vremenske epohe

Vizuelni prikaz segmentacije obično se realizuje tako što se kontinuirani EEG signal prikazuje kao niz uzastopnih segmenata, pri čemu se granice između vremenskih epoha označavaju vertikalnim linijama.

Svaka vremenska epoha može biti predstavljena različitom bojom (npr. plava, zelena, crvena) kako bi se olakšalo razlikovanje i praćenje promena tokom vremena. Ovakav pristup omogućava istraživačima da vrlo brzo uoče lokalne promene u okviru EEG signala i da dalje primene algoritme za automatsku detekciju abnormalnosti u okviru EEG zapisa.

Segmentacija kao takva predstavlja jedan od osnovnih i početnih koraka u obradi EEG podataka koji omogućava ne samo smanjenje uticaja inherentnog šuma već i povećanje preciznosti u analizi i interpretaciji EEG signala, čime se doprinosi boljoj i bržoj dijagnostici neuroloških poremećaja kod pacijenata.

Sledeći Python kod prikazuje primer segmentacije sintetičkog EEG signala u vremenske epohe od 1 sekunde, gde se svaka vremenska epoha prikazuje u drugoj boji radi lakše vizualizacije kompletnog EEG zapisa, a granice između vremenskih epoha su označene vertikalnim linijama. Izvorni Python kod za " Slika 9: Segmentacija podataka EEG signala na vremenske epohe (adaptirano prema eksperimentalnoj simulaciji, Radomirović, 2025)."

```
import numpy as np
import matplotlib.pyplot as plt
from scipy.signal import butter, filtfilt

# Parametri simulacije
fs = 250 # Frekvencija uzorkovanja (Hz)
duration = 5 # Ukupno trajanje signala (s)
t = np.linspace(0, duration, fs * duration) # Vremenski vektor

# Kreiranje sintetičkog EEG signala: sinusoidni signal sa dominantnom frekvencijom
# alfa talasa (10 Hz) + dodatni šum
eeg_clean = 50 * np.sin(2 * np.pi * 10 * t)
noise = 10 * np.random.randn(len(t))
eeg_signal = eeg_clean + noise

# Definisanje trajanja epohe u sekundama
epoch_duration = 1 # 1 sekunda po epozi
epoch_samples = int(fs * epoch_duration)
num_epochs = len(t) // epoch_samples

# Generisanje boja za svaki segment
colors = ['blue', 'green', 'red', 'purple', 'orange']

# Kreiranje figure
plt.figure(figsize=(14, 8))
plt.plot(t, eeg_signal, color='lightgray', label='Originalni EEG signal') # crni sirovi signal
# u pozadini

# Segmentacija signala i prikazivanje segmentovanih epoha sa različitim bojama
for i in range(num_epochs):
    start = i * epoch_samples
    end = start + epoch_samples
    epoch_t = t[start:end]
    epoch_signal = eeg_signal[start:end]
    plt.plot(epoch_t, epoch_signal, color=colors[i % len(colors)], linewidth=2,
    label=f'Epoha {i+1}')
```

```
plt.axvline(x=t[end-1], color='k', linestyle='--', linewidth=0.8) # vertikalna linija na kraju epohe
```

```
plt.xlabel('Vreme (s)')  
plt.ylabel('Amplituda ( $\mu$ V)')  
plt.title('Segmentacija EEG signala u epohe')  
plt.legend()  
plt.grid(True)  
plt.tight_layout()  
plt.show()
```

Algoritam 6: Python kod segmentacije podataka u EEG signalima u vremenske epohe


U gore navedenom primeru, sintetički EEG signal se kreira kao sinusoidna komponenta koja simulira alfa talase, uz dodatak slučajnog šuma. Nakon toga EEG signal se zatim deli na vremenske epohe dužine od jedne sekunde. Svaka vremenska epoha se prikazuje u drugačijoj boji, što omogućava vizuelno razlikovanje segmenata EEG signala. Vertikalne linije se dodaju na kraju svake vremenske epohe kako bi se jasno označile granice između segmenata EEG signala. Takav prikaz očigledno pomaže u analizi dinamike EEG zapisa, što je od ključnog značaja u medicinskoj neurodijagnostici.

Primer 4: Ekstrakcija karakteristika EEG signala

Ekstrakcija karakteristika predstavlja ključnu fazu u obradi EEG signala, jer omogućava redukciju dimenzionalnosti podataka i ističe one informacije koje su biološki i medicinski relevantne. Poznata je činjenica da EEG signali sadrže bogat spektar informacija koje se mogu opisati kroz više aspekata, gde kao ključne karakteristike EEG signala izdvajamo:

- **Frekvencijski pojasevi:** EEG signal se sastoji od različitih frekvencijskih pojaseva, a među najznačajnijima su:
 - **Delta:** 0.5–4 Hz koji je povezan sa dubokim snom ili teškim oštećenjima moždane aktivnosti.
 - **Theta:** 4–8 Hz koji se često posmatra u stanjima pospanosti i kreativnog razmišljanja.
 - **Alfa:** 8–12 Hz koji je karakterističan za opuštenu budnost, naročito sa zatvorenim očima.
 - **Beta:** 12–30 Hz koji je povezan sa aktivnim razmišljanjem, koncentracijom i anksioznošću.
 - **Gama:** >30 Hz koji je povezano sa visoko-kognitivnim procesima i integracijom informacija.
- **Vremenske osobine:** Ove osobine se odnose na promene u amplitudama EEG signala tokom vremena, kao na primer:
 - **Amplitude impulsa:** Iznenaadne promene amplitude impulsa EEG signala mogu ukazivati na epileptičke napade ili druge abnormalnosti.

- **Hjorth parametri:** Merenje mobilnosti (koliko brzo se EEG signal menja) i složenosti EEG signala pruža dodatne informacije o dinamičkoj strukturi samog EEG zapisa.
- **Statističke mere:** U analizi EEG signala, statističke mere kao što su standardna devijacija i entropija koriste se za kvantifikovanje varijabilnosti i nesigurnosti u EEG podacima. Ove mere mogu pomoći u identifikaciji značajnih promena u obrascima podataka kod EEG signala.



Slika 10: Spektrogram karakteristika EEG signal

Gore navedeni grafikoni „Slika 10: Spektrogram karakteristika EEG signala“ prikazuju spektrogram EEG signala, u kome su jasno označeni frekvencijski pojasevi kao što su delta, theta, alfa i beta. Toplotna mapa koristi boje da prikaže intenzitet frekvencijskih komponenti EEG signala gde područja sa visokom snagom u alfa opsegu biće prikazana crvenom bojom, dok područja sa nižom snagom mogu biti prikazana u hladnijim tonovima (plava ili zelena). U nastavku ovog naučno-istraživačkog rada je prikazan opis grafikona sa "Slika 10: Spektrogram karakteristika EEG signala" dobijen ekstrakcijom karakteristika sintetičkog EEG signala:

- **X-osa:** Vreme (u sekundama)
- **Y-osa:** Frekvencija (u Hz)

Ovaj spektrogram omogućava vizuelnu analizu kako se frekvencijski sadržaj EEG zapisa se menja tokom vremena, čime se ističu važne karakteristike EEG signala koje mogu biti od presudnog značaja za dalju analizu, npr. identifikaciju abnormalnih obrazaca koji ukazuju na epileptičke napade kod pacijenata. Sledeći Python kod generiše spektrogram sintetičkog EEG signala, gde se frekvencijski pojasevi jasno ističu pomoću toplotne mape. Ovaj primer simulira EEG signal sa dominantnom alfa komponentom i dodatnim šumom, a spektrogram prikazuje distribuciju snage signalnih frekvencija EEG signala tokom vremena. Izvorni Python

kod za "Slika 10: Spektrogram karakteristika EEG signala (adaptirano prema eksperimentalnoj simulaciji, Radomirović, 2025)."

```
import numpy as np
import matplotlib.pyplot as plt
from scipy.signal import spectrogram

# Parametri Spektrogram simulacije
fs = 250 # Frekvencija uzorkovanja (Hz)
duration = 10 # Trajanje signala u sekundama
t = np.linspace(0, duration, fs * duration, endpoint=False)

# Kreiranje sintetičkog EEG signala:
# Simuliramo signal sa dominantnom alfa frekvencijom (10 Hz) i dodatnim šumom
alpha_wave = 50 * np.sin(2 * np.pi * 10 * t)
noise = 15 * np.random.randn(len(t))
eeg_signal = alpha_wave + noise

# Izračunavanje spektrograma
f, t_spec, Sxx = spectrogram(eeg_signal, fs=fs, window='hann', nperseg=fs//2,
                             noverlap=fs//4)

# Konvertovanje snage u decibele
Sxx_db = 10 * np.log10(Sxx + 1e-10) # Dodajemo malu konstantu da izbegnemo log(0)

# Kreiranje grafikona
plt.figure(figsize=(14, 8))
plt.pcolormesh(t_spec, f, Sxx_db, shading='gouraud', cmap='viridis')
plt.title('Spektrogram EEG signala sa označenim frekvencijskim pojasevima')
plt.ylabel('Frekvencija (Hz)')
plt.xlabel('Vreme (s)')
cbar = plt.colorbar()
cbar.set_label('Snaga (dB)')
plt.ylim([0, 40]) # Fokus na frekvencijski opseg do 40 Hz, gde se nalaze delta, theta, alfa i beta pojasevi
plt.tight_layout()
plt.show()
```

Algoritam 7: Python kod za ekstrakciju karakteristika EEG signala

U nastavku se navodi objašnjenje za izvorni Python kod za „Slika 10: Spektrogram karakteristika EEG signal (adaptirano prema eksperimentalnoj simulaciji, Radomirovic, 2025)“.

- **Generisanje signala:**
 - Postavlja se frekvenciju uzorkovanja (f_s) na 250 Hz i trajanje signala na 10 sekundi.
 - Kreira se sintetički EEG signal koji se sastoji od dominantne alfa komponente (10 Hz sinusoid) i dodatnog slučajnog šuma.
- **Izračunavanje spektrograma:**
 - Koristi se funkcija *spectrogram* iz *Python SciPy* biblioteke da bi se dobili spektrogram EEG signala. Parametri kao što su veličina prozora i preklapanje su podešeni da bi se dobio glatki spektrogram.
 - Rezultat S_{xx} predstavlja snagu EEG signala na različitim frekvencijama i vremenima, a zatim se konvertuje u decibele radi bolje vizualizacije.
- **Vizuelizacija:**
 - Pomoću *pcolormesh* funkcije iz *Python Matplotlib* biblioteke, spektrogram se prikazuje kao toplotna mapa, gde boje predstavljaju snagu EEG signala.
 - Ose grafikona su postavljene tako da X -osa predstavlja vreme, a Y -osa frekvenciju. Grafikon se fokusira na frekvencijski opseg EEG signala do 40 Hz, koji obuhvata najvažnije EEG frekvencijske pojaseve signala (delta, theta, alfa, beta).

Gore prikazani primer spektrograma EEG signala jasno demonstrira kako se ekstrakcija karakteristika/atributa EEG zapisa može vizuelno prikazati, odnosno kako se može koristiti za identifikaciju ključnih frekvencijskih komponenti EEG signala, što je od izuzetne važnosti u medicinskoj neurodijagnostici kod pacijenata.


Primer 5: Prostorna obrada EEG signala

Metode prostorne obrade, kao što je metoda zajedničkih prostornih modela (*Common Spatial Patterns*, CSP), ključne su za analizu prostorne strukture EEG signala. Algoritam zajedničkih prostornih modela je posebno dizajniran da istraži prostorne odnose između elektroda i da maksimizira varijansu EEG signala između dve ciljne klase.

Konkretno u zadacima koji uključuju klasifikaciju pokreta, metoda zajedničkih prostornih modela može da istakne razlike između pokreta leve i desne ruke. Osnovna ideja algoritma zajedničkih prostornih modela je da transformiše originalni EEG signal u prostor gde su EEG signali različitih klasa što je moguće više razdvojeni.

Ova transformacija omogućava da se globalni šum, koji se pojavljuje u svim kanalima EEG signala, filtrira, dok se fokusira na lokalne obrasce koji su biološki i medicinski relevantni za dalju obradu matematičkim modelima veštačke neuronske mreže.

Grafički prikaz ovog procesa može biti predstavljen u dva panela:



Slika 11: Obrada EEG signala metodom zajedničkih prostornih modela (CSP)

- **Levi panel:** Prikazuje topografsku mapu sirovih EEG amplituda prikupljenih sa 32 kanala/elektroda. Ova topografska mapa se dobija interpolacijom vrednosti dobijenih sa elektroda na modelu glave pacijenta, što pak omogućava vizuelnu interpretaciju prostorne raspodele EEG zapisa. Na ovakvoj mapi mogu se primetiti regionalne varijacije, gde neki kanali (npr. frontalni) imaju veće amplitude, dok drugi (npr. potiljačni) pokazuju niže vrednosti.
- **Desni panel:** Prikazuje rezultate primene algoritma zajedničkih prostornih modela (CSP), odnosno prve komponente algoritma zajedničkih prostornih modela, koja maksimalno naglašava razlike između dve klase (npr. pokret leve vs. desne ruke). U ovom prikazu, vektorski grafikon pokazuje doprinos pojedinih elektroda (prema 10-20 sistemu) u formiranju komponente zajedničkih prostornih modela. Na ovaj način se dobija uvid u to koji kanali EEG signala imaju najveći uticaj na razlikovanje između klase, čime se identifikuju lokalni obrasci relevantni za kasniju klasifikaciju.

Prostorna obrada zajedničkih prostornih modela ima višestruke prednosti u primeni veštačkih neuronskih mreža u medicinskoj neurodijagnostici. Pre svega, omogućava da se EEG zapisi, koji su često zagađeni globalnim (iheretnim) šumom, transformišu u prostor gde se ističu specifične, lokalne karakteristike EEG signala.

Ovo je posebno korisno u detekciji epileptičkih napada, gde su suptilne promene u električnoj aktivnosti mozga pacijenta kritične za pravovremenu dijagnozu. Primena algoritma zajedničkih prostornih modela može poboljšati tačnost matematičkog modela veštačke neuronske mreže u zadacima klasifikacije pokreta, jer se fokusira na informacije koje su direktno povezane sa funkcionalnim aktivnostima mozga pacijenta.

U nastavku ovog naučno-istraživačkog rada se nalazi primer Python koda koji simulira proces opisanog kao algoritam zajedničkih prostornih modela. Python kod generiše dva grafička panela, prvi grafički panel sa topografskom mapom sintetičkih sirovih EEG amplituda, a drugi grafički panel prikazuje rezultate primene algoritma zajedničkih prostornih modela. Sledeći Python kod se može koristiti kao osnova za vizuelizaciju i dalje istraživanje prostorne obrade EEG signala.

```

import numpy as np
import matplotlib.pyplot as plt
from scipy.interpolate import griddata

# Simulacija podataka za algoritam zajedničkih prostornih modela
np.random.seed(42)
n_channels = 32

# Generisanje slučajnih pozicija elektroda na površini glave (u 2D prostoru)
# Pretpostavlja se jednostavan model gde se pozicije kreću unutar kruga
angles = np.linspace(0, 2*np.pi, n_channels, endpoint=False)
radii = np.random.uniform(0.5, 1.0, n_channels)
electrode_x = radii * np.cos(angles)
electrode_y = radii * np.sin(angles)

# Simulacija sirovih EEG amplituda ( $\mu$ V) za svaki kanal
raw_amplitudes = np.random.uniform(-150, 150, n_channels)

# Simulacija CSP komponente (prva komponenta koja naglašava razlike između klasa)
# Pretpostavi se da CSP algoritam izdvoji pozitivne vrednosti za kanale koji imaju veći značaj
csp_component = raw_amplitudes * np.random.uniform(0.5, 1.5, n_channels)

# Kreiranje grida za interpolaciju (za topografsku mapu)
grid_x, grid_y = np.mgrid[-1:1:200j, -1:1:200j]

# Interpolacija sirovih EEG amplituda
grid_raw = griddata((electrode_x, electrode_y), raw_amplitudes, (grid_x, grid_y),
method='cubic')

# Interpolacija CSP komponente
grid_csp = griddata((electrode_x, electrode_y), csp_component, (grid_x, grid_y),
method='cubic')

# Plotovanje grafikona
fig, axes = plt.subplots(1, 2, figsize=(16, 7))

# Levi panel: Topografska mapa sirovih EEG amplituda
c1 = axes[0].imshow(grid_raw, extent=(-1, 1, -1, 1), origin='lower', cmap='jet')
axes[0].scatter(electrode_x, electrode_y, c='k', s=50, label='Elektrode')
axes[0].set_title('Topografska mapa sirovih EEG amplituda')

```

```

axes[0].set_xlabel('X pozicija')
axes[0].set_ylabel('Y pozicija')
axes[0].legend()
fig.colorbar(c1, ax=axes[0], orientation='vertical', label='Amplituda ( $\mu V$ )')

# Desni panel: CSP komponenta nakon obuke
c2 = axes[1].imshow(grid_csp, extent=(-1, 1, -1, 1), origin='lower', cmap='viridis')
axes[1].scatter(electrode_x, electrode_y, c='k', s=50, label='Elektrode')
axes[1].set_title('CSP komponenta - Prva komponenta')
axes[1].set_xlabel('X pozicija')
axes[1].set_ylabel('Y pozicija')
axes[1].legend()
fig.colorbar(c2, ax=axes[1], orientation='vertical', label='CSP vrednost')

plt.suptitle('Prostorna filtracija korišćenjem CSP algoritma')
plt.tight_layout(rect=[0, 0.03, 1, 0.95])
plt.show()

```

Algoritam 8: Python kod za obrada EEG signala zajedničkim prostornim modelom (CSP)

U nastavku se navodi objašnjenje za izvorni Python kod za „Slika 11: Obrada EEG signala metodom zajedničkih prostornih modela (CSP) (adaptirano prema eksperimentalnoj simulaciji, Radomirovic, 2025)“.

- **Simulacija podataka:**
 - Generišu su slučajne 2D koordinate za 32 elektroda unutar kruga, simulirajući pozicije prema 10-20 sistemu.
 - Slučajnim vrednostima dodeljuje su sirove amplitude sintetičkog EEG signala u rasponu od -150 do 150 μV .
 - Simulira se komponenta metode zajedničkih prostornih modela tako što se modifikuju sirove amplitude sintetičkog EEG signala kako bi se naglasili kanali koji imaju veći značaj u razlikovanju između klasa.
- **Interpolacija:**
 - Koristi se *griddata* funkciju za interpolaciju podataka sa elektroda na 2D mrežu koja predstavlja površinu glave pacijenta. Ovo omogućava generisanje glatkih topografskih mapa za sirove amplitude sintetičkog EEG signala i komponente metode zajedničkih prostornih modela.
- **Vizuelizacija:**
 - Prvi grafički panel prikazuje topografsku mapu sirovih amplituda sintetičkog EEG signala, dok drugi panel prikazuje komponentu metode zajedničkih prostornih modela nakon obuke na sintetičkim EEG zapisima.

- Oba grafička panela uključuju *scatter plot* koji označava pozicije elektroda, a toplotne mape (*colorbars*) vizualizuju vrednosti amplituda EEG zapisa i vrednosti komponente metode zajedničkih prostornih modela.
- Grafikon sadrži odgovarajuće naslove, oznake osa i legendu kako bi se olakšalo razumevanje prikazanih podataka.

Primer 6: Obrada EEG signala u veštačkoj neuronskoj mreži


Skriveni slojevi predstavljaju "srce" veštačkih neuronskih mreža, gde se odvija većina obrade podataka i učenja. U ovim slojevima, podaci se transformišu kroz niz nelinearnih operacija, koje omogućavaju veštačkoj neuronskoj mreži da automatski otkrije i izvuče kompleksne obrasce i strukture iz ulaznih podataka. U slučaju EEG signala, niži skriveni slojevi veštačke neuronske mreže mogu otkriti osnovne karakteristike poput promena u frekvencijama i amplitudama, dok dublji slojevi uče apstraktnije reprezentacije koje mogu ukazivati na abnormalnosti, kao što su epileptički napadi ili specifične regionalne anomalije.

U praksi, skriveni slojevi veštačke neuronske mreže funkcionišu kao hijerarhijski filteri, gde se ulazni podaci, koji mogu biti sirovi i veoma kompleksni, prolaze kroz niz transformacija, pri čemu svaka transformacija je vođena težinskim parametrima i prethodno opisanim aktivacionim funkcijama (kao što su *ReLU*, *Sigmoid* i *Tanh*). Aktivacione funkcije uvode nelinearnost u sistem veštačke neuronske mreže, čime se omogućava matematičkom modelu veštačke neuronske mreže da "nauči" nelinearne odnose koji nisu dostupni tradicionalnim linearnim metodama. Ovakav pristup se često naziva učenjem predstavljenih karakteristika, jer veštačka neuronska mreža automatski kreira hijerarhiju osobina koje olakšavaju kasniju klasifikaciju ili predviđanje (Goodfellow, Bengio, & Courville, 2016).

U oblasti medicinske neurodijagnostike, skriveni slojevi veštačke neuronske mreže imaju posebnu ulogu pri analizi EEG signala. EEG zapisi koji su inherentno kompleksni i podložni šumovima, zahtevaju sofisticirane tehnike obrade. Istraživanje Acharya et al. (2018) pokazalo je da matematički modeli bazirani na konvolucionim neuronskim mrežama (CNN) mogu uspešno klasifikovati epileptične napade iz EEG signala, zahvaljujući sposobnosti da skriveni slojevi izdvoje ključne obrasce u EEG signalu.

Iako je prethodno spomenuti rad (Acharya et al. 2018) naglašavao upotrebu arhitekturu konvolucione neuronske mreže, isti princip se primenjuje i u rekurentnim neuronskim mrežama (RNN) i posebnim modelima rekurentnih neuronskih mreža kao što su LSTM veštačke neuronske mreže, gde se podaci "slože" u više nivoa reprezentacije. Time se postiže efikasna ekstrakcija karakteristika/atributa EEG signala, što omogućava preciznu identifikaciju abnormalnosti u moždanoj aktivnosti kod pacijenata. Skriveni slojevi veštačke neuronske mreže ne samo da omogućavaju otkrivanje skrivenih obrazaca, već i pomažu u eliminaciji inherentnog šuma. Nelinearne aktivacione funkcije automatski filtriraju irelevantne informacije, fokusirajući veštačku neuronsku mrežu na signale od interesa u okviru EEG zapisa. Ovo je posebno važno u analizi EEG signala, gde prisustvo artefakata ili interferencija može značajno narušiti tačnost dijagnoze, a primena filtera, regularizacije, nelinearnih aktivacionih funkcija i prethodno opisanih mehanizama omogućava matematičkom modelu veštačke neuronske mreže da pruži pouzdane rezultate, što je pak od suštinskog značaja za medicinsku neurodijagnostiku.

Kao jedan od osnovnih primera koncepta aktivacije u nastavku je opisan višeslojni perceptron (MLP) model sa jednim skrivenim slojem. Sledeći primer Python koda prikazuje kako skriveni sloj veštačke neuronske mreže transformiše ulazne podatke. Ovaj primer koristi jednostavan višeslojni perceptron (MLP) model sa jednim skrivenim slojem, te prikazuje kako aktivaciona funkcija (u ovom slučaju *ReLU*) transformiše ulazne vrednosti. Dati Python kod takođe generiše grafikon koji vizuelno prikazuje distribuciju podataka pre i posle primene aktivacione funkcije.



Slika 12: ReLU aktivaciona funkcija

U nastavku se navodi objašnjenje za izvorni Python kod za “Slika 12. *ReLU* aktivaciona funkcija (adaptirano prema eksperimentalnoj simulaciji, Radomirovic, 2025)”.

```
import numpy as np
import matplotlib.pyplot as plt

# Generišu se slučajni ulazni podaci
np.random.seed(42)
x = np.linspace(-10, 10, 400)

# Simulacija linearne transformacije:  $y = wx + b$ , gde su  $w=1.5$  i  $b=-2$ 
w = 1.5
b = -2
z = w * x + b

# Primena ReLU aktivacione funkcije:  $f(z) = \max(0, z)$ 
def relu(x):
    return np.maximum(0, x)
a = relu(z)

# Kreiranje grafikona
plt.figure(figsize=(14, 6))
```

```

# Prvi panel: Linearna transformacija
plt.subplot(1, 2, 1)
plt.plot(x, z, color='blue', label='z = 1.5x - 2')
plt.title('Rezultat linearne transformacije')
plt.xlabel('Ulaz x')
plt.ylabel('z = 1.5x - 2')
plt.legend()
plt.grid(True)

# Drugi panel: Rezultat ReLU aktivacije
plt.subplot(1, 2, 2)
plt.plot(x, a, color='red', label='ReLU(z)')
plt.title('Rezultat ReLU aktivacione funkcije')
plt.xlabel('Ulaz x')
plt.ylabel('Aktivirani izlaz')
plt.legend()
plt.grid(True)

plt.suptitle('Transformacija podataka kroz skriveni sloj sa ReLU aktivacijom')
plt.tight_layout(rect=[0, 0.03, 1, 0.95])
plt.show()

```

Algoritam 9: Python kod za ReLU aktivacionu funkciju


- **Ulazni podaci:** Generiše se niz vrednosti x u opsegu od -10 do 10, koji predstavljaju ulazne vrednosti.
- **Linearno transformisanje:** Primena linearne transformacije ($y = w \cdot x + b$) simulira operaciju koju vrši ulazni signal pre primene aktivacione funkcije. Ovde se koristi fiksni koeficijent $w = 1.5$ i *bias* $b = -2$.
- **ReLU aktivacija:** Python funkcija *relu* primenjuje *ReLU* aktivacionu funkciju na transformisane podatke, što rezultira izlazom koji je nula za negativne vrednosti i linearno raste za pozitivne vrednosti.
- **Vizuelizacija:** Prvi grafikon prikazuje linearno transformisani signal, dok drugi prikazuje rezultat primene *ReLU* funkcije. Ovo omogućava vizuelno poređenje i bolju interpretaciju uloge skrivenog sloja.

Izlazni sloj predstavlja poslednju komponentu veštačkih neuronskih mreža i ima ključnu ulogu u generisanju konačnih odluka koje se koriste za klasifikaciju podataka. Njegova funkcija je da, na osnovu transformacija koje su izvršene u prethodnim (skrivenim) slojevima veštačkih neuronskih mreža, prevede kompleksne interne reprezentacije podataka u jednostavan, interpretabilan izlaz. Priroda izlaznog sloja direktno zavisi od zadatka koji se rešava, tako na primer za regresione zadatke izlaz može biti kontinualna vrednost, dok se za klasifikacione zadatke koristi se niz verovatnoća koje predstavljaju pripadnost određenim kategorijama.

U kontekstu medicinske neurodijagnostike epilepsije, model treniran na EEG signalima prolazi kroz ulazni sloj, zatim kroz skriveni sloj gde se ekstraktuju relevantne karakteristike EEG zapisa, a na kraju izlazni sloj koristi *Softmax* funkciju kako bi generisao verovatnoće koje ukazuju na prisustvo ili odsustvo epileptičkih napada. Aktivaciona *Softmax* funkcija je ključna u višeklasnoj klasifikaciji jer transformiše ulazne vrednosti (*logite*) u skup verovatnoća čiji zbir iznosi 1. U tom smislu ako matematički model veštačke neuronske mreže skrivenih slojeva generiše izlazni vektor [2.0, 0.5] za dve klase, *Softmax* će transformisati te vrednosti tako da, na primer, dobijeni rezultat može biti [0.85, 0.15]. Ovo se tumači kao 85% verovatnoće da je EEG signal „normalan“ i 15% verovatnoće da ukazuje na epileptički napad kod pacijenta. *Softmax* funkcija se primenjuje na ulazni vektor z čije komponente mogu biti bilo koji realni brojevi, gde se *Softmax* funkcija se definiše kao:

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_j e^{z_j}}$$

gde je z_i -ta komponenta ulaznog vektora, a suma u imeniocu se vrši preko svih komponenti vektora. Ova transformacija pretvara ulazne vrednosti u verovatnoće, pri čemu su veće vrednosti eksponencijalno naglašene, a sve vrednosti se normalizuju tako da zbir bude jednak 1. Ovakav pristup omogućava da se pacijenti efikasno klasifikuju na osnovu njihovih EEG zapisa, čime se poboljšava tačnost dijagnostike i omogućava brža intervencija, što je od presudnog značaja za lečenje pacijenata.



Slika 13: Primena Softmax aktivacione funkcije u klasifikaciji

Primena *Softmax* funkcije u izlaznom sloju veštačkih neuronskih mreža omogućava transformaciju neobrađenih izlaznih vrednosti u interpretabilan oblik verovatnoće. Ovo je ključno u zadacima klasifikacije, posebno u medicinskoj dijagnostici epilepsije, gde preciznost i brzina donošenja odluka mogu direktno uticati na ishode i samo lečenje pacijenata.

Kroz integraciju ovakvih funkcija, matematički modeli postaju sposobni da automatski klasifikuju EEG signale, čime se unapređuje preciznost dijagnostike i omogućava pravovremena intervencija. Prethodno navedni osnovni primer MLP, uz vizuelni prikaz *Softmax* transformacije, ilustruje kako se napredne matematičke funkcije koriste u modernim matematičkim modelima veštačkih neuronskih mreža za rešavanje realnih problema u biomedicinskoj analizi podataka.

Izbor odgovarajuće aktivacione funkcije u izlaznom sloju veštačke neuronske mreže je kritičan jer utiče na interpretabilnost izlaza. *Softmax* je posebno koristan u višeklasnim zadacima jer omogućava transparentno predstavljanje verovatnoća, što pomaže stručnjacima da donesu informisane odluke, osim toga ovaj pristup se lako kombinuje sa metodama optimizacije, gde se minimiziraju funkcije greške (npr. unakrsna entropija) kako bi se poboljšala preciznost matematičkog modela tokom samog procesa treniranja matematičkog modela veštačke neuronske mreže.

Kako bi se ovaj koncept dodatno ilustrovao, sledeći Python kod prikazuje grafički primer *Softmax* funkcije. Ovaj grafikon simulira ulazne vrednosti iz izlaznog sloja veštačke neuronske mreže i prikazuje kako *Softmax* funkcija transformiše te vrednosti u verovatnoće, što je centralno za klasifikacione zadatke. Izvorni Python kod za "Slika 13. Primena *Softmax* aktivacione funkcije u klasifikaciji (adaptirano prema eksperimentalnoj simulaciji, Radomirović, 2025)."

```
import numpy as np
import matplotlib.pyplot as plt

# Definisanje softmax funkcije
def softmax(x):
    exp_x = np.exp(x - np.max(x)) # stabilizacija eksponencijalne funkcije
    return exp_x / exp_x.sum(axis=0)

# Primer ulaznog vektora iz izlaznog sloja (npr. logiti)
x = np.array([2.0, 1.0, 0.1])
softmax_output = softmax(x)

# Kreiranje grafikona
fig, ax = plt.subplots(figsize=(8, 6))
bar_width = 0.5
index = np.arange(len(x))

# Prikaz originalnih ulaznih vrednosti (logiti) i softmax izlaza
ax.bar(index, x, bar_width, label='Logiti', color='skyblue')
ax.bar(index + bar_width, softmax_output, bar_width, label='Softmax izlaz', color='salmon')
```

```

ax.set_xlabel('Klasni indeksi')
ax.set_ylabel('Vrednosti')
ax.set_title('Transformacija izlaznih vrednosti u verovatnoće pomoću softmax funkcije')
ax.set_xticks(index + bar_width / 2)
ax.set_xticklabels(['Klasa 1', 'Klasa 2', 'Klasa 3'])
ax.legend()

plt.tight_layout()
plt.show()

```

Algoritam 10: Python kod Softmax aktivacione funkcije u klasifikaciji EEG signala

- **Definisanje softmax funkcije:** *Softmax* funkcija računa eksponencijal svake vrednosti u ulaznom vektoru, oduzima maksimalnu vrednost radi numeričke stabilnosti, a zatim normalizuje tako da zbir izlaznih vrednosti bude 1.
- **Primer ulaznog vektora:** Primer ulaznog vektora X sadrži tri vrednosti koje mogu predstavljati logite (neobrađene izlazne vrednosti) iz poslednjeg sloja neuronske mreže.
- **Kreiranje grafikona:** Grafikon prikazuje dve grupe histograma: jednu za originalne logite i drugu za transformisane vrednosti dobijene *Softmax* funkcijom. Na taj način se jasno vidi kako se ulazne vrednosti transformišu u verovatnoće.

Prethodno prikazani grafikon omogućava vizuelno razumevanje procesa *Softmax* transformacije podataka u izlaznom sloju veštačkih neuronskih mreža, što je ključno za interpretaciju rezultata klasifikacije. Efikasno predstavljanje verovatnoća olakšava donošenje odluka u aplikacijama kao što je dijagnostika epilepsije, gde je preciznost ključna ali isto tako razumljivost i interpretabilnost same odluke sistema veštačke inteligencije.

Izlazni sloj veštačkih neuronskih mreža igra presudnu ulogu u procesu donošenja odluka, posebno u klasifikacionim zadacima u medicinskoj neurodijagnostici. Korišćenjem *Softmax* aktivacione funkcije, veštačka neuronska mreža transformiše ulazne vrednosti u interpretabilne verovatnoće, omogućavajući preciznu klasifikaciju EEG signala na osnovu naučenih obrazaca.

Ovaj pristup, zajedno sa unapređenom arhitekturom skrivenih slojeva i efikasnim metodama optimizacije, predstavlja temelj za razvoj naprednih matematičkih modela veštačkih neuronskih mreža koji mogu značajno unaprediti dijagnostiku neuroloških poremećaja. Kroz integraciju ovih tehnologija, moguće je postići visoku tačnost i pouzdanost, što direktno utiče na pravovremenu intervenciju i poboljšanje zdravstvenih ishoda kod pacijenata.

2.2.10. Evaluacija i performanse veštačke neuronske mreže u neurodijagnostici EEG signala

Da bi se osigurala efikasnost veštačkih neuronskih mreža u neurodijagnostici u analizi i tumačenju EEG signala, nakon završene obuke matematičkog modela veštačke neuronske mreže sprovodi se evaluacija performansi pomoću standardnih metrika, kao što su tačnost, preciznost, osetljivost (senzitivnost) i specifičnost.

- **Tačnost (*Accuracy*):** Izračunava se kao odnos tačno klasifikovanih primera (TP + TN) i ukupnog broja primera.
- **Preciznost (*Precision*):** Izračunava se kao odnos ispravno predviđenih pozitivnih primera (TP) prema ukupnom broju primera predviđenih kao pozitivni (TP + FP).
- **Osetljivost (*Sensitivity/Recall*):** Izračunava se kao odnos ispravno prepoznatih pozitivnih primera (TP) i ukupnog broja stvarnih pozitivnih primera (TP + FN).
- **Specifičnost (*Specificity*):** Izračunava se kao odnos ispravno prepoznatih negativnih primera (TN) i ukupnog broja stvarnih negativnih primera (TN + FP).

Ove metrike služe za kvantifikovanje uspešnosti matematičkog modela veštačkih neuronskih mreža u prepoznavanju obrazaca i, naročito u kontekstu EEG signala, mogu značiti razliku između tačne dijagnoze neuroloških poremećaja i pogrešnih ili nepotpunih medicinskih odluka. Visoka tačnost klasifikacije u EEG analizi direktno doprinosi pouzdanoj dijagnostici, dok smanjenje broja lažnih pozitivnih i lažnih negativnih odluka omogućava sigurnije donošenje medicinskih odluka.

Evaluacija matematičkih modela veštačkih neuronskih mreža obično uključuje podelu podataka na trening, validacioni i test skup. Test skup omogućava nezavisnu procenu performansi matematičkog modela, a korišćenjem metrika kao što su F1-vrednost, preciznost i osetljivost, istraživači mogu objektivno da uporede različite matematičke modele i pristupe. Pored toga, važan je i aspekt računске efikasnosti, odnosno brzine obrade i kompjuterskih resursa potrebnih za treniranje, što postaje ključno u realnim kliničkim uslovima gde su vremenski odziv i skalabilnost matematičkog modela od presudnog značaja.

Iako su u prethodnom periodu veštačke neuronske mreže pokazale izuzetne performanse u klasifikaciji EEG signala, izazovi u primeni ovih matematičkih modela i dalje ostaju. Jedan od glavnih izazova jeste obrada velikih količina podataka u realnom vremenu, što zahteva dalju optimizaciju matematičkog modela veštačkih neuronskih mreža kako bi se smanjili neophodni računarski resursi i ujedno povećala brzina obrade podataka. Budući pravci istraživanja usmereni su ka razvoju adaptivnih matematičkih modela koji mogu automatski da prilagode svoje parametre u skladu sa promenama u ulaznim EEG podacima. Ovakav pristup omogućava veštačkim neuronskim mrežama da se efikasnije nose sa varijabilnošću EEG signala, što je naročito važno u dinamičnim kliničkim okruženjima.

Pored toga, integracija Bayesovih metoda predstavlja još jedan pravac istraživanja, gde bi se uključivanjem Bayesovih pristupa za procenu nesigurnosti u matematičkim modelima veštačkih neuronskih mreža, bi se mogao postići veći nivo pouzdanosti predviđanja, što je opet pak presudno u uslovima visokog šuma i varijabilnosti podataka, što je očigledno slučaj sa EEG zapisima.

Primena hibridnih matematičkih modela koji kombinuju različite arhitekture, kao što su na primer veštačke konvolucione neuronske mreže (CNN) ili pak Transformere, u budućnosti će svakako omogućiti bolju ekstrakciju i obradu informacija iz EEG signala, te samim time pružiti dodatne mogućnosti za preciznu medicinsku neurodijagnostiku.

Još jedan izazov predstavlja povećanje interpretabilnosti matematičkog modela veštačkih neuronskih mreža. U medicinskoj dijagnostici, transparentnost odluka matematičkog

modela je od ključne važnosti, jer omogućava lekarima da razumeju osnovne principe na kojima se donose odluke o dijagnozi i tretmanu. Razvoj tehnika koje omogućavaju dublje razumevanje unutrašnjih procesa veštačkih neuronskih mreža, kao što su metode vizualizacije aktivacija i analiza važnosti ulaznih karakteristika, biće ključne za buduće primene ovih matematičkih modela u kliničkoj praksi.

Sveobuhvatna primena veštačkih neuronskih mreža u klasifikaciji EEG signala predstavlja značajan napredak u oblasti medicinske neurodijagnostike. Integracijom ulaznih, skrivenih i izlaznih slojeva, veštačke neuronske mreže omogućavaju automatsko učenje i generalizaciju složenih obrazaca, što rezultira visokim nivoom tačnosti i pouzdanošću predviđanja epileptičnih napada. Ovaj pristup ne samo da unapređuje proces dijagnostike epilepsije, već otvara nove mogućnosti za primenu multimodalnih veštačkih neuronskih mreža u analizi drugih biomedicinskih podataka, poput snimaka magnetene rezonance, snimaka PET skenera (*Positron Emission Tomography*, PET), kao i drugih signala.

Kao što je detaljno opisano u nastavku ove naučno-istraživačke studije, mnogobrojni primeri pokazuju da matematički modeli veštačkih neuronskih mreža upravo zasnovani na LSTM arhitekturama, specijalno trenirani za obradu vremenskih serija EEG signala, mogu postići znatno bolje performanse u poređenju sa tradicionalnim pristupima, upravo zbog njihove sposobnosti da uče dugoročne zavisnosti i prepoznaju suptilne promene u električnoj aktivnosti mozga pacijenata (Acharya, Oh, Hagiwara, Tan, & Ng, 2018).

Nastavak istraživanja u ovoj oblasti fokusiraće se na razvoj efikasnijih, adaptivnih i hibridnih modela koji će biti sposobni da se bolje prilagode promenljivim uslovima u realnom vremenu i potrebama kliničke prakse. Dalji rad na optimizaciji matematičkog modela i povećanju interpretabilnosti veštačkih neuronskih mreža omogućavaće implementaciju ovih sistema u kliničkim okruženjima, čime će se poboljšati zdravstveni ishodi pacijenata i unaprediti medicinska dijagnostika na globalnom nivou.

Iz perspektive integracije matematičkih osnova, razvoj veštačkih neuronskih mreža je rezultat sinergije linearne algebre, teorije verovatnoće i statistike, matematičke analize, informacione teorije i metoda optimizacije. Linearna algebra pruža strukturu za predstavljanje podataka, dok teorija verovatnoće omogućava kvantifikaciju nesigurnosti u podacima. Matematička analiza je osnova za izračunavanje gradijenata potrebnih za optimizaciju, a informaciona teorija pomaže u maksimiziranju prenosa informacija kroz veštačku neuronsku mrežu. Kombinacija ovih disciplina omogućava veštačkim neuronskim mrežama da automatski otkriju i ekstraktuju skrivene obrasce, što je ključno za preciznu klasifikaciju i predviđanje.

U svetlu prethodno navedenog, jasno je da dalje unapređenje matematičkih modela i integracija naprednih matematičkih metoda predstavlja temelj za buduće inovacije u oblasti veštačke inteligencije.

Razvoj adaptivnih modela, primena Bayesovih metoda i hibridnih arhitektura, kao i povećanje interpretabilnosti matematičkih modela veštačkih neuronskih mreža, biće ključni pravci istraživanja koji će omogućiti precizniju i bržu dijagnostiku u kritičnim aplikacijama, naročito u medicinskoj neurodijagnostici.

2.3. Specijalizovane arhitekture neuronskih mreža za obradu EEG signala: RNN i LSTM

Duboke veštačke neuronske mreže (*Deep Neural Network*, DNN) su vrsta veštačkih neuronskih mreža koje se odlikuju velikim brojem skrivenih slojeva. Tradicionalne veštačke neuronske mreže, s jednim ili dva skrivena sloja, često se nazivaju "plitkim" neuronskim mrežama, dok duboke neuronske mreže sa druge strane, mogu imati desetine pa čak i stotine skrivenih slojeva neurona u okviru same veštačke neuronske mreže.

Glavna razlika između dubokih i plitkih veštačkih neuronskih mreža leži u njihovoj sposobnosti učenja složenih, hijerarhijskih obrazaca koji se nalaze u ulaznim podacima. Svaki sloj u veštačkoj neuronskoj mreži uči da prepozna određene karakteristike (atribute) ulaznih podataka, u slučaju ovog naučno-istraživačkog rada ulazni podaci su EEG signali.

U plitkim veštačkim neuronskim mrežama, skriveni slojevi moraju naučiti sve karakteristike odjednom u jednom prolazu, što može biti izuzetno teško za složene podatke koji pri tome u najvećem broju slučajeva imaju nelinearnu prirodu i veoma kompleksne distribucije. Sa druge strane, duboke neuronske mreže uče karakteristike podataka postupno, sloj po sloj. Prvi slojevi uče jednostavne karakteristike, kao što su na primer u domenu prepoznavanja objekata ivice ili boje objekata na slici, dok kasniji slojevi uče složenije karakteristike, kao što su sami oblici ili objekti.

Ova hijerarhijska struktura omogućuje da duboke neuronske mreže uče vrlo složene obrasce gradeći složene koncepte identifikacijom, pamćenjem i usvajanjem jednostavnijih konceptata kroz sve skrivene slojeve duboke neuronske mreže. Praktično ovaj koncept učenja omogućava dubokim neuronskim mrežama da rešavaju zadatke iz domena kao što su prepoznavanje slika (*Computer Vision*, CV), prepoznavanje govora (*Natural Language Processing*, NLP) i obrada/razumevanje prirodnog jezika (*Natural Language Understanding*, NLU).

Duboke neuronske mreže nude načelno nekoliko bitnih prednosti u odnosu na plitke neuronske mreže:

- **Sposobnost učenja složenih obrazaca:** Kao što je prethodno naglašeno, duboke neuronske mreže mogu naučiti vrlo složene, hijerarhijske obrasce, što ih čini prikladnim za zadatke koji zahtevaju razumevanje složenih odnosa u ulaznim podacima, kao i podacima koji se prenose kroz slojeve duboke neuronske mreže.
- **Automatsko učenje karakteristika/atributa:** Duboke neuronske mreže mogu automatski učiti relevantne karakteristike/atribute iz sirovih ulaznih podataka, što eliminiše potrebu za manuelnim podešavanjem i prilagođavanjem karakteristika ulaznih podataka.
- **Smanjena potreba za velikim skupom podataka:** U nekim slučajevima, duboke neuronske mreže mogu postići izuzetno dobre rezultate sa manjim skupovima podataka nego plitke neuronske mreže, pre svega jer duboke neuronske mreže mogu generalizovati naučene obrasce na nove, nikad pre predstavljene podatke.

U nastavku ovog naučno-istraživačkog rada se navode samo neki od izazova sa kojima se susreće proces implementacije (obuke) i korišćenja dubokih neuronskih mreža:

- **Zahtevni za obuku:** Obuka dubokih neuronskih mreža može biti izuzetno teška i zahtevati velike skupove podataka kao i adekvatne kompjuterske resurse za skladištenje, transport i procesiranje velikih količina podataka.
- **Problem nestajanja gradijenata:** U nastavku biće opisan jedan od najvećih problema dubokih mreža koje mogu patiti od problema nestajanja gradijenata, a što otežava učenje u ranijim skrivenim slojevima duboke neuronske mreže.
- **Sklonost pretreniranju:** Duboke neuronske mreže su takođe sklone pretreniranju, što znači da mogu naučiti previše specifične detalje trening podataka, te time umanjiti sposobnost generalizacije i loše se ponašati na novim podacima.

Dok su višeslojne perceptronske (MLP) veštačke neuronske mreže efikasne u obradi statičnih podataka, sa druge strane podaci koji su kvalifikovani kao vremenske serije, a tu pre svega se misli na podatke koji se dobijaju iz EEG signala, zahtevaju matematičke modele koji moraju uzeti u obzir vremensku dimenziju podataka i modelirati zavisnosti između uzastopnih tačaka.

Rekurentne neuronske mreže su dizajnirane da se nose sa ovim izazovom, omogućavajući prenos informacija između vremenskih koraka (epoha), što omogućava rekurentnim neuronskim mrežama da "pamte" prethodne informacije. Važno je napomenuti da matematički modeli standardnih rekurentnih neuronskih mreža svakako pate od problema nestajućih gradijenata, što ograničava njihovu sposobnost da uče dugoročne zavisnosti (Pascanu, Mikolov, & Bengio, 2013).

Nestajanje gradijenata je problem koji se javlja kod treniranja dubokih neuronskih mreža, posebno rekurentnih neuronskih mreža. Rekurentne neuronske mreže su vrsta veštačkih neuronskih mreža koje su posebno dizajnirane za rad sa sekvencijalnim podacima, kao što su vremenske serije. Njihova ključna karakteristika je povratna veza koja omogućava da se informacije iz prethodnih vremenskih koraka prenesu u trenutni korak. To znači da rekurentna neuronska mreža "pamti" prethodne informacije, skrivena stanja veštačkih neurona, i koristi ih za obradu trenutnih podataka.

U tom smislu, u svakom vremenskom koraku t , rekurentna neuronska mreža prima ulaz x_t i prethodno skriveno stanje h_{t-1} , te generiše izlaz y_t i novo skriveno stanje h_t . Skriveno stanje h_t predstavlja sažetak informacija o prethodnim ulazima podataka koji se koriste za treniranje i dato skriveno stanje h_t koristi se za predviđanje budućih vrednosti. Matematički se ovo može izraziti putem sledeće jednačine:

$$h_t = \sigma(W_{xh} \cdot x_t + W_{hh} \cdot h_{t-1} + b_h) \quad (20)$$

gde su:

- W_{xh} - matrica težinskih faktora između ulaza i skrivenog stanja
- W_{hh} - matrica težinskih faktora između prethodnog i trenutnog skrivenog stanja
- b_h - vektor pristrasnosti (*bias vector*)
- σ - aktivaciona funkcija (npr. *Tanh*)

Iako su rekurentne neuronske mreže napravile svojevrsnu revoluciju u oblasti analize vremenskih serija, suočavaju se s problemima kao što su nestajanje gradijenata (*Vanishing Gradient*) i nestabilnost tokom treniranja. Nestajanje gradijenata otežava učenje dugoročnih vremenskih zavisnosti, jer gradijenti eksponencijalno opadaju tokom procesa obuke i ulančavanja težinskih parametara putem procesa propagacije unazad (*backpropagation*) kroz rekurentnu neuronsku mrežu. Nestabilnost tokom treniranja se na taj način manifestuje kao osetljivost na inicijalizaciju težinskih faktora i brzinu učenja (Pascanu, Mikolov, & Bengio, 2013).

Tokom procesa treniranja rekurentne neuronske mreže, gradijenti se koriste za ažuriranje parametara težina rekurentne neuronske mreže. Gradijenti se izračunavaju unazad kroz veštačku neuronsku mrežu (*backpropagation*), počevši od izlaznog sloja prema ulaznom sloju. Ova metoda koristi lančano pravilo iz diferencijalnog računa, koje omogućava parcijalni izvod složenih funkcija. U tom smislu kod veštačkih neuronskih mreža, lančano pravilo se primenjuje na parcijalni izvod funkcije greške, gde se po težinskom parametru računa se množenjem parcijalnih izvoda svake međufunkcije u grafu (neron + sinapsa) računanjem unazad, na primer: ako je $y = f(g(h(x)))$, tada je $\frac{dy}{df} = \frac{dy}{df} \cdot \frac{df}{dg} \cdot \frac{dg}{dh} \cdot \frac{dh}{dx}$.

Problem nestajućih gradijenata nastaje kada se tokom ovog procesa gradijenti eksponencijalno smanjuju kako se propagiraju unazad kroz skrivene slojeve rekurentne neuronske mreže, a ovo su razlozi:

1. Ponovljeno množenje parcijalnih izvoda manjih od 1 (npr. kod sigmoidnih aktivacionih funkcija gde je $\sigma'(x) \leq 0.25$)
2. Dugotrajno "pamćenje" u dubokim neuronskim mrežama postaje nemoguće jer se parametri težine ranijih skrivenih slojeva (*hidden layers*) ne ažuriraju adekvatno.


Posledica eksponencijalnog smanjivanja gradijenata je da raniji skriveni slojevi veštačke neuronske mreže prestaju da uče, što otežava matematičko modelovanje dugoročnih zavisnosti u podacima, konkretno opisan je primer smavanzivanja gradijenata u rekurentnim neuronskim mrežama za vremenske serije.

Kao primer kako dolazi do nestajanja gradijenata, posmatrajmo jednu jednostavnu veštačku neuronsku mrežu sa jednim skrivenim slojem i jednim izlaznim slojem. Neka je aktivaciona funkcija u skrivenom sloju sigmoidna funkcija, čij parcijalni izvod je manji od 1.

Tokom propagacije unazad, gradijent za parametar težine u ulaznom sloju se izračunava tako što se pomnože parcijalni izvod aktivacionih funkcija u svim skrivenim slojevima između ulaznog sloja i izlaznog sloja.

Ako je aktivaciona funkcija sigmoidna, njen parcijalni izvod je uvek manji od 1, što praktično znači da se gradijent smanjuje množenjem sa vrednostima manjim od 1. Što je veštačka neuronska mreža dublja (više skrivenih slojeva), to se gradijent više puta množi sa vrednostima manjim od 1, što dovodi do njegovog eksponencijalnog smanjenja.

Kao dodatni primer može se posmatrati slučaju veštačke neuronske mreže sa 10 skrivenih slojeva, gde ako se parcijalni izvod aktivacione sigmoidne funkcije u svakom skrivenom sloju je 0.5, tada će se gradijent smanjiti 10 puta, što znači da će postati $0.5^{10} = 0.0009765625$.



Slika 14: Poređenje RNN i LSTM predikcije

Izvorni Python kod za "Slika 14. Poređenje RNN i LSTM predikcije (adaptirano prema eksperimentalnoj simulaciji, Radomirović, 2025)."

```
import numpy as np
import matplotlib.pyplot as plt
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import SimpleRNN, LSTM, Dense

# Stvaranje sintetičkih podataka
timesteps = 100
data_points = np.sin(0.1 * np.arange(timesteps)) + np.random.normal(0, 0.1, timesteps)

# Reshapovanje podataka za RNN/LSTM (samples, timesteps, features)
data = data_points.reshape((1, timesteps, 1)) # Oblici: (1, 100, 1)

# RNN Model
rnn_model = Sequential([
    SimpleRNN(32, return_sequences=True, input_shape=(timesteps, 1)), # Dodato
    return_sequences=True
    Dense(1)
])

# LSTM Model
lstm_model = Sequential([
```

```

    LSTM(32, return_sequences=True, input_shape=(timesteps, 1)), # Dodato
return_sequences=True
    Dense(1)
])

# Kompilacija
rnn_model.compile(optimizer='adam', loss='mse')
lstm_model.compile(optimizer='adam', loss='mse')

# Obuka modela (koristimo iste podatke za ulaz i izlaz kao autoencoder)
rnn_model.fit(data, data, epochs=100, verbose=0)
lstm_model.fit(data, data, epochs=100, verbose=0)

# Predviđanje
rnn_predictions = rnn_model.predict(data)
lstm_predictions = lstm_model.predict(data)

# Grafički prikaz
plt.figure(figsize=(12, 6))
plt.plot(data_points, label='Originalni podaci', linestyle='--')
plt.plot(rnn_predictions[0, :, 0], label='RNN Predikcije')
plt.plot(lstm_predictions[0, :, 0], label='LSTM Predikcije')
plt.title('Poređenje RNN i LSTM predikcija')
plt.legend()
plt.show()

```

Algoritam 11: Poređenje RNN i LSTM predikcija

Kao što se vidi iz gore navedenog primera, gradijent je postao vrlo mali, što otežava učenje u ranijim skrivenim slojevima veštačke neuronske mreže. Postoji nekoliko metoda za rešavanje problema nestajanja gradijenata i u nastavku ovog naučno-istraživačkog rada je prikazano nekoliko primera:

- **LSTM i GRU mreže:** LSTM (*Long Short-Term Memory*) i GRU (*Gated Recurrent Unit*) veštačke neuronske mreže koriste mehanizme kapija koje omogućuju da se gradijenti "održavaju" tokom dužih vremenskih perioda.
- **Druge aktivacione funkcije:** Korišćenje aktivacionih funkcija kao što je *ReLU* (*Rectified Linear Unit*) može pomoći u ublažavanju problema nestajanja gradijenata.
- **Normalizacija gradijenata:** Normalizacija gradijenata (*Gradient Clipping*) ograničava veličinu gradijenata, što sprečava njihovo prekomerno smanjenje.
- **Preskakanje veza:** Preskakanje veza omogućuje da gradijenti "preskoče" nekoliko slojeva, što olakšava učenje dugoročnih zavisnosti.

Kao što je već rečeno, da bi se prevazišao gore opisani problem učenja u rekurentnim neuronskim mrežama i rešio problem nestajanje gradijenta, razvijeni su novi modeli veštačkih neuronskih mreža, LSTM (*Long Short-Term Memory*) (Hochreiter & Schmidhuber, 1997).

LSTM modeli veštačkih neuronskih mreža koriste mehanizme kapija, zaboravljajuću, ulaznu i izlaznu kapiju, te selektivno upravljaju protokom informacija kroz LSTM veštačku neuronsku mrežu.


Ključne komponente LSTM veštačke neuronske mreže su:

- **Ćelija (Cell):** LSTM veštačka neuronska mreža sadrži ćeliju koja služi kao "memorija" LSTM veštačke neuronske mreže. Ćelija sadrži stanje memorije C_t koje se ažurira u svakom vremenskom koraku.
- **Kapije (Gates):** LSTM veštačka neuronska mreža ima tri vrste kapija koje kontrolišu protok informacija u ćeliju i iz nje:
 - **Zaboravljajuća kapija (Forget Gate):** Odlučuje koje informacije iz prethodnog stanja memorije C_{t-1} treba zaboraviti.
 - **Ulazna kapija (Input Gate):** Odlučuje koje nove informacije treba dodati u stanje memorije/ćelije LSTM veštačke neuronske mreže.
 - **Izlazna kapija (Output Gate):** Odlučuje koje informacije iz stanja memorije treba proslediti kao izlaz u sledeću ćeliju LSTM veštačke neuronske mreže.

U nastavku teksta je prikazan primer kako funkcioniše LSTM veštačka neuronska mreža i primena LSTM veštačkih neuronskih mreža na analizu EEG signala.

- **Zaboravljajuća kapija (Forget Gate):** Zaboravljajuća kapija prima kao ulaz prethodno skriveno stanje h_{t-1} i trenutni ulaz x_t , te pomoću sigmoidne funkcije σ generiše vektor vrednosti između 0 i 1. Vrednosti koje su bliže 0 označavaju da treba zaboraviti odgovarajuće informacije iz prethodnog stanja memorije, dok vrednosti koje su bliže 1 označavaju da treba zadržati date informacije.
- **Ulazna kapija (Input Gate):** Ulazna kapija takođe prima kao ulaz prethodno skriveno stanje h_{t-1} i trenutni ulaz x_t , te pomoću sigmoidne funkcije σ generiše vektor vrednosti između 0 i 1. Ovaj vektor se koristi za kontrolu koje nove informacije će biti dodate u stanje memorije LSTM veštačke neuronske mreže, gde ulazna kapija generiše i kandidat vektora novih vrednosti pomoću aktivacione funkcije $Tanh$.
- **Ažuriranje stanja memorije (Update Cell Memory):** Stanje memorije c_t se ažurira kombinacijom prethodnog stanja memorije c_{t-1} i novih informacija. Zaboravljajuća kapija određuje koje informacije iz prethodnog stanja memorije treba zadržati, dok ulazna kapija određuje koje nove informacije treba dodati.
- **Izlazna kapija (Output Gate):** Izlazna kapija prima kao ulaz prethodno skriveno stanje h_{t-1} i trenutni ulaz x_t , te pomoću sigmoidne aktivacione funkcije σ generiše vektor vrednosti između 0 i 1. Ovaj vektor se koristi za kontrolu koje informacije iz stanja memorije će biti prosledene kao izlaz. Izlazno skriveno stanje h_t se generiše tako što se pomnoži izlazna kapija sa vrednostima aktivacione funkcije $Tanh$ primenjenom na stanje memorije c_t .

Grafički prikaz LSTM neuronske ćelije sa svim elementima, Ulazna kapija Zaboravljajuća kapija, Izlazna kapija, kao i opisanim procesom Ažuriranje stanja memorije.



Slika 15: LSTM ćelija sa ažuriranjem stanja memorije

U nastavku teksta je prikazan detaljni opis matematičkih formula pripadajućih elemenata LSTM veštačke neuronske mreže:

- **Zaboravljajuća kapija:** $f_t = \sigma(W_{-f} \cdot [h_{t-1}, x_t] + b_{-f})$
- **Ulazna kapija:** $i_t = \sigma(W_{-i} \cdot [h_{t-1}, x_t] + b_{-i})$
- **Kandidat vektor:** $\tilde{c}_i = \tanh(W_{-c} \cdot [h_{t-1}, x_t] + b_{-c})$
- **Ažuriranje stanja memorije:** $c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_i$
- **Izlazna kapija:** $o_t = \sigma(W_{-o} \cdot [h_{t-1}, x_t] + b_{-o})$
- **Izlazno skriveno stanje:** $h_t = o_t \odot \tanh(c_t)$

gde $\odot$ označava elementni proizvod, wise-element (*Hadamard product*), operaciju gde se odgovarajući elementi tenzora množe jedan s drugim, gde tenzor predstavlja višedimenzionalni niz brojeva.


Rezultat je tenzor istih dimenzija kao ulazni tenzor. U okviru LSTM ćelija veštačke neuronske mreže, $\odot$ elementni proizvod igra ključnu ulogu u upravljanju protokom informacija kroz kapije LSTM veštačke neuronske mreže.

Ova arhitektura omogućava LSTM veštačke neuronske mreže da selektivno zadrži ili odbaci informacije kroz vremenske korake, što ga čini idealnim za analizu vremenskih sekvenci EEG signala, gde se abnormalnosti često manifestuju kroz suptilne, vremenski rasprostranjene obrasce (Graves, 2013).

Neke od primena LSTM veštačkih neuronskih mreža na EEG signalima uključuju:

- **Detekcija epileptičkih napada:** LSTM veštačka neuronska mreža se može naučiti da prepozna karakteristične obrasce u EEG zapisima koji se javljaju pre ili tokom epileptičkih napada kod pacijenata.
- **Klasifikacija moždanih stanja:** LSTM veštačka neuronska mreža se može koristiti za klasifikaciju različitih stanja svesti, kao što su budnost, pospanost ili san.
- **Predviđanje kognitivnih stanja:** LSTM veštačka neuronska mreža se može koristiti za predviđanje kognitivnih stanja, kao što su pažnja ili mentalno opterećenje.
- **Segmentacija EEG signala:** Razdvajanje EEG signala u manje delove (npr. segmente od nekoliko sekundi, vremenske epohe), omogućava daleko bolje prepoznavanje vremenskih obrazaca.
- **Klasifikacija abnormalnosti:** Korišćenje LSTM veštačkih neuronskih mreža za mapiranje vremenskih sekvenci EEG signala na kategorije, kao što su "normalno", "iktalno" ili "interiktalno" stanje.

U nastavku ovog naučno-istraživačkog rada je prikazan primer Python koda koji koristi *TensorFlow* i *Keras* biblioteke za implementaciju LSTM veštačke neuronske mreže koja analizira sintetički EEG signal, zajedno s vizualizacijom arhitekture LSTM veštačke neuronske mreže i primenom iste na EEG podacima



Slika 16: Primer LSTM modela u obradi EEG signala

Izvorni Python kod za "Slika 16. Primer LSTM modela u obradi EEG signala (adaptirano prema eksperimentalnoj simulaciji, Radomirović, 2025)."

```

import numpy as np
import matplotlib.pyplot as plt
from tensorflow import keras
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense, Dropout
from tensorflow.keras.utils import plot_model

```

1. Priprema podataka

Pretpostavimo da imamo EEG podatke u obliku numpy niza (n_samples, n_timesteps, n_channels)

```

# n_samples - broj uzoraka
# n_timesteps - broj vremenskih koraka u svakom uzorku
# n_channels - broj EEG kanala

# Primer:
n_samples = 100
n_timesteps = 50
n_channels = 10
eeg_data = np.random.rand(n_samples, n_timesteps, n_channels)
eeg_labels = np.random.randint(0, 2, n_samples) # 0 - normalno, 1 - abnormalno

# 2. Izgradnja LSTM modela
model = Sequential()
model.add(LSTM(64, input_shape=(n_timesteps, n_channels), return_sequences=True))
model.add(Dropout(0.2)) # Dodavanje Dropout sloja za sprečavanje pretreniranja
model.add(LSTM(32))
model.add(Dropout(0.2))
model.add(Dense(1, activation='sigmoid')) # Izlazni sloj s sigmoidnom funkcijom za
binarnu klasifikaciju

# 3. Vizualizacija arhitekture modela
plot_model(model, to_file='lstm_architecture.png', show_shapes=True,
show_dtype=True)

# 4. Kompilacija modela
model.compile(optimizer='adam', loss='binary_crossentropy', metrics=['accuracy'])

# 5. Obuka modela
model.fit(eeg_data, eeg_labels, epochs=10, batch_size=32)

# 6. Evaluacija modela
loss, accuracy = model.evaluate(eeg_data, eeg_labels)
print('Loss:', loss)
print('Accuracy:', accuracy)

# 7. Predviđanje
predictions = model.predict(eeg_data)

```

Algoritam 12: Python kod primene LSTM modela u obradi EEG signala

Matematički modeli LSTM veštačkih neuronskih mreža predstavljaju značajan napredak u oblasti analize vremenskih serija, posebno u kontekstu EEG podataka, gde je potrebna sposobnost prepoznavanja dugoročnih vremenskih zavisnosti.

Ova tehnologija omogućava precizniju i stabilniju analizu složenih bioloških signala, čineći je pogodnom za primenu u medicinskoj neurodijagnostici, kao i u mnogim drugim industrijama koje se oslanjaju na analizu vremensko sekvenciranih podataka.

2.4. Pravci daljeg razvoja LSTM veštačkih neuronskih mreža

Kao što je opisano u prethodnim poglavljima, rekurentne neuronske mreže ostvarile su značajne rezultate u obradi sekvencijalnih i nelinearnih podataka, ali se i dalje javljaju brojni izazovi, naročito vezani za problem nestajućih i eksplodirajućih gradijenata (Pascanu, Mikolov, & Bengio, 2013). Ovi problemi otežavaju učenje dugoročnih zavisnosti u podacima, što je od presudnog značaja za primene kao što su obrada prirodnog jezika, prepoznavanje govora i analiza vremenskih serija. Uzimajući u obzir složenost EEG signala, gde se često javljaju suptilne promene u električnoj aktivnosti mozga pacijenta, primena matematičkih modela LSTM veštačkih neuronskih mreža postaje ključna jer one zahvaljujući svom sistemu kapija i mehanizmom ažuriranja stanja LSTM ćelije, ublažavaju ove probleme i omogućavaju efikasno učenje dugoročnih zavisnosti.

Istraživanja u oblasti rekurentnih neuronskih mreža, uključujući matematičke modele LSTM veštačkih neuronskih mreža, usmerena su na razvoj novih arhitektura veštačkih neuronskih mreža koje mogu efikasnije i duže da zadrže relevantne informacije, odnosno prevaziđu izazove sa eksplodirajućim i nestajućim gradijentima.

Razvoj novih arhitektura veštačkih neuronskih mreža, a pre svega tehnika optimizacije, predstavlja jedan od glavnih pravaca daljeg razvoja modela LSTM veštačkih neuronskih mreža, a ključni aspekti tog budućeg razvoja uključuju sledeće aspekte poboljšanja:

- **Nove vrste regularizacije** - Regularizacija predstavlja tehniku koja se koristi za sprečavanje prekomernog prilagođavanja matematičkog modela trening podacima u okviru veštačke neuronske mreže (*overfitting*). U kontekstu matematičkih modela LSTM veštačkih neuronskih mreža, istražuju se specifične tehnike regularizacije prilagođene njihovoj arhitekturi, poput temporalne regularizacije ili regularizacije bazirane na kapijama čija uloga i funkcionisanje u okviru matematičkog modela LSTM veštačke neuronske mreže je opisana u prethodnom poglavlju ([2.3. Specijalizovane arhitekture za obradu EEG signala: RNN i LSTM](#)). Ove tehnike mogu pomoći u smanjenju pretreniranosti, čime se poboljšava sposobnost matematičkog modela LSTM veštačke neuronske mreže da generalizuje na nove, neviđene podatke. Kao primer se navodi primena *Dropout* regularizacije unutar LSTM ćelija koja može značajno poboljšati robusnost matematičkog modela LSTM veštačke neuronske mreže (Srivastava et al., 2014).
- **Mehanizmi za stabilizaciju treniranja** - Novi mehanizmi za stabilizaciju treniranja matematičkog modela LSTM veštačke neuronske mreže uključuju tehnike normalizacije, kao što je *Layer Normalization*, koja prilagođava vrednosti aktivacija unutar skrivenih slojeva LSTM veštačke neuronske mreže kako bi se smanjile oscilacije tokom obuke veštačke neuronske mreže. Osim toga, modifikacije arhitekture, poput *Highway Networks* (Srivastava, Greff, & Schmidhuber, 2015) ili *Grid LSTM*

(Kalchbrenner et al., 2015), omogućavaju bolju propagaciju informacija kroz LSTM veštačke neuronske mreže, čime se poboljšava stabilnost i brzina konvergencije matematičkog modela LSTM veštačke neuronske mreže.

- **Arhitekture bazirane na Transformerima** - Transformeri, prvobitno razvijeni za obradu prirodnog jezika (Vaswani et al., 2017), pokazali su se izuzetno efikasnim u modeliranju dugoročnih zavisnosti kroz mehanizme pažnje (*attention mechanisms*). Za razliku od tradicionalnih RNN/LSTM modela veštačkih neuronskih mreža, koji teško pamte kontekst izvan prozora od nekoliko koraka, Transformeri direktno povezuju bilo koja dva elementa u sekvenci. Adaptacija ovih matematičkih modela za sekvencijalne podatke, uključujući naravno i EEG signale, predstavlja značajan pravac istraživanja. Integracija Transformera sa matematičkim modelima LSTM veštačkih neuronskih mreža može dodatno poboljšati performanse kombinovanjem prednosti oba pristupa, LSTM veštačke neuronske mreže u modeliranju vremenskih zavisnosti i Transformera u selektivnom fokusiranju na relevantne delove ulaza.
- **Mehanizmi pažnje (*attention mechanisms*)** - Mehanizmi pažnje omogućavaju veštačkoj neuronskoj mreži da selektivno "fokusira" svoje resurse na delove ulaznih podataka koji su najrelevantniji za zadatak. U okviru matematičkog modela LSTM veštačkih neuronskih mreža, integracija mehanizama pažnje (kao što su *self-attention* i *hierarchical attention*) može znatno poboljšati performanse, naročito u slučaju dugih sekvenci. Ovaj pristup omogućav matematičkom modelu LSTM veštačke neuronske mreže da se bolje nosi sa informacijama koje se protežu kroz vreme, te na taj način da identifikuje ključne segmente podataka koji su presudni za tačno predviđanje (Bahdanau, Cho, & Bengio, 2015).
- **Hibridni modeli** - Hibridni pristupi kombinuju LSTM veštačke neuronske mreže sa drugim arhitekturama, najčešće konvolucionim neuronskim mrežama. Kao što je poznato konvolucione neuronske mreže imaju sposobnost da izvlače prostorne karakteristike, dok LSTM veštačke neuronske mreže efikasno modeliraju vremenske zavisnosti. Ova kombinacija omogućava bolju ekstrakciju i obradu podataka koji imaju i prostornu i vremensku dimenziju, što je od velike važnosti u analizama poput onih sa multikanalnim EEG signalima ili video podacima (Bashivan et al., 2015).
- **Automatsko podešavanje hiperparametara LSTM veštačke neuronske mreže** - Podešavanje hiperparametara LSTM veštačke neuronske mreže, kao što su broj slojeva, veličina skrivenog stanja, stopa učenja, itd., predstavlja značajan izazov. Ručno podešavanje je vremenski zahtevno i često neefikasno, pa se koriste automatske metode optimizacije, uključujući metaheurističke algoritme poput genetskih algoritama, *Bayesian Optimization* i *Random Search*. Ovi algoritmi omogućavaju sistematsku pretragu prostora hiperparametara, pronalazeći optimalne vrednosti koje vode ka boljim performansama matematičkog modela (Bergstra & Bengio, 2012).
- **Razvoj "lightweight" matematičkih modela** - Za primene u realnom vremenu i na uređajima sa ograničenim resursima (kao što su IoT i EDGE uređaji), razvoj "lightweight" matematičkih modela LSTM veštačkih neuronskih mreža je od velike važnosti. Ovi matematički modeli se karakterišu manjim brojem parametara, smanjenom zahtevnošću za kompjuterskim resursima poput skladištenja i procesiranja

podataka, kao i bržom obukom, što ih čini pogodnim za implementaciju u kliničkim uslovima. Tehnike kao što su kvantizacija parametara težina i *pruning* (uklanjanje manje značajnih veza) omogućavaju postizanje ovih ciljeva (Han, Mao, & Dally, 2016).

- **Povećanje interpretabilnosti** - U medicinskim aplikacijama, posebno u medicinskoj neurodijagnostici, interpretabilnost matematičkog modela je ključna kako bi se osigurala transparentnost i poverenje u donošene neurodijagnostičke odluke. Razvijaju se tehnike koje omogućavaju vizualizaciju unutrašnjih procesa LSTM veštačkih neuronskih mreža, kao što su analiza aktivacija kapija i vizualizacija mehanizama pažnje. Ove tehnike omogućavaju istraživačima i kliničarima da bolje razumeju kako matematički model LSTM veštačke neuronske mreže dolazi do određenih odluka, čime se olakšava validacija i eventualno prilagođavanje modela LSTM veštačke neuronske mreže za specifične primene (Lundberg & Lee, 2017).
- **Etički i regulatorni okvir** - Razvoj i primena LSTM veštačkih neuronskih mreža, kao i drugih veštačkih neuronskih mreža, mora biti usklađen sa etičkim smernicama i regulatornim okvirima, posebno u medicinskoj dijagnostici. Na globalnom nivou, Evropska komisija je postavila etičke smernice za pouzdanu upotrebu AI (European Commission, 2019), dok se u Srbiji aktivno radi na usklađivanju nacionalnih standarda sa evropskim regulativama (Vuković, Petrović, & Jovanović, 2019). Ovi okviri obezbeđuju da se razvoj i implementacija matematičkih modela veštačkih neuronskih mreža sprovodi na siguran, transparentan i etički prihvatljiv način, uz zaštitu privatnosti pacijenata.

Budući razvoj LSTM veštačkih neuronskih mreža usmeren je ka rešavanju trenutnih izazova u modeliranju dugoročnih zavisnosti i naravno optimizaciji hiperparametara. Napredne tehnike, pre svega one kojse se odnose na nove metode regularizacije, mehanizmi pažnje, hibridni modeli i automatsko podešavanje hiperparametara, predstavljaju ključne pravce za unapređenje performansi matematičkog modela LSTM veštačkih neuronskih mreža.

Razvoj "*lightweight*" matematičkih modela omogućava primenu ovih tehnologija u realnom vremenu, što je posebno važno za kritične aplikacije u medicinskoj dijagnostici, kao što je detekcija epileptičkih napada kod pacijenata. Povećanje interpretabilnosti matematičkog modela LSTM veštačkih neuronskih mreža dodatno doprinosi transparentnosti i pouzdanosti, omogućavajući kliničarima da donesu informisane odluke.

Integracija ovih pravaca istraživanja sa postojećim matematičkim i tehničkim osnovama veštačkih neuronskih mreža pruža temelj za dalji razvoj inovativnih rešenja u medicinskoj neurodijagnostici. Ovaj interdisciplinarni pristup, koji kombinuje napredne algoritme, matematičke principe i etičke/regulatorne smernice, ima potencijal da transformiše medicinsku dijagnostiku i unapredi kvalitet života pacijenata na globalnom nivou.

2.5. EEG tehnika i njen značaj u neurološkoj dijagnostici

EEG (elektroencefalografija) predstavlja jednu od najvažnijih neinvazivnih dijagnostičkih metoda koja se koristi za snimanje električne aktivnosti mozga kod pacijenata. Kroz postavljanje elektroda na skalp pacijenta, snimanje EEG signala omogućava kontinuirano

praćenje i analizu moždanih talasa pacijenata u realnom vremenu, čime se pružaju ključne informacije o funkcionalnom stanju različitih regija mozga pacijenta (Niedermeyer & da Silva, 2005).

Ova tehnika beleži električne impulse koje generišu neuroni, a rezultujući EEG signal se prikazuje kao vremenska serija sa karakterističnim frekvencijama i amplitudama. Specifični obrasci aktivnosti, kao što su alfa, beta, theta i delta talasi, mogu ukazivati na normalno funkcionisanje mozga, ali istovremeno i na prisustvo patoloških stanja, što je od izuzetne važnosti u dijagnostici epilepsije, poremećaja spavanja, mentalnih poremećaja, kao i drugih neuroloških bolesti koje pak utiču na kognitivne funkcije pacijenata (Benbadis, Tatum, & Cascino, 2020; Saqlain & Saeed, 2024).

Tokom epileptičkih napada, EEG signal obično pokazuje nagle i izražene promene u električnoj aktivnosti, čime se omogućava precizna identifikacija i diferencijacija između iktalne (tok napada) i interiktalne (između napada) aktivnosti. Pored epilepsije kao primarnog aplikativnog domena u medicinskoj neurodijagnostici, analiza EEG zapisa se koristi ujedno i za praćenje i analizu faza spavanja, identifikaciju poremećaja spavanja kao što su apneja u snu i nesanica, te za procenu mentalnih poremećaja poput depresije, anksioznosti i šizofrenije kod pacijenata (Niedermeyer & da Silva, 2005; Casson, Yates, & Rodrigues, 2010). Pouzdanost očitavanja EEG signala i njegova pravilna interpretacija od presudnog su značaja za postizanje tačnih i pravovremenih dijagnoza. Ta pouzdanost zavisi od nekoliko ključnih faktora:

- **Pozicija elektroda:** Precizno postavljanje elektroda prema standardizovanom 10-20 sistemu omogućava da se EEG signal iz različitih regija mozga pacijenta pravilno zabeleži (Niedermeyer & da Silva, 2005). Neispravno postavljene elektrode mogu dovesti do distorzije EEG zapisa, kao i gubitka važnih informacija, što otežava preciznu lokalizaciju moždanih aktivnosti.
- **Varijabilnost među kliničarima:** Interpretacija EEG signala često zavisi od stručnosti i iskustva neuroloških stručnjaka, kliničara. Različiti analitičari mogu tumačiti iste podatke na različite načine, što može dovesti do varijacija u rezultatima i, posledično, do potencijalno pogrešnih dijagnoza (Benarous et al., 2019).
- **Šum u podacima:** EEG signali su vrlo osetljivi na elektromagnetske interferencije, pa čak i na pokrete pacijenata i fiziološke artefakte (Casson, Yates, & Rodrigues, 2010; Casson, 2019). Ovi šumovi mogu maskirati stvarne signalne obrasce, otežavajući detekciju patoloških obrazaca i smanjujući preciznost medicinske neurodijagnostike.

U okviru prethodnih poglavlja ovog naučno-istraživačkog rada detaljno su razmatrane matematičke i metodološke osnove veštačkih neuronskih mreža, kao i primena naprednih matematičkih modela poput rekurentnih neuronskih mreža i LSTM veštačkih neuronskih mreža za analizu vremenskih serija, uključujući podatke iz EEG signala. Kao nastavak tih tema, EEG tehnika se ovde povezuje sa primenom tehnologija veštačke inteligencije koje mogu značajno unaprediti tačnost i efikasnost dijagnostike. Primena matematičkih modela dubokog učenja omogućava automatsko filtriranje šuma i ekstrakciju relevantnih obrazaca, čime se smanjuje subjektivnost u interpretaciji podataka i povećava pouzdanost rezultata (Goodfellow, Bengio, & Courville, 2016; Sak, Senior, & Beaufays, 2014). Integracija EEG tehnike sa naprednim metodama veštačke inteligencije omogućava kreiranje sistema koji ne samo da automatski

prepoznaju abnormalnosti, već i pružaju kvantitativne metrike koje se mogu koristiti za praćenje promena u moždanoj aktivnosti pacijenata tokom vremena. Takvi sistemi veštačke inteligencije doprinose bržoj i preciznijoj dijagnostici, što je od presudnog značaja za pravovremenu intervenciju i lečenje pacijenata sa neurološkim poremećajima.

Kao što je ranije naglašeno, pouzdanost očitavanja zavisi od pravilnog postavljanja elektroda, smanjenja šuma i standardizacije interpretacije, što su sve izazovi sa kojima se suočavaju klasične metode analize EEG signala (Benarous et al., 2019; Casson, Yates, & Rodrigues, 2010). Uzimajući u obzir sve prethodno navedene izazove u akviziciji i obradi podataka iz EEG signala, očigledno je da se sve veći fokus stavlja na primenu metoda zasnovanih na veštačkoj inteligenciji, koje mogu pre svega automatski prepoznati i klasifikovati kompleksne nelinearne obrasce u okviru EEG signala.

Algoritmi veštačke inteligencije, naročito matematički modeli dubokog učenja poput rekurentnih neuronskih mreža i matematičkih modela LSTM veštačkih neuronskih mreža, imaju sposobnost učenja i generalizacije velikih skupova podataka, čime se povećava tačnost i efikasnost analize, a istovremeno se smanjuje subjektivnost koja nastaje prilikom ručne interpretacije od strane kliničara (Goodfellow, Bengio, & Courville, 2016; Sak, Senior, & Beaufays, 2014). Naravno treba posebno napomenuti da bez obzira na dokazanu izuzetnu uspešnost korišćenja EEG tehnike u kliničkoj praksi, analiza EEG signala svakako predstavlja izazov zbog inherentne složenosti i varijabilnosti. EEG podaci su često podložni interferencijama i šumovima, koji mogu nastati usled pokreta pacijenta, elektromagnetskih smetnji iz okoline ili lošeg kontakta elektroda na skalpu pacijenta (Casson, 2019). Tradicionalna interpretacija EEG zapisa, koja se oslanja na ručnu analizu od strane iskusnih neuroloških stručnjaka, može biti dugotrajna i podložna subjektivnosti, što dodatno komplikuje preciznu dijagnostiku (Benarous et al., 2019).

Ono što se može očekivati da će se u bliskoj budućnosti fokus usmeriti na razvoj tehnika i sistema za automatsku analizu EEG signala, pre svega kroz integraciju matematičkih modela veštačkih neuronskih mreža sa metodama za obradu signala i optimizaciju hiperparametara. Ovo uključuje razvoj "*lightweight*" matematičkih modela prilagođenih za rad u realnom vremenu, što je posebno važno u kliničkim okruženjima gde su brzina i preciznost ključni za adekvatan tretman pacijenata (Vuković, Petrović, & Jovanović, 2019). Takođe za očekivati je se nastavi sa daljom integracijom hibridnih modela koji kombinuju prednosti rekurentnih neuronskih mreža, konvolutivnih neuronskih mreža i Transformera, čime se postiže još efikasnija ekstrakcija i interpretacija atributa iz EEG signala (LeCun, Bengio, & Hinton, 2015). Na osnovu svega do sada izloženog može se reći da postoji immanentna potreba za kontinuiranim naučnim radom na unapređenju metoda akvizicije i interpretacije EEG signala, naročito kroz primenu naprednih matematičkih modela koji mogu automatski filtrirati šum i ekstrahovati relevantne obrasce, a sve radi povećavanja pouzdanost očitavanja i omogućavanja pravovremenih dijagnoza. EEG tehnika ostaje temeljna metoda u neurološkoj dijagnostici, pružajući vitalne informacije o funkcionalnom stanju mozga pacijenata. Integracija EEG tehnike sa naprednim metodama veštačke inteligencije obećava dalji napredak u preciznosti i efikasnosti dijagnostičkih postupaka, što je od izuzetnog značaja za ranu detekciju i lečenje neuroloških poremećaja kod pacijenata. Napredak u oblasti veštačke inteligencije i mašinskog učenja podataka predstavljaju prekretnicu u analizi EEG signala i pripadajućih podataka. Tradicionalne metode, koje se oslanjaju na ručnu interpretaciju EEG zapisa, često nisu dovoljne

za obradu složenih i visokodimenzionalnih EEG signala, što može dovesti do pogrešnih dijagnoza (Benbadis et al., 2020). Korišćenjem tehnika veštačke inteligencije, posebno dubokog učenja, moguće je automatizovati proces prepoznavanja obrazaca u podacima, čime se značajno unapređuje preciznost i brzina dijagnoze kod pacijenata.

Modeli kao što su LSTM veštačke neuronske mreže omogućavaju detekciju suptilnih promena u EEG signalima, koje mogu biti indikator epileptičkih napada ili drugih neuroloških poremećaja kod pacijenata (Hochreiter & Schmidhuber, 1997). Kroz proces učenja, ove veštačke neuronske mreže automatski identifikuju relevantne karakteristike iz velikih skupova podataka, što omogućava bržu obradu EEG zapisa i efikasnije filtriranje šumova (Kaur, Kumari, & Gupta, 2021). Matematički modeli veštačkih neuronskih mreža ne samo da ubrzavaju analizu EEG podataka, već i značajno smanjuju broj lažno pozitivnih i lažno negativnih dijagnoza, što direktno utiče na kvalitet zdravstvene zaštite pacijenata (Saqlain & Saeed, 2024). Pored brzine i tačnosti, integracija tehnika veštačke inteligencije u analizi i obradi EEG signala omogućava primenu u realnom vremenu, što je od izuzetne važnosti u hitnim situacijama gde pravovremena dijagnoza može spasiti živote pacijenata. Ova automatska obrada podataka omogućava kontinuirani monitoring pacijenata, a u kombinaciji sa naprednim filterima i standardizovanim procedurama, doprinosi sveukupnoj pouzdanosti EEG očitavanja. Prethodna poglavlja su opisala osnovne principe EEG tehnike i njen značaj u neurološkoj dijagnostici, naglašavajući važnost preciznog snimanja električne aktivnosti mozga pacijenata i izazove u interpretaciji EEG signala.

U nastavku ovog naučno-istraživačkog rada će se kroz faktore koji utiču na pouzdanost EEG očitavanja i ulogu veštačke inteligencije u analizi EEG signala, dodatno objasniti kako se moderni pristupi mogu koristiti za poboljšanje kvaliteta dijagnostičkih rezultata i kliničke prakse u celini. Kombinacija visoko preciznog snimanja, pravilno postavljenih elektroda, naprednih tehnika filtriranja šuma i automatske analize pomoću veštačkih neuronskih mreža omogućava integrisani klinički sistem koji značajno povećava tačnost, brzinu i pouzdanost neurološke dijagnostike (Niedermeyer & da Silva, 2005; Casson et al., 2010; Goodfellow et al., 2016). Ova istraživanja nastoje da unaprede razumevanje i primenu veštačkih neuronskih mreža u medicinskoj dijagnostici, sa posebnim fokusom na detekciju abnormalnih obrazaca u EEG podacima. Implementacija ovih metoda ne samo da povećava tačnost i brzinu dijagnoza, već takođe omogućava razvoj naprednih sistema za praćenje pacijenata sa neurološkim poremećajima, kao što su epilepsija, koji se mogu koristiti u svakodnevnoj kliničkoj praksi. Ovo istraživanje ima potencijal da doprinese globalnom poboljšanju dijagnostičkih metodologija, pružanju boljih zdravstvenih usluga i omogućavanju kvalitetnijeg života pacijentima sa neurološkim poremećajima. U budućim poglavljima ovog naučno-istraživačkog rada, detaljno će biti obrađeni savremeni pristupi u obradi EEG signala korišćenjem rekurentnih neuronskih mreža, konvolucionih mreža i hibridnih modela. Poseban fokus biće stavljen na primenu LSTM veštačkih neuronskih mreža u kombinaciji sa naprednim algoritmima optimizacije, čime će se dodatno poboljšati tačnost i efikasnost detekcije abnormalnih obrazaca.

Ova naučno-istraživačka studija će svakako pomoći u razvoju novih matematičkih modela prilagođenih specifičnim izazovima u medicinskoj dijagnostici, a rezultati će biti testirani na relevantnim javnim skupovima EEG podataka.

3. Dosadašnja istraživanja i regulatorni okvir primene veštačke inteligencije u medicinskoj dijagnostici EEG signala

U okviru ovog poglavlja detaljno se razmatra metodologija istraživanja primenjena u ovom naučno-istraživačkom radu, uz poseban fokus na dosadašnja istraživanja i regulatorne okvire koji definišu primenu veštačke inteligencije u medicinskoj dijagnostici EEG signala. U nastavku ovog naučno-istraživačkog rada je detaljnije prikazano kako su prethodni naučni radovi oblikovali razumevanje i razvoj matematičkih modela za automatsku detekciju anomalija u EEG signalima, te koja su očekivanja razvoja regulatornih okvira, kako u Republici Srbiji tako i u regionu, u skladu sa sve bržim tehnološkim napretkom, posebno tehnologija veštačke inteligencije i mašinskog učenja podataka.

Posebno se razmatra primena matematičkih modela za klasifikaciju vremenskih serija, gde se u tom kontekstu posebno naglašava značaj matematičkih modela LSTM veštačkih neuronskih mreža, koji su poznati po svojoj sposobnosti da uče dugoročne zavisnosti u vremenski zavisnim podacima, što je pak ključno za analizu kompleksnih i dinamičnih EEG signala. Pored tehničkih aspekata, od suštinskog je značaja je razumevanje i primena regulatornih okvira u medicinskoj neurodijagnostici, posebno kada se koriste napredne tehnologije veštačke inteligencije.

U savremenom zdravstvenom sistemu, primena veštačke inteligencije kao primarne dijagnostičke tehnologije nosi sa sobom niz etičkih, pravnih i socijalnih pitanja koja moraju biti rešena kako bi se osigurala sigurnost pacijenata i posebno poverenje u nove tehnologije. Ovi regulatorni okviri, koji ne podrazumevaju samo pravno-regulativne norme, već uzimaju u obzir etičke i društvene smernice, predstavljaju temelj za razvoj, implementaciju i kontinuirani nadzor sistema veštačke inteligencije i mašinskog učenja podataka u oblasti medicinske dijagnostike.

Dosadašnja istraživanja u oblasti primene veštačkih neuronskih mreža, naročito rekurentnih neuronskih mreža i njihovih unapređenih varijanti modela LSTM veštačkih neuronskih mreža, doprinose razumevanju i rešavanju izazova u analizi vremenskih serija, uključujući EEG podatke.

U literaturi se ističe da varijacije u interpretaciji medicinskih podataka, usled prethodnog iskustva medicinskih stručnjaka, mogu dovesti do pogrešnih dijagnoza (Benbadis & Kaplan, 2019). Ova činjenica posebno naglašava potrebu za standardizovanim pristupima koji minimiziraju subjektivnost kliničara i omogućavaju doslednije dijagnostičke rezultate.

U okviru ovog odeljka se izlažu ključna dostignuća u primeni matematičkih modela veštačkih neuronskih mreža za analizu vremenskih serija, ističući izazove i ograničenja sa kojima se istraživači suočavaju, kao i relevantne zakone, regulative i protokole koji uređuju primenu veštačke inteligencije u medicinskoj dijagnostici na globalnom nivou, uz poseban osvrt na napredak u Republici Srbiji.

Pored tehničkih izazova, dosadašnja istraživanja se sve više usmeravaju i na regulatorni okvir primene veštačke inteligencije u medicinskoj neurodijagnostici. Na globalnom nivou, relevantni zakoni, regulative i protokoli, kao što su etičke smernice Evropske komisije za pouzdanu upotrebu veštačke inteligencije (European Commission, 2019), postavljaju de-facto

standarde za sigurnu i odgovornu primenu tehnologija veštačke inteligencije i mašinskog učenja podataka u industrijskoj i naučnoj praksi. Ovi propisi naglašavaju važnost transparentnosti, zaštite podataka i etičko korišćenje veštačke inteligencije, što je od posebne važnosti u medicinskoj neurodijagnostici.

Uzimajući u obzir napredak u implementaciji tehnologija veštačke inteligencije i mašinskog učenja podataka, Republika Srbija aktivno radi na usklađivanju svojih nacionalnih standarda sa evropskim regulativama, što se ogleda u istraživačkim projektima i inicijativama Ministarstva zdravlja Republike Srbije (Vuković, Petrović, & Jovanović, 2019).

3.1. Dosadašnja istraživanja u primeni veštačke inteligencije za analizu EEG signala

Prethodna istraživanja u oblasti analize EEG signala pokazala su značajan potencijal primene veštačke inteligencije u detekciji neuroloških poremećaja, naročito epilepsije kod pacijenata.

Tradicionalne metode, koje se uglavnom oslanjaju na ručnu interpretaciju EEG signala, često pate od subjektivnosti kliničara i ograničene sposobnosti da se precizno identifikuju suptilne promene u električnoj aktivnosti mozga pacijenata (Benbadis, Tatum, & Cascino, 2020). Zbog toga su istraživači okrenuli pažnju ka razvoju automatizovanih sistema baziranih na matematičkim modelima mašinskog učenja podataka i veštačke inteligencije, koji mogu da uče reprezentacije iz sirovih podataka i time poboljšaju preciznost dijagnoze.

Kao čest primer se navode istraživanja Acharya et al. (2018) koja su demonstrirala da konvolucione neuronske mreže (CNN) mogu biti uspešno primenjene za automatsku dijagnostiku epilepsije na osnovu EEG zapisa.

Iako je ovaj naučno-istraživački rad Acharya et al. (2018) naglasio upotrebu arhitektura konvolucionih neuronskih mreža (CNN), sličan princip primene se može proširiti na rekurentne neuronske mreže (RNN) i matematičke modele LSTM veštačkih neuronskih mreža, koji se posebno ističu u obradi vremenskih serija zbog svoje sposobnosti da modeliraju zavisnosti između uzastopnih tačaka podataka, poput EEG zapisa.

Upravo zbog prethodno navedenih činjenica, modeli LSTM veštačkih neuronskih mreža su postali dominantan izbor u analizi EEG signala, a pre svega zbog činjenica da omogućavaju detekciju suptilnih promena i anomalija u složenim vremenskim obrascima (Hochreiter & Schmidhuber, 1997; Kaur, Kumari, & Gupta, 2021).

U dole prikazanoj tabeli su navedena neka od značajnijih istraživanja u domenu medicinske neurodijagnostike primenom matematičkih modela veštačke inteligencije.

Prezime, godina	Naziv rada	Opis istraživanja	Rezultat istraživanja
Benbadis, 2020	<i>The role of EEG in patients with suspected epilepsy</i>	Analiza upotrebe EEG signala u dijagnostici epilepsije, s naglaskom na prepoznavanje abnormalnosti.	Povećana tačnost dijagnoze, ali izazovi u

			standardizaciji interpretacije.
Acharya, 2013	<i>Automated EEG analysis of epilepsy: A review</i>	Revizija primene automatskih tehnika za analizu EEG signala u detekciji epileptičkih napada.	Identifikovan potencijal AI metoda, ali je istaknuta potreba za daljim unapređenjima.
Sak et al., 2014	<i>Long short-term memory recurrent neural network architectures for large scale acoustic modeling</i>	Primena LSTM arhitektura za analizu vremenskih serija, što je relevantno i za EEG podatke.	LSTM modeli efikasno uče dugoročne zavisnosti i poboljšavaju preciznost analize.
Kaur et al., 2021	<i>Deep learning in EEG signal analysis: A review</i>	Pregled primene dubokog učenja u analizi EEG signala, sa fokusom na detekciju abnormalnosti.	LSTM modeli pokazuju visoku tačnost, ali su potrebna dodatna optimizacija i prilagođavanje.
Liu et al., 2020	<i>Epileptic seizure classification with symmetric and hybrid bilinear models</i>	Hibridni model koji kombinuje konvolucione i rekurentne mreže za ekstrakciju prostorno-vremenskih karakteristika EEG signala.	Postignute F1-vrednosti iznad 97% u klasifikaciji epileptičkih napada.
Benarous et al., 2019	<i>Sources of interrater variability and prognostic value of standardized EEG features in post-anoxic coma after resuscitated cardiac arrest</i>	Istraživanje varijabilnosti u interpretaciji EEG signala među stručnjacima i uticaj te varijabilnosti na prognostičku vrednost EEG atributa kod pacijenata nakon anoksičnog koma.	Istaknuta je velika varijabilnost među posmatračima, što ukazuje na potrebu za standardizacijom interpretacije.
Casson, 2019	<i>Wearable EEG technology: Current status and future prospects</i>	Pregled naprednih tehnologija za prenosive EEG uređaje, sa fokusom na izazove poput šuma i interferencija, kao i mogućnosti poboljšanja kvaliteta signala.	Dati su uvidi u tehnološke inovacije i preostale izazove u prenosivoj EEG tehnologiji, što je važno za dalji razvoj pouzdanih uređaja.
Niedermeyer & da Silva, 2005	<i>Electroencephalography: Basic principles, clinical applications, and related fields</i>	Sveobuhvatan pregled osnovnih principa EEG-a, uključujući tehnike snimanja, obradu signala i primenu u kliničkoj praksi.	Postavljen je temelj za razumevanje EEG tehnike i njene primene u različitim neurološkim poremećajima.
Saqlain & Saeed, 2024	<i>Recent advances in deep learning for biomedical signal processing</i>	Pregled savremenih metoda dubokog učenja u obradi biomedicinskih signala, uključujući EEG zapise, sa diskusijom o izazovima i mogućnostima za poboljšanje automatizovanih dijagnostičkih sistema.	Predložene su nove metode i tehnike koje mogu poboljšati analizu biomedicinskih signala, ističući potrebu za daljim istraživanjima i optimizacijom modela.

Wolpert & Macready, 1997	<i>No free lunch theorems for optimization</i>	Teorijski rad koji opisuje ograničenja optimizacionih algoritama, naglašavajući da ne postoji univerzalno najbolji algoritam za sve probleme, što ima implikacije za odabir metaheurističkih pristupa u optimizaciji VNM modela.	Ukazuje na potrebu za specifičnim prilagođavanjem optimizacionih tehnika za različite zadatke, što je važno pri razvoju preciznih AI modela za EEG analize.
--------------------------	--	--	---

Tabela 1: Pregled relevantnih naučnih istraživanja u oblasti analize EEG signala

Gore prikazana tabela daje prikaz svih najnovijih i najrelevantnijih naučnih istraživanja u oblasti analize EEG signala, detekcije epileptičkih napada, odnosno primene veštačkih neuronskih mreža i mašinskog učenja podataka u medicinskoj neurodijagnostici.

U tabeli br.1 su prikazani radovi koji se bave razvojem metoda za automatsku analizu EEG signala, identifikaciju abnormalnosti, optimizaciju hiperparametara matematičkih modela korišćenjem metaheurističkih algoritama, kao i naučno-istraživački radovi koji naglašavaju izazove u standardizaciji interpretacije EEG signala.

Rezultati istraživanja jasno ukazuju na značajne prednosti primene tehnologija veštačke inteligencije i mašinskog učenja podataka, ali i na postojeće izazove, što predstavlja prostor za dalja unapređenja i razvoj inovativnih metoda. Ovaj pregled pomaže u identifikaciji ključnih metoda i pristupa, kao i u definisanju smernica za dalji razvoj istraživanja u ovoj oblasti, što je od izuzetnog značaja za unapređenje medicinske neurodijagnostike.

3.2. Industrijska primena LSTM modela u medicini

Nelinearna i nestacionarna priroda EEG signala, koja je detaljno opisana u prethodnim poglavljima, čini EEG signale izuzetno složenim za ručnu analizu. Suptilne, ali veoma kritične promene u EEG talasima često ostaju neprimećene prilikom jednostavne vizuelne inspekcije, što dovodi do rizika od propuštanja važnih informacija prilikom dijagnoze pacijenata (Noachtar & Rémi, 2009).

Pregledi različitih tehnika analize EEG signala pokazuju da, uprkos postojanju širokog spektra do sada implementiranih metoda, postoji značajan prostor za unapređenje kako bi se poboljšala tačnost dijagnoze epilepsije (Acharya et al., 2013). Prethodna istraživanja ukazuju da primena veštačke inteligencije i mašinskog učenja podataka ima ogroman potencijal da pomogne medicinskim stručnjacima (neurorolozima, EEG tehničarima,...) da brže i preciznije analiziraju podatke iz EEG signala, što može biti ključno za rano otkrivanje anomalija u moždanoj funkciji pacijenata (Kaur et al., 2021).

Primena algoritama mašinskog učenja podataka (*Machine Learning*) u analizi EEG signala takođe je intenzivno istraživana. Rasheed et al. (2021) u svojoj naučnoj studiji ukazuju na umerene uspehe primene tehnika mašinskog učenja podataka, ali ističu da i pored njihovih prednosti, nijedan od pristupa nije postigao savršene rezultate u detekciji epileptičnih napada kod pacijenata. Ova zapažanja sugerišu da je kombinacija tradicionalnih i naprednih tehnika nužna za poboljšanje preciznosti dijagnoze u kliničkoj praksi.

Analiza EEG signala, zajedno sa interpretacijom EEG dijagrama, ostaje ključna tehnika za dijagnostiku epilepsije, kao i za precizno lociranje pogođenih oblasti i praćenje uspešnosti terapije pre svega zbog svoje tačnosti, dostupnosti i neinvazivnosti (Noachtar & Rémi, 2009; Tatum et al., 2018). EEG tehnika se takođe pokazala kao ključan alat za diferencijalnu dijagnozu i kvantifikaciju epileptičnih napada tokom predhirurških pregleda, što omogućava finu analizu i planiranje hirurških intervencija kod pacijenata (Tatum et al., 2018). Ipak, postoji opasnost od preterane dijagnostike epilepsije usled pogrešnog tumačenja abnormalnih EEG signala, što pak može dovesti do nepotrebnih intervencija i pogrešnih terapijskih odluka (Amin & Benbadis, 2019).

Prethodna istraživanja su takođe ispitivala potencijal primene veštačke inteligencije za dijagnostiku epilepsije koristeći različite modele klasifikatora, kako nadgledane tako i nenadgledane pristupe mašinskog učenja podataka. Kao primer u naučnoj literaturi često se navodi naučno-istraživački rad Abbasi i Goldenholz (2019) koji sugerise da upotreba algoritma mašinskog učenja podataka poput algoritma *Support Vector Classifiers* (SVC) može postići tačnost od oko 86%, mada druge naučne studije pak ukazuju da dijagnostika bez vizuelne analize često rezultira tačnostima u rasponu od 80% do 86%. Uočena ograničenja algoritma mašinskog učenja podataka kao što je to slučaj sa *Support Vector Machine* (SVM) algoritmom, naročito sposobnost obrade sekvencijalnih podataka, takođe su istaknuta kao prepreka u postizanju još veće preciznosti u kliničkoj praksi primenom metoda mašinskog učenja podataka.

U oblasti kliničkih ishoda, neosporno je da primenjene metode mašinskog učenja svakako ukazuju na značajne rezultate u medicinskoj dijagnostici. U okviru naučno-istraživačkog rada Paldino et al. (2014) je primenjen model mašinskog učenja podataka *Random Forest* (RF) i postignut je rezultat od 100% osetljivost i 95,4% specifičnost u predviđanju jezičkog oštećenja kod pedijatrijskih pacijenata analizom difuzione tenzorske snimke. Iako je ovaj pristup pokazao visoke performanse, traktuografija ima ograničenja jer je indirektna, netačna i teško ju je precizno kvantifikovati.

Pored tradicionalnih metoda mašinskog učenja, mnogobrojni naučni radovi su ispitivali i pristupe dubokog učenja, pre svega u oblastima istraživanja koja su pokazala da hibridne strukture veštačkih neuronskih mreža koje kombinuju konvolucione neuronske mreže i rekurentne neuronske mreže mogu definitivno uspešno izvlačiti prostorne i vremenske karakteristike epileptičnih napada iz EEG snimaka. Konkretno, model hibridne bilinearne strukture, koji koristi kratkoročnu Furijeovu transformaciju na segmentima od 1 sekunde, uspešno je klasifikovao tipove napada sa F1-vrednostima od 97,4% i 97,2% (Liu et al., 2020). Takvi matematički modeli definitivno pokazuju potencijal za unapređenje algoritama za automatsku detekciju, ali njihova primena u realnom svetu i dalje zahteva dodatna istraživanja.

Jedan od ključnih izazova u primeni algoritama veštačke inteligencije, pogotovu u domenu medicinske neurodijagnostike, je potreba za optimizacijom velikog broja kontrolnih parametara veštačke neuronske mreže (hiperparametri). Kako se broj hiperparametara povećava, tačnost implementacionog procesa postaje sve preciznija, ali istovremeno zavisi i od optimalnog podešavanja vrednosti. U tom smislu postoji ekletantan trend primene metaheurističkih algoritama optimizacije, a sve u cilju automatskog podešavanja hiperparametara matematičkih modela veštačkih neuronskih mreža.

Među najpoznatijim metodama optimizacije hiperparametara modela veštačkih neuronskih mreža su *Genetic Algorithm* (GA) (Katoch, Chauhan, & Kumar, 2021), *Particle Swarm Optimization* (PSO) (Kennedy & Eberhart, 1995), *Bat Algorithm* (BA) (Yang & Gandomi, 2012), *Brainstorm Optimization* (BSO) (Shi, 2011), *Chimp Optimization Algorithm* (ChOA) (Khishe & Mosavi, 2020), *Self-Adaptive Step-Size Search* (SASS) (Kumar, Das, & Zelinka, 2020) i *COLSHADE* (Gurrola-Ramos, Hernández-Aguirre, & Dalmau-Cedeño, 2020).

Važno je reći da prema "*No Free Lunch*" teoremi (Wolpert & Macready, 1997), nijedan od ovih pristupa nije univerzalno optimalan, te su potrebni dalji eksperimentalni radovi za poboljšanje rezultata u konkretnim slučajevima medicinske neurodijagnostike.

Metaheuristički algoritmi su takođe uspešno kombinovani sa modelima mašinskog učenja u brojnim oblastima, gde na primer u medicinskoj dijagnostici su se koristili za podešavanje konvolucionih neuronskih mreža u klasifikaciji slika dobijenih putem magnetne rezonance (*Magnetic Resonance Imaging* (MRI)) (Paldino et al., 2014; Abbasi & Goldenholz, 2019) i rendgenskih (*X-ray*) slika (Zivkovic et al., 2022).

Veliki uspeh postignut je i u prognoziranju vremenskih serija, što je od značaja za dijagnostiku Parkinsonove bolesti (Liu et al., 2020) i za predviđanje senzorskih podataka iz elektrokardiograma (Pilcevic et al., 2023) i EEG signala (Pilcevic et al., 2023). Ono što je važno napomenuti da svi prethodno spomenuti pristupi primene veštačke inteligencije u domenu medicinske dijagnostike, pokazuju da se metodologije razvijene za jednu oblast mogu prilagoditi i primeniti u drugim aplikativnim (industrijskim) domenima.

Dinamička analiza veštačkih neuronskih mreža je takođe dobila značajnu pažnju, istraživanja su se bavila bipartitnom sinhronizacijom pomoću dualnog metoda baziranog na događajima, što omogućava bolju koordinaciju između veštačkih neuronskih mreža (Song et al., 2023). Drugi radovi su pak ispitali dinamičke metode zasnovane na događajima za rešavanje problema putem *fuzzy* konsenzusa u nelinearnim višezastupničkim okvirima (Du et al., 2024). Kombinacija tehnika vremenskog uzorkovanja i prostorne metode podele, koja smanjuje troškove merenja, takođe je analizirana i diskutovana u naučno-istraživačkim radovima (Song, Peng, Song, & Stojanovic, 2024).

Iako su prethodna istraživanja dala značajan doprinos primene veštačke inteligencije i mašinskog učenja podataka u domenu medicinske dijagnostike, značajan napredak je svakako ostvaren i u primeni matematičkih modela LSTM veštačkih neuronskih mreža, posebno onih optimizovanih putem algoritma pretrage promenljivog okružnja (*Variable Neighborhood Search*, VNS) za detekciju anomalija u EEG signalima. Ova jedinstvena kombinacija obećava da će unaprediti metodologije za identifikaciju abnormalnosti u EEG očitavanjima i ponuditi novi, efikasan pristup za navigaciju složenostima u dijagnostici i praćenju moždanih anomalija kod pacijenata.

Pored toga, razmatranje alternativnih modela za obradu sekvencijalnih podataka, kao što su jednostavne rekurentne neuronske mreže, rekurentne neuronske mreže sa slojevima pažnje i *echo-state* rekurentne neuronske mreže, ukazuje na potrebu za integracijom najperspektivnijih tehnika. U velikom broju slučajeva ovo uključuje pristup integracije matematičkih modela LSTM veštačke neuronske mreže optimizovanih algoritmom varijabilne

pretrage susedstva, naročito za primene u realnom vremenu, gde je efikasnost i dostupnost matematičkog modela od izuzetne važnosti za kliničku praksu.

Analiza naučno-istraživačkih radova pokazuje da su rekurentne neuronske mreže i matematički modeli LSTM veštačkih neuronskih mreža postavili temelje za napredne metode analize EEG signala, omogućavajući automatsko prepoznavanje složenih vremenski i prostorno zavisnih obrazaca koji su ključni za preciznu dijagnozu neuroloških poremećaja.

Iako su postojeći matematički modeli uspeli da pokažu visoku tačnost, izazovi vezani za kvalitet podataka, potreba da se obezbedi izuzetno zahtevni distribuirani računarski resursi, i potreba za optimizacijom hiperparametara modela veštačke neuronske mreže ostaju značajni za adekvatnu primenu u kliničkoj praksi.

Definitivno je da dalja istraživanja treba da se fokusiraju na sintezu „*lightweight*“ matematičkih modela koji su efikasni i sposobni za rad u realnom vremenu, čime će se unaprediti medicinska dijagnostika i poboljšati zdravstveni ishodi pacijenata.

Ovaj naučno-istraživački rad se oslanja na analizu mogućnosti primene matematičkih modela LSTM veštačkih neuronskih mreža za detekciju abnormalnih obrazaca u EEG signalima. Matematički modeli LSTM veštačkih neuronskih mreža su specijalno dizajnirani da prevaziđu problem nestajućih gradijenata koji su karakteristični za standardne matematičke modele rekurentnih neuronskih mreža, omogućavajući tako efikasno učenje dugoročnih vremenskih i prostornih zavisnosti u podacima (Pascanu, Mikolov, & Bengio, 2013).

U prethodnim poglavljima je detaljno opisana struktura LSTM veštačke neuronske mreže, koja uključuje mehanizme kapija (zaboravljajuću, ulaznu i izlaznu), koji selektivno kontrolišu tok informacija kroz LSTM veštačku neuronsku mrežu. Ovi mehanizmi omogućavaju matematičkom modelu LSTM veštačke neuronske mreže da zadrži relevantne informacije i odbaci one koje nisu korisne, čime se poboljšava preciznost detekcije u inherentno složenim EEG signalima.

Pored unapređenje same arhitekture veštačke neuronske mreže, u ovom naučno-istraživačkom radu se primenjuju i metaheuristički algoritmi za optimizaciju hiperparametara matematičkog modela LSTM veštačke neuronske mreže. Algoritmi optimizacije hiperparametara matematičkog modela LSTM veštačke neuronske mreže, poput genetskog algoritma (*Genetic Algorithm*, GA) i algoritam optimizacije roja čestica (*Particle Swarm Optimization*, PSO), omogućavaju automatsko podešavanje hiperparametara kao što su broj slojeva, broj neurona u skrivenim slojevima, stopa učenja i drugih ključnih hiperparametara. Ova optimizacija je od suštinskog značaja za postizanje najboljih performansi modela LSTM veštačke neuronske mreže, jer omogućava matematičkom modelu da se efikasnije prilagodi specifičnostima EEG podataka, smanjujući rizik od pretreniranosti i povećavajući njegovu sposobnost generalizacije na nove podatke.

Dodatno, ovaj naučno-istraživački rad predstavlja i modifikovanu varijantu algoritma pretrage varijabilnog susedstva (*Variable Neighborhood Search*, VNS), razvijenu specifično za potrebe ovog istraživanja. Ovaj algoritam optimizacije hiperparametara putem pretrage varijabilnog susedstva omogućava dinamično podešavanje i prilagođavanje hiperparametara LSTM veštačke neuronske mreže tokom procesa treniranja, čime se postiže još veća tačnost i stabilnost matematičkog modela LSTM veštačke neuronske mreže.

Ujedno važno je napomenuti da se primena veštačke inteligencije se ne može analizirati i planirati primena u kliničkoj praksi bez adekvatnog regulatornog okvira, kako na globalnom nivou (European Commission, 2019), tako i u Republici Srbiji (Vuković, Petrović, & Jovanović, 2019). Zbog toga je očigledna uloga regulatornog okvira u osiguravanju da se primena tehnologija veštačke inteligencije odvija na siguran i etičan način.

3.3. Regulatorni okviri i etički standardi

Kao što je opisano u prethodnom poglavlju, pored tehničkih aspekata, od suštinskog značaja je primena regulatornih okvira u medicinskoj neurodijagnostici, posebno kada se koriste napredne tehnologije veštačke inteligencije i mašinskog učenja podataka koje imaju direktne implikacije na pacijente u kliničkoj praksi.

U savremenom zdravstvenom sistemu, primena veštačke inteligencije kao primarne dijagnostičke tehnologije nosi sa sobom niz etičkih, pravnih i socijalnih pitanja koja moraju biti rešena kako bi se osigurala sigurnost i poverenje pacijenata u nove tehnologije koje će se očigledno svi više i više koristiti u dnevnoj kliničkoj praksi.

Primena veštačke inteligencije u medicinskoj neurodijagnostici, a posebno u analizi EEG signala, ne može se posmatrati samo sa tehničke strane, izuzetno je važno i razumevanje regulatornih okvira i etičkih standarda koji osiguravaju bezbednost pacijenata i poverenje u nove tehnologije. Konkretno kao primer tehničkih i etičkih standarda koji se moraju usvojiti u medicinskoj neurodijagnostici, a posebno se o istim mora voditi računa prilikom analize EEG signala pomoću tehnika veštačke inteligencije, su izuzetno važni principi anonimizacije podataka. Naime, pošto se radi o izuzetno osetljivim ličnim podacima pacijenata, koji direktno odražavaju neurološku funkciju pacijenata, posebna pažnja se mora posvetiti procesu anonimizacije podataka, jer isti mogu otkriti vrlo lične i osetljive informacije o samom pacijentu. Ovo zahteva dodatnu pažnju u zaštiti podataka i implementaciji etičkih smernica u procesu prikupljanja i obrade medicinskih podataka.

U nastavku ovog naučno-istraživačkog rada su prikazani pravni okviri i etičke smernice koje predstavljaju temelj za razvoj, implementaciju i kontinuirani nadzor sistema veštačke inteligencije u oblasti medicinske neurodijagnostike.

3.3.1. Evropski i međunarodni standardi

Evropska komisija je prepoznala značaj i potrebu implementacije etičkih smernica za pouzdanu upotrebu veštačke inteligencije u svim sferama društva, što se odražava u dokumentima poput "*Ethics Guidelines for Trustworthy AI*" (European Commission, 2019). Ove smernice definišu ključne principe nadgledane primene veštačke inteligencije, među kojima su posebno važni principi:

- Princip transparentnosti,
- Princip odgovornosti,
- Princip pravednosti,

- Princip bezbednosti,
- Princip privatnosti i
- Princip ljudskog nadgledanja.

Prema ovim smernicama Evropska komisija želi da sistemi veštačke inteligencije pre svega moraju biti dizajnirani tako da budu pouzdani i da omogućavaju krajnjim korisnicima apsolutno razumevanje na koji način sistemi veštačke inteligencije donose odluke tokom procesa zaključivanja i odlučivanja.

Posebno se naglašavaju principi transparentnosti i objašnjivosti matematičkog modela u domenima medicinske dijagnostike, gde pogrešne odluke sistema veštačke inteligencije, kao i njihova interpretacija, mogu imati ozbiljne posledice po zdravlje pacijenata.

Osim etičkih smernica, primena veštačke inteligencije u medicini podrazumeva i striktnu zakonodavnu okvire, među kojima je posebno značajna Opšta uredba o zaštiti podataka (*General Data Protection Regulation*, GDPR) koja je doneta u Evropskoj uniji još 2016. godine i kontinuirano je unapređivana od tada.

Regulativni okvir definisan Opštom uredbom o zaštiti podataka postavlja stroge standarde za prikupljanje, obradu i čuvanje ličnih podataka, uključujući i medicinske podatke. Ovi propisi osiguravaju da podaci pacijenata budu zaštićeni i da se koriste isključivo u svrhe koje su jasno definisane i odobrene od strane nadležnih organa. Implementacija Opšte uredbe o zaštiti podataka kao obavezujućeg regulatornog okvira predstavlja izazov za mnoge zdravstvene ustanove, ali istovremeno pruža okvir za etičko i odgovorno korišćenje tehnologija veštačke inteligencije (European Commission, 2019).

U kontekstu analize EEG signala, ovo znači da pacijenti moraju biti jasno informisani o tome kako će se njihovi EEG podaci koristiti, ko će imati pristup tim podacima, odnosno kako se osigurava sigurnost prikupljenih i obrađivanih podataka. Pacijenti imaju pravo da pristupe svojim ličnim (medicinskim) podacima, da zahtevaju njihovu ispravku, brisanje, pa čak i prenosivost, što stvara izazove u implementaciji sistema veštačke inteligencije koji se oslanjaju na velike količine podataka.

Zdravstvene ustanove moraju implementirati tehničke i organizacione mere kako bi osigurale zaštitu svih prikupljenih ličnih podataka od neovlašćenog pristupa ili pak zloupotrebe. Ovo može uključivati enkripciju podataka, kontrolu pristupa zasnovanu na ulogama koje određeni korisnici sistema veštačke inteligencije imaju u okviru samog sistema, kao i redovne revizije sigurnosnih protokola koji se primenjuju u okviru datih sistema veštačke inteligencije.

Pored prethodno spomenutih opštih regulatornih okvira, postoje specijalizovani regulatorni okviri poput HIPAA, (*Health Insurance Portability and Accountability Act*, HIPAA) koji se primenjuje u Sjedinjenim Američkim Državama, a koji je pre svega usredsređen isključivo na zaštitu zaštićenih zdravstvenih informacija (*Protected Health Information*, PHI) koje poseduju zdravstveni osiguravači i pružaoci zdravstvenih usluga. Iako HIPAA regulatorni okvir takođe zahteva saglasnost pacijenta za korišćenje i deljenje PHI, ima više izuzetaka nego GDPR regulatorni okvir, posebno za svrhe lečenja, plaćanja i administrativne svrhe.

Prava pojedinaca da pristupe i isprave svoje zdravstvene informacije su nešto ograničenija nego u okviru GDPR regulatornog okvira. Praktično HIPAA regulatorni okvir je osmišljen tako da se primarno fokusira na osiguravanje poverljivosti i sigurnosti zdravstvenih informacija pacijenata, kao i na olakšavanje prenosa zdravstvenog osiguranja.

U domenu primene veštačke inteligencije u obradi i analizi EEG signala, HIPAA regulatorni okvir zahteva da se EEG podaci adekvatno zaštite od neovlašćenog pristupa i zloupotrebe, ali ne postavlja tako stroge zahteve u pogledu transparentnosti algoritama kao što to predviđa GDPR regulatorni okvir. Sankcije za nepoštovanje HIPAA propisa uključuju novčane i krivične kazne, čija visina zavisi od težine povrede.

Ključna razlika između ova dva standarda (GDPR vs HIPAA) leži u pristupu zaštiti podataka. GDPR regulatorni okvir je sveobuhvatniji i pruža veću kontrolu pojedincima nad svojim podacima, dok je HIPAA regulatorni okvir specifičniji i usmeren na zaštitu zdravstvenih informacija u okviru zdravstvenog sistema.

U praksi, to znači da organizacije koje primenjuju sisteme veštačke inteligencije u medicinskoj dijagnostici moraju pažljivo razmotriti oba standarda i uskladiti svoje prakse kako bi osigurale poštovanje svih relevantnih propisa.

U zemljama kao što je Republika Srbija, koje teže usklađivanju sa standardima koji su na snazi u Evropskoj Uniji, razumevanje GDPR regulatornog okvira je od posebnog značaja, ali se ne sme zanemariti ni HIPAA regulatorni okvir, posebno što je izuzetno važna činjenica da veliki broj zdravstvenih ustanova u Republici Srbiji direktno sarađuje sa institucijama Sjedinjenih Američkih Država i koriste američke tehnologije.

Integracija etičkih principa, transparentnost matematičkih algoritama i zaštita privatnosti pacijenata su ključni elementi za odgovornu primenu sistema veštačke inteligencije u medicini, bez obzira na regulatorni okvir koji se primenjuje. Usklađivanje sa ovim različitim standardima može biti kompleksno, ali je ključno za osiguravanje da se sistemi veštačke inteligencije koji su dizajnirani za medicinsku dijagnostiku mogu koristiti globalno, uz poštovanje različitih pravnih i etičkih zahteva.

3.3.2. Regulatorni okviri u Republici Srbiji

U Republici Srbiji, primena tehnologija veštačke inteligencije i mašinskog učenja podataka u zdravstvenoj zaštiti pacijenata predstavlja značajan korak napred, ali se suočava sa nizom specifičnih izazova. Ograničeni resursi, nedostatak sveobuhvatnog zakonodavnog okvira i potreba za usklađivanjem sa strogim međunarodnim standardima ključni su faktori koji oblikuju trenutno okruženje u okviru koga se razvijaju procedure primene i sistemi veštačke inteligencije u medicinskoj dijagnostici.

U tom smislu Ministarstvo zdravlja Republike Srbije je pokrenulo inicijativu 2023. godine, koja predviđa razvoj nacionalne baze EEG podataka sa preko 10.000 anonimizovanih snimaka u saradnji sa EU projektom AI4Health. Ova inicijativa svakako predstavlja ohrabrujući pomak ka modernizaciji i digitalizaciji zdravstvenog sistema Republike Srbije.

Ministarstvo zdravlja Republike Srbije je zamislilo da ova baza EEG podataka ima potencijal da omogući kreiranje prilagođenih nacionalnih matematičkih modela veštačke inteligencije za analizu EEG signala u Republici Srbiji, što bi moglo rezultirati preciznijim dijagnozama i efikasnijim praćenjem neuroloških poremećaja pacijenata u medicinskim ustanovama Republike Srbije.

Ova baza EEG zapisa Ministarstva zdravlja Republike Srbije ima za cilj da transformiše način na koji se pristupa dijagnostici neuroloških poremećaja i unapredi sposobnost primene naprednih medicinskih tehnologija u zdravstvenoj zaštiti pacijenata u Republici Srbiji.

Glavni cilj ove inicijative Ministarstvo zdravlja Republike Srbije je stvaranje centralizovanog resursa koji će omogućiti:

- **Standardizovanu analizu EEG signala:** Sakupljanjem i digitalizacijom velikog broja lokalnih EEG snimaka, moguće je razviti prilagođene matematičke modele veštačke inteligencije za preciznu analizu i klasifikaciju EEG signala. Ovo će doprineti boljoj identifikaciji abnormalnosti, kao što su epileptički napadi, i drugi neurološki poremećaji.
- **Razvoj i testiranje matematičkih modela veštačke inteligencije:** Lokalna baza podataka će poslužiti kao temelj za razvoj nacionalnih modela veštačke inteligencije, poput LSTM veštačkih neuronskih mreža, koje su specijalizovane za rad sa vremenskim serijama. Kao što je opisano u prethodnim poglavljima ovakvi prilagođeni matematički modeli, optimizovani putem metaheurističkih algoritama, moći će da se treniraju na realnim i anonimiziranim, visokokvalitetnim podacima, čime se povećava preciznost predikcija i smanjuje se broj lažnih dijagnoza kod pacijenata u Republici Srbiji.
- **Unapređenje praćenja i lečenja pacijenata:** Korišćenjem matematičkih modela veštačke inteligencije razvijenih na osnovu ove domaće baze EEG signala, će omogućiti uspostavljanje sistema za kontinuirani monitoring pacijenata u Republici Srbiji. Ovo će omogućiti pravovremenu intervenciju i prilagođavanje terapije u slučaju detekcije abnormalne moždane aktivnosti, što je ključno za poboljšanje ishoda lečenja pacijenata u Republici Srbiji.

Svakako je potrebno posebno naglasiti da ovakve inicijative Ministarstva zdravlja Republike Srbije zahtevaju pažljivo planiranje i implementaciju, uz poseban fokus na zaštitu privatnosti pacijenata i etičku upotrebu podataka koji su prikupljeni i obrađeni kasnije sistemima veštačke inteligencije. To podrazumeva uspostavljanje jasnih protokola za digitalizaciju, anonimizaciju, kontrolu pristupa podacima i praćenje usklađenosti sa relevantnim propisima.

Pored pomenute inicijative Ministarstva zdravlja Republike Srbije, važnu ulogu igra i rad etičkih komiteta za veštačku inteligenciju u Republici Srbiji. Usvajanje standarda EN ISO 15258:2023, sa posebnim akcentom na transparentnost matematičkih algoritama, predstavlja značajan korak ka odgovornoj primeni sistema veštačke inteligencije u medicinskoj neurodijagnostici.

Projekat nacionalne baze EEG podataka Ministarstva zdravlja Republike Srbije predstavlja ohrabrujući pomak ka digitalizaciji zdravstvenog sistema Republike Srbije. Uspesna implementacija ovakvog nacionalnog projekta u okviru Ministarstva zdravlja

Republike Srbije zahteva takođe pažljivo planiranje i sprovođenje nekoliko sledećih ključnih koraka:

- **Anonimizacija podataka i zaštita privatnosti pacijenata:** Da bi se osigurala zaštita ličnih podataka pacijenata, svi EEG snimci moraju biti pažljivo digitalizovani i anonimizovani. To podrazumeva uklanjanje svih identifikacionih informacija i primenu najnovijih tehnika enkripcije podataka. Ovi procesi se moraju uskladiti sa međunarodnim standardima, kao što je Opšta uredba o zaštiti podataka (GDPR) (European Commission, 2019).
- **Tehnička infrastruktura i standardizacija:** Za prikupljanje, skladištenje i obradu velikog broja EEG snimaka neophodna je adekvatna nacionalna tehnička infrastruktura koja zbog osetljivosti informacija, i zakonske potrebe da se podaci čuvaju na teritoriji Republike Srbije, podrazumeva adekvatne tehničke resurse na teritoriji Republike Srbije. Ovo uključuje razvoj softverskih rešenja za standardizovanu obradu podataka, kao i postavljanje računarske mreže za distribuciju i pristup anonimiziranim podacima koja će omogućiti efikasnu analizu i primenu prilagođenih nacionalnih sistema veštačke inteligencije.
- **Saradnja sa međunarodnim projektima:** Projekat je realizovan u saradnji sa EU projektom *AI4Health*, što omogućava prenos znanja i tehnologije iz razvijenih zemalja u Republiku Srbiju. Ovakva saradnja ne samo da poboljšava tehničke aspekte ovog nacionalnog projekta, već i podstiče razvoj lokalne istraživačke zajednice kroz organizovanje obuka, radionica i zajedničkih istraživačkih inicijativa (Ministarstvo zdravlja Republike Srbije, 2023).
- **Edukacija i razvoj stručnjaka:** Uspeh ovakvih inicijativa zavisi i od kontinuirane edukacije zdravstvenih radnika i istraživača u Republici Srbiji. Potrebno je obezbediti programe obuke za pravilno korišćenje i održavanje sistema veštačke inteligencije, kao i za interpretaciju rezultata generisanih primenom veštačke inteligencije.
- **Usklađivanje sa etičkim standardima:** Etika u primeni sistema veštačke inteligencije u zdravstvu igra ključnu ulogu, a implementacija standarda EN ISO 15258:2023, sa fokusom na transparentnost matematičkih algoritama i objašnjenje odluka, predstavljaju temelj za odgovornu upotrebu tehnologija veštačke inteligencije. Primena matematičkih metoda kao što su SHAP (*SHapley Additive exPlanations*, SHAP) vrednosti omogućava lekarima da razumeju logičku osnovu donesenih odluka u okviru sistema veštačke inteligencije, što povećava poverenje u samu apliciranu tehnologiju (Lundberg & Lee, 2017).

Da bi se osiguralo da sistemi medicinske dijagnostike, bazirani na veštačkoj inteligenciji, budu pouzdani i etički prihvatljivi, neophodno je obezbediti da su njihove odluke transparentne i razumljive medicinskim stručnjacima. U tom kontekstu, primena matematičkih metoda kao što su SHAP vrednosti postaje izuzetno važna. Činjenica je da SHAP vrednosti predstavljaju moćan alat za kliničare koji pak omogućava da se razjasni kako pojedinačne karakteristike (*features*) doprinose predikcijama matematičkih modela veštačke inteligencije i samim time utiču na zdravstvene ishode pacijenata.

Praktično to znači da SHAP vrednosti kvantifikuju uticaj svake karakteristike EEG zapisa na izlaz matematičkog modela sistema veštačke inteligencije za dati ulazni podatak. U medicinskoj neurodijagnostici EEG signala, ovo znači da lekari mogu razumeti kako različiti aspekti EEG signala, kao što su frekvencija, amplituda i faza talasa, utiču na dijagnostičku odluku sistema veštačke inteligencije u interpretaciji EEG signala.

Standard EN ISO 15258:2023 naglašava važnost transparentnosti i objašnjenja odluka sistema veštačke inteligencije, gde SHAP vrednosti su samo jedan od načina da se ispune ovi zahtevi standarda. Primena SHAP vrednosti omogućava da sistemi veštačke inteligencije ne budu "crne kutije", već da njihove odluke budu razumljive i verifikovane od strane stručnjaka. Ovo povećava poverenje u tehnologiju veštačke inteligencije, smanjuje rizik od grešaka i pristrasnosti, i osigurava da se sistemi veštačke inteligencije adekvatno i na verifikovan način koriste u korist pacijenata.

U slučaju da sistem veštačke inteligencije predviđi da pacijent ima epileptični napad na osnovu analize EEG signala, SHAP vrednosti mogu pokazati koji su specifični delovi EEG signala (npr. nagli porast amplitude u određenom frekvencijskom opsegu) bili najvažniji za tu odluku sistema veštačke inteligencije. Ovo omogućava lekarima da kritički procene odluku sistema veštačke inteligencije, da uporede te nalaze sa svojim medicinskim znanjem i iskustvom, i da donesu informisanu odluku o daljem lečenju pacijenta.

Primena SHAP vrednosti omogućava da se identifikuju potencijalni problemi u matematičkim modelima veštačke inteligencije, kao što su prekomerna zavisnost od određenih karakteristika ili prisustvo pristrasnosti u podacima. Ovo omogućava ujedno da se matematički model sistema veštačke inteligencije poboljša i na taj način se osigura da sistem donosi pravedne i tačne odluke.

SHAP vrednosti su ključni alat za etičku i odgovornu primenu veštačke inteligencije u zdravstvu, posebno u kontekstu medicinske dijagnostike EEG signala. One omogućavaju transparentnost, objašnjenje odluka, verifikaciju od strane stručnjaka i identifikaciju potencijalnih problema u matematičkom modelu sistema veštačke inteligencije, što doprinosi boljem zdravstvenom ishodu i povećanju poverenja u nove tehnologije veštačke inteligencije. Integracija SHAP vrednosti u razvoj i primenu sistema veštačke inteligencije je u skladu sa standardima EN ISO 15258:2023 i predstavlja korak ka odgovornoj i etičkoj primeni veštačke inteligencije u zdravstvu i kliničkoj praksi.

Inicijativa Ministarstva zdravlja Republike Srbije iz 2023. godine, a koja se odnosi na razvoj nacionalne EEG baze podataka u saradnji sa projektom Evropske Unije AI4Health, predstavlja ključni korak ka modernizaciji zdravstvenog sistema u Republici Srbiji. Ova nacionalna baza ima potencijal da unapredi preciznost dijagnostike neuroloških poremećaja kroz razvoj prilagođenih matematičkih modela sistema veštačke inteligencije, poboljšanje procesa obrade podataka i smanjenje broja pogrešnih dijagnoza. Implementacija ovakvih rešenja zahteva sinergiju između regulatornih okvira, etičkih standarda, tehničke infrastrukture i kontinuirane edukacije stručnjaka, što će omogućiti održiv razvoj i primenu tehnologija veštačke inteligencije u zdravstvenoj zaštiti.

U kontekstu zemalja u razvoju, kao što je Republika Srbija, primena međunarodnih standarda često predstavlja izazov zbog ograničenih resursa, manje razvijenih zakonodavnih

okvira i nedostatka specijalizovane ekspertize. Bez obzira na očigledne izazove, upravo u zemljama poput Republike Srbije postoji veliki potencijal za unapređenje zdravstvenog sistema kroz primenu modernih tehnologija veštačke inteligencije.

Istraživanja, poput onog koje su sprovedi Vuković, Petrović i Jovanović (2019), ukazuju na značajan potencijal implementacije sistema veštačke inteligencije u zdravstvenoj zaštiti Republike Srbije, uz istovremeno naglašavanje potrebe za usklađivanjem nacionalnih regulatornih pravila sa regulatornim i etičkim smernicama Evropske Unije. Takva usklađenost ne samo da poboljšava kvalitet i sigurnost medicinskih usluga, već i podstiče razvoj lokalne istraživačke zajednice i privlači dodatna ulaganja u inovacije.

Jedan od ključnih načina za prevazilaženje postojećih izazova je aktivna međunarodna naučna saradnja i razmena znanja i iskustava sa razvijenim zemljama, gde to podrazumeva učešće u međunarodnim projektima, organizovanje obuka i radionica, kao i uspostavljanje partnerstva sa vodećim istraživačkim institucijama, univerzitetima i kompanijama, kako u zemlji tako i u svetu.

Usklađivanje međunarodnih regulatornih okvira sa lokalnim zakonodavstvom u praksi svakako predstavlja ne samo izazov već i priliku za unapređenje zdravstvenog sistema u Republici Srbiji. Prethodno opisana inicijativa Ministarstva zdravlja Republike Srbije iz 2023. godine za razvoj nacionalne EEG baze podataka ne samo da omogućava prikupljanje, digitalizaciju i analizu velikog broja anonimiziranih EEG snimaka, već i postavlja čvrste osnove za implementaciju naprednih nacionalnih modela sistema veštačke inteligencije u kliničkoj praksi Republike Srbije.

Projekat koji je realizovan u bliskoj saradnji sa Evropskom komisijom i projektom AI4Health, osigurava prenos znanja i tehnologije iz razvijenih zemalja, doprinoseći modernizaciji lokalnih medicinskih praksi Republike Srbije. Ključno je osigurati da se ovi transferi znanja i tehnologije odvijaju na održiv način, uzimajući u obzir specifične potrebe i resurse Republike Srbije.

To podrazumeva prilagođavanje tehnologija lokalnim uslovima, obuku lokalnih stručnjaka za njihovo korišćenje i održavanje, kao i razvoj sopstvenih inovacija na osnovu prenetog znanja. Takođe, neophodno je uspostaviti mehanizme za praćenje i evaluaciju uticaja ovih tehnologija na kvalitet zdravstvenih usluga i ishode lečenja pacijenata u Republici Srbiji.

Integracija regulatornih okvira i etičkih standarda predstavlja preduslov za bezbednu i efikasnu primenu tehnologija veštačke inteligencije u medicinskoj dijagnostici EEG signala. Evropske smernice, kao i lokalni regulatorni okviri u Srbiji, postavljaju temelj za razvoj transparentnih, odgovornijih i pouzdanih sistema veštačke inteligencije.

Inicijative poput one Ministarstva zdravlja (2023) i usvajanje standarda EN ISO 15258:2023 jasno ukazuju na značajan potencijal za unapređenje svih sistema zdravstvene zaštite Republike Srbije (primarni – sekundarni – tercijarni) kroz primenu nacionalnih sistema veštačke inteligencije. Ovi standardi zahtevaju pre svega da svi produkcionni sistemi veštačke inteligencije budu transparentni i pri tome da omogućavaju nedvosmisleno objašnjenje predloženih odluka, što se postiže pak implementacijom metoda za interpretaciju modela, kao što su prethodno opisane SHAP vrednosti.

Od ključnog značaja je promovisanje etičke svesti i odgovornosti među svim akterima uključenim u razvoj i primenu sistema veštačke inteligencije u zdravstvu Republike Srbije, uključujući istraživače, programere, zdravstvene radnike i pravnike koji su svi zajedno uključeni u zdravstveni sistem Republike Srbije na svim nivoima kliničke prakse (primarni – sekundarni – tercijarni nivo).

3.3.3. Etika i tehničke inovacije u medicinskoj dijagnostici

Prethodno navedeni primeri iz etičke prakse, kako internacionalni, tako i oni koji su u primeni u Republici Srbiji, zajedno sa kontinuiranim razvojem tehnoloških i regulatornih rešenja, ukazuju na buduće pravce koji će omogućiti da sistemi veštačke inteligencije postanu sastavni deo modernog zdravstvenog sistema u Republici Srbiji. Cilj je svakako poboljšanje kvaliteta života pacijenata i unapređenje zdravstvenih usluga, ali se mora pažljivo balansirati sa etičkim imperativima i naravno prethodno definisanim, ali i planiranim, regulatornim nacionalnim okvirima.

Etički aspekti primene veštačke inteligencije u medicinskoj dijagnostici odnose se na nekoliko ključnih pitanja koja moraju biti u fokusu prilikom razvoja i implementacije sistema veštačke inteligencije u kliničkoj praksi:

- zaštita privatnosti pacijenata,
- obezbeđivanje transparentnosti u donošenju odluka,
- sprečavanje pristrasnosti u matematičkim modelima,
- osiguranje odgovornosti u slučaju grešaka.

Ovi aspekti su međusobno povezani i svakako se moraju razmatrati holistički kao deo celine i procesa implementacije sistema veštačke inteligencije u kliničkoj praksi.

Transparentnost sistema veštačke inteligencije omogućava lekarima i pacijentima da razumeju kako i na koji način se dolazi do određene dijagnoze, čime se povećava poverenje u tehnologiju veštačke inteligencije i omogućava njena šira prihvaćenost u kliničkoj praksi. Međutim, transparentnost nije uvek tako lako postići, posebno kod kompleksnih matematičkih modela dubokog učenja kod kojih transparentnost, objašnjivost modela i vizuelizacija procesa odlučivanja predstavljaju vrlo često velike izazove pred tehnološkim timovima zaduženim za implementaciju sistema veštačke inteligencije.

Zato je neophodno razvijati i primenjivati tehnike za objašnjenje odluka sistema veštačke inteligencije, kao što su SHAP vrednosti ili LIME (*Local Interpretable Model-agnostic Explanations*, LIME), koje omogućavaju da se razume doprinos svake pojedinačne osobine (*feature*) u matematičkom modelu na konačnu predikciju i odluke koje mogu da utiču na kliničke ishode pacijenata.

Etički standardi propisuju da svaki sistem veštačke inteligencije mora omogućiti ljudsko nadgledanje, kako bi se sprečile situacije u kojima automatizovani sistemi donose odluke bez odgovarajuće kontrole (European Commission, 2019). Ovo je posebno važno u kritičnim situacijama, gde pogrešna odluka može imati ozbiljne posledice po zdravlje pacijenata.

U kontekstu medicinske dijagnostike EEG signala, ovi izazovi su od presudnog značaja jer pogrešne interpretacije mogu dovesti do pogrešnih terapijskih odluka, pa čak smrtnih ishoda. Zbog svega toga, ljudsko nadgledanje rada i pravilna interpretacija, odnosno razumevanje odluka u okviru sistema veštačke inteligencije, mora biti integrisano u sam proces donošenja odluka, a lekari moraju imati mogućnost da intervenišu i preispitaju odluke sistema veštačke inteligencije kao konačan ishod procesa dijagnostike.

Uprkos tehničkim inovacijama i napretku u razvoju algoritama i matematičkih modela sistema veštačke inteligencije, uspešna primena sistema veštačke inteligencije u medicinskoj dijagnostici zahteva i implementaciju regulatornih i etičkih okvira koji osiguravaju odgovornu i etičku upotrebu tehnologije. U razvoju matematičkih modela za analizu EEG signala, važno je osigurati da su svi podaci pacijenata adekvatno zaštićeni i anonimizirani, a da su modeli veštačke inteligencije dizajnirani tako da budu transparentni i objašnjivi. Ovo se postiže kombinacijom tehničkih rešenja, kao što su napredne metode enkripcije podataka, diferencijalna privatnost i federativno učenje, sa etičkim smernicama i regulatornim propisima koji definišu kako se podaci mogu prikupljati, digitalizovati, koristiti i deliti između različitih učesnika i pojedinačnih sistema koji obrađuju podatke pacijenata.

Obuka matematičkih modela sa ugrađenim mehanizmima za objašnjenje odluka, uz stalni nadzor i evaluaciju od strane regulatornih tela, ključna je za osiguranje transparentnosti i odgovornosti. Takav pristup omogućava da se osigura ne samo tehnička pouzdanost sistema veštačke inteligencije, već i njihova usklađenost sa primenjivim etičkim i pravnim normama (Vuković, Petrović, & Jovanović, 2019). Kontekstualna integracija regulatornih okvira i etičkih standarda je ključna za primenu veštačkih neuronskih mreža u medicinskoj dijagnostici i osigurava pre svega da se tehnologija veštačke inteligencije koristi na način koji je u skladu sa vrednostima društva u celini, ali svakako i pojedinačnim interesima pacijenata.

Usaglašavanje međunarodnih smernica, kao što su one Evropske komisije (npr. "*Ethics Guidelines for Trustworthy AI*"), sa lokalnim zakonodavnim okvirom Republike Srbije, predstavlja izazov ali istovremeno pruža priliku za unapređenje svih elemenata zdravstvenog sistema Republike Srbije kroz uspostavljanje visokih standarda u oblasti primene sistema veštačke inteligencije u medicini.

Etički i regulatorni okviri osiguravaju da se sistemi veštačke inteligencije razvijaju i implementiraju na način koji štiti pacijente, garantuje transparentnost i odgovornost, te omogućava kontinuirani razvoj tehnologije uz poštovanje osnovnih ljudskih prava. Ova integracija je temelj za dalji razvoj inovativnih tehnoloških rešenja koja koriste tehnologiju veštačke inteligencije u medicinskoj dijagnostici, što će pak direktno doprineti boljem zdravstvenom ishodu pacijenata i povećanju poverenja u nove tehnologije veštačke inteligencije čija primena se očekuje u kliničkoj praksi Republike Srbije.

Neki od daljih pravaca razvoja su svakako alati za automatsko otkrivanje pristrasnosti u matematičkim modelima sistema veštačke inteligencije, kao i ka tehnikama za njihovo ublažavanje. Praksa je pokazala da je neophodno raditi na permanentnoj edukaciji lekara i pacijenata o prednostima i ograničenjima sistema veštačke inteligencije, kako bi se osigurala informisana saglasnost i kasnija adekvatna upotreba tehnologije veštačke inteligencije u medicinskoj praksi.

3.3.4. Specifični etički izazovi u analizi EEG signala

Analiza EEG signala pomoću tehnologija veštačke inteligencije donosi sa sobom specifične etičke izazove koji zahtevaju pažljivo razmatranje i proaktivan pristup. EEG signali, kao što je poznato, sadrže izuzetno osetljive informacije o neurološkom stanju pacijenta, uključujući detaljne podatke o potencijalnim neurološkim poremećajima, kognitivnim funkcijama, emocionalnim stanjima, pa čak i sklonostima i karakternim crtama pacijenta.

Zaštita privatnosti i poverljivosti ovih podataka je od izuzetnog značaja, a to prevazilazi osnovnu zaštitu od neovlašćenog pristupa podacima pacijenata koji su implementirani u tradicionalnim softverskim alatima za upravljanje podacima. Zaštita mora obuhvatiti i sprečavanje zloupotrebe podataka, kao što je njihova upotreba u svrhe koje nisu u skladu sa interesima pacijenata, diskriminacija, ili neovlašćeno deljenje sa trećim stranama bez izričite saglasnosti pacijenata.

Potrebno je imperativno uspostaviti jasne i stroge politike, odnosno procedure koje regulišu proces digitalizacije, pristup, korišćenje i deljenje EEG podataka, uz redovne revizije i nadzor usklađenosti svih relevantnih procesa i primenjenih tehnologija u prikupljanju, obraditi i analizi EEG podataka pacijenata.

Jedan od ključnih izazova u obezbeđivanju privatnosti je obezbeđivanje efikasne anonimizacije podataka pacijenata. Iako anonimizacija može značajno smanjiti rizik od identifikacije pacijenata, napredne tehnike veštke inteligencije, posebno one koje koriste mašinsko učenje, mogu potencijalno deanonimizovati podatke, naročito ako se kombinuju sa drugim dostupnim informacijama, kao što su demografski podaci ili drugi medicinski zapisi.

Zbog toga je neophodno primeniti robusne tehnike anonimizacije koje su otporne na napredne metode deanonimizacije, i strogo kontrolisati pristup podacima pacijenata, ograničavajući ga samo na one koji imaju opravdanu potrebu za pristupom podacima. Ovo zahteva korišćenje naprednih tehnika anonimizacije, kao što su diferencijalna privatnost (koja dodaje šum podacima kako bi se sprečila identifikacija pojedinaca), federativno učenje (koje omogućava obuku matematičkih modela na decentralizovanim podacima bez potrebe za deljenjem sirovih podataka), kao i implementaciju strogih protokola za kontrolu pristupa podacima pacijenata, uključujući autentifikaciju, autorizaciju i reviziju aktivnosti sistema veštačke inteligencije. Takođe je bitno redovno ažurirati tehnike anonimizacije u skladu sa najnovijim industrijskim i naučnim dostignućima u oblasti privatnosti i zaštite podataka.

Drugi ključni izazov je obezbeđivanje pravednosti i nepristrasnosti u matematičkim modelima sistema veštačke inteligencije. Matematički modeli obučeni na pristrasnim podacima mogu dovesti do diskriminatornih dijagnoza i lečenja, što može imati ozbiljne posledice po pacijente iz marginalizovanih grupa ili one koji ne pripadaju dominantnoj populaciji u skupu podataka. U slučaju da na primer matematički model sistema veštačke inteligencije za dijagnostiku epilepsije obučen prvenstveno na podacima pacijenata bele rase, može biti manje tačan u dijagnostici epilepsije kod pacijenata drugih rasa. Stoga je važno osigurati da su trening podaci reprezentativni za različite demografske grupe, odnosno da se matematički modeli sistema veštačke inteligencije redovno testiraju na pristrasnost, koristeći metrike koje su dizajnirane da detektuju diskriminaciju.

Ova vrsta regulatorne i etičke kontrole zahteva pažljivo planiranje prikupljanja i obrade skupova podataka za treniranje sistema veštačke inteligencije, uključujući reprezentativan uzorak pacijenata i pažljivu analizu potencijalnih izvora pristrasnosti. Neophodno je da tokom procesa digitalizacije podataka koristiti tehnike za otkrivanje i ispravljanje pristrasnosti u matematičkim modelima sistema veštačke inteligencije, kao što su rebalansiranje podataka, ponderisanje uzoraka i razvoj matematičkih algoritama koji su manje osetljivi na pristrasnosti u podacima. Važno je takođe istaći da se matematički modeli sistema veštačke inteligencije koji se obučavaju na medicinskim podacima i za potrebe medicinske dijagnostike, redovno validiraju na različitim populacijama, demografskim, starosnim i polnim grupama kako bi se osiguralo da su performanse primenjenih modela konzistentne.

Etički izazov predstavlja i pitanje autonomije pacijenata, odnosno njihovog prava na samostalno odlučivanje o svom zdravlju. Pacijenti moraju biti adekvatno informisani o upotrebi tehnologija veštačke inteligencije u njihovoj dijagnostici i lečenju, uključujući potencijalne koristi i rizike, kao i o inherentnim ograničenjima sistema veštačke inteligencije. Pacijenti moraju imati pravo da odbiju tretman koji uključuju korišćenje tehnologije veštačke inteligencije bez straha od negativnih posledica.

Transparentnost i objašnjivost matematičkih modela veštačke inteligencije su ključni za omogućavanje pacijentima da razumeju kako se donose odluke o njihovom zdravlju i da donesu informisane odluke. Ovo zahteva razvoj matematičkih modela sistema veštačke inteligencije koji su objašnjivi i razumljivi, ne samo medicinskim stručnjacima, već i samim pacijentima, kao i implementaciju jasnih i lako razumljivih protokola za informisanje pacijenata o upotrebi sistema veštačke inteligencije u njihovoj dijagnostici i lečenju.

Važno je uspostaviti takve protokole lečenja koji omogućavaju da pacijenti imaju mogućnost konsultacije sa lekarom o rezultatima koji su proizvod analize sistema veštačke inteligencije, da postave pitanja i da izraze svoje brige, i da na kraju krajeva donesu informisane odluke o svom zdravlju. Lekari moraju biti obučeni da efikasno komuniciraju sa pacijentima o tehnologijama veštačke inteligencije, objašnjavajući njihove prednosti i nedostatke, kao i da podrže pacijente u donošenju sopstvenih odluka koje su u skladu sa njihovim vrednostima i ličnim preferencama.

U rešavanju ovih etičkih izazova, od suštinskog je značaja uspostaviti multidisciplinarni pristup koji uključuje medicinske stručnjake, istraživače, etičare, pravnike, programere i predstavnike pacijenata. Samo kroz ovakvu saradnju je moguće razviti etičke okvire i tehnička rešenja koja će osigurati da se tehnologije veštačke inteligencije u analizi EEG signala koriste na odgovoran i etički način, štiteći prava i interese pacijenata i doprinoseći unapređenju njihovog zdravlja i unapređenju kliničke prakse.

3.3.5. Preporuke razvoja etičkih i regulatornih okvira u medicinskoj dijagnostici

Da bi se osigurala etička i odgovorna primena tehnologija veštačke inteligencije u analizi EEG signala, neophodno je uspostaviti sveobuhvatan etički okvir koji obuhvata sledeće elemente:

- **Jasne smernice i propise:** Regulatorna tela treba da razviju jasne smernice i propise za upotrebu sistema veštačke inteligencije u medicinskoj dijagnostici, uključujući standarde za zaštitu podataka, anonimizaciju i objašnjivost matematičkih modela. Ovi propisi treba da budu fleksibilni i da se redovno ažuriraju kako bi se uzeli u obzir novi industrijski trendovi, tehnološki razvoj i etičke izazove budućnosti.
- **Etički komiteti:** Zdravstvene ustanove treba da osnuju etičke komitete koji će nadgledati razvoj i primenu tehnologija veštačke inteligencije i ujedno osigurati usklađenost tehnologije sa etičkim standardima. Etički komiteti treba da budu sastavljeni od stručnjaka iz različitih oblasti, uključujući medicinu, pravo, etiku, informatiku i društvene nauke.
- **Obuka i edukacija:** Lekari i drugi zdravstveni radnici treba da budu obučeni o etičkim aspektima primene veštačke inteligencije, kao i o tehničkim aspektima matematičkih modela sistema veštačke inteligencije. Ovo će im omogućiti da donose informisane odluke o upotrebi sistema veštačke inteligencije u svojoj medicinskoj praksi i da razumeju potencijalne rizike i koristi za svoje pacijente.
- **Javna rasprava:** Važno je podsticati javnu raspravu o etičkim implikacijama sistema veštačke inteligencije u zdravstvu kako bi se izgradilo poverenje i osigurala transparentnost. Ovo može uključivati organizovanje javnih foruma, objavljivanje članaka u medijima i korišćenje društvenih mreža za informisanje i angažovanje javnosti u široj podršci usvajanja veštačke inteligencije kao bitnog elementa zdravstvenog sistema u celini.
- **Interdisciplinarna saradnja:** Razvoj etičkih smernica i rešenja zahteva saradnju između stručnjaka iz različitih oblasti, uključujući medicinu, pravo, etiku, informatiku i društvene nauke. Ovo će osigurati da se uzmu u obzir svi relevantni aspekti društva u celini i na taj način da se razviju sistemska rešenja koja su efikasna i etički prihvatljiva.

Integracija etičkih principa u razvoj i primenu tehnologija veštačke inteligencije u analizi EEG signala je ključna za osiguranje da ove tehnologije budu korisne za pacijente i društvo u celini. U bliskoj budućnosti, može se očekivati da će se razviti neki novi etički izazovi kako tehnologije veštačke inteligencije postanu sve sofisticiranije i sve više integrisane u zdravstveni sistem.

Veoma je važno da se etički i regulatorni okviri redovno preispituju i ažuriraju kako bi se osiguralo da se postojeći i svi budući izazovi adekvatno rešavaju. Izuzetno je važno da se podstiče istraživanje o etičkim implikacijama veštačke inteligencije u zdravstvu kako bi se bolje razumeli potencijalni rizici i krajnje koristi za pacijente.

3.4. Kontekstualna integracija istraživanja EEG tehnike

Prethodna poglavlja ovog naučno-istraživačkog rada detaljno su obradila osnove EEG tehnike, matematičke osnove veštačkih neuronskih mreža, kao i izazove u interpretaciji EEG signala. Ova teorijska osnova pruža temelj za razumevanje složenosti analize EEG signala, kao i za identifikaciju potreba za unapređenjem metodologija rada i kliničke prakse.

U okviru ovog poglavlja, biće prikazana sinergija i integracija prethodno opisanih naučnih istraživanja koja su postavila temelje za razvoj ovog naučno-istraživačkog rada. Prethodni naučni radovi u oblasti analize EEG signala, primena veštačkih neuronskih mreža i optimizacije hiperparametara matematičkog modela, predstavljaju ključnu inspiraciju za ovaj naučno-istraživački rad, jer je ukazano na glavne izazove i mogućnosti unapređenja medicinske dijagnostike neuroloških poremećaja primenom sistema veštačke inteligencije u analizi EEG zapisa.

U nastavku ovog naučno-istraživačkog rada se izlažu načini na koje se rezultati prethodnih studija integrišu u implementirani pristup doktorske disertacije, kao i na koji način su analizirane metodologije transformisane i nadograđene u okviru ovog naučno-istraživačkog rada. Razmatrano je kako su prepoznate adresirane praznine u dosadašnjim naučnim istraživanjima, kako je ovaj naučno-istraživački rad doprineo popunjavanju tih praznina, i kao konačni rezultat ove doktorske disertacije je predstavljen novi metodološki pristup u analizi EEG signala modelima LSTM veštačkih neuronskih mreža optimizovanih metaheuristikama.

Prethodna istraživanja, kao što su studije Acharya et al. (2013) i Sak et al. (2014), detaljno su razmotrila upotrebu automatizovanih metoda u analizi EEG signala, naglašavajući prednosti korišćenja veštačkih neuronskih mreža u detekciji epileptičkih napada. Ovi radovi su istakli pre svega da tradicionalne metode, oslanjajući se na ručnu interpretaciju, često ne uspevajući da uhvate suptilne obrasce unutar EEG signala, što direktno utiče na tačnost dijagnoze i ishode lečenja pacijenata. Ručna interpretacija EEG signala je podložna subjektivnosti i zahteva značajnu ekspertizu kliničara, što je čini vremenski zahtevnom i potencijalno nekonzistentnom za donošenje pravovremenih i tačnih dijagnoza.

Na osnovu nalaza iz studije Acharya et al. (2013) i Sak et al. (2014), ovaj naučno-istraživački rad se usmerava na primenu matematičkih modela LSTM veštačkih neuronskih mreža, koje su specijalno razvijene za rad sa vremenskim serijama, kao što su EEG signali, i koji omogućavaju učenje dugoročnih zavisnosti u podacima (Hochreiter & Schmidhuber, 1997). LSTM veštačke neuronske mreže omogućavaju da se uhvate kompleksni temporalni odnosi u EEG podacima, što je ključno za tačnu detekciju epileptičkih napada i drugih neuroloških abnormalnosti.

U okviru ovog naučno-istraživačkog rada razmatra se primena mehanizama pažnje (*attention mechanisms*) unutar matematičkog modela LSTM veštačkih neuronskih mreža, što omogućava modelu LSTM veštačke neuronske mreže da se fokusira na najrelevantnije delove EEG signala i tako dodatno poboljša performanse predikcije i klasifikacije.

Istraživanje sprovedeno u okviru ovog naučno-istraživačkog rada se oslanja na ideje i metodologije prethodnih studija, ali ih dodatno nadograđuje kroz integraciju metaheurističkih algoritama za optimizaciju hiperparametara matematičkog modela LSTM veštačke neuronske mreže.

Dok su raniji radovi identifikovali izazove, poput problema nestajućih gradijenata (Pascanu, Mikolov, & Bengio, 2013) i potrebe za boljom interpretacijom EEG signala, ovaj pristup kombinuje LSTM veštačke neuronske mreže sa metaheurističkim tehnikama kao što su genetski algoritmi (*Genetic Algorithm*, GA) i algoritam optimizacije roja čestica (*Particle*

Swarm Optimization, PSO) radi poboljšanja performansi matematičkog modela LSTM veštačke neuronske mreže.

Optimizacija hiperparametara je kritična za postizanje optimalnih performansi matematičkog modela LSTM veštačke neuronske mreže, ali je često vremenski zahtevna i zahteva značajne računarske resurse. Upravo ovde metaheuristički algoritmi dolaze do izražaja, jer omogućavaju efikasno pretraživanje prostora hiperparametara i pronalaženje optimalnih vrednosti u razumnom vremenskom roku. Time se postiže ne samo veća tačnost, već i efikasnija obuka matematičkog modela LSTM veštačke neuronske mreže, što je posebno važno u kontekstu obrade EEG podataka koji sadrže visoku količinu šuma i varijacija.

U okviru ovog naučno-istraživačkog rada je razmatrana i primena adaptivnih metaheurističkih algoritama, koji dinamički prilagođavaju svoje parametre tokom procesa optimizacije, što pak može dodatno poboljšati efikasnost i robustnost optimizacije.

Pored toga, prethodni radovi su ukazali na važnost standardizacije u snimanju i interpretaciji EEG signala (Niedermeyer & da Silva, 2005; Casson, Yates, & Rodrigues, 2010). Razlike u protokolima za snimanje i obradu EEG signala mogu značajno uticati na performanse matematičkog modela LSTM veštačke neuronske mreže, te je stoga standardizacija ključna za osiguranje pouzdanih rezultata optimizacije.

Ovaj naučno-istraživački rad koristi te smernice kao osnovu za uspostavljanje robustne implementacione metodologije, u kojoj ceo postupak počinje sa pravilno postavljanjem elektroda, nakon toga se prelazi na adekvatno filtriranje šuma i artefakata, primenu standardizovanih metoda za ekstrakciju karakteristika, i kao deo procesa pripreme podataka finalna primena automatizovanih metoda za detekciju abnormalnosti. Time se osigurava da su svi koraci procesa, od prikupljanja podataka do finalne klasifikacije u okviru matematičkog modela LSTM veštačke neuronske mreže, usklađeni sa najboljim praksama iz prethodnih naučno-istraživačkih studija i kliničke prakse.

Konkretno, implementirane su preporuke za frekvenciju uzorkovanja podataka, postavljanje elektroda prema sistemu 10-20, korišćenje filtera za uklanjanje šuma frekvencije električne mreže (50Hz ili 60Hz zavisno od geografskog područja), kao i filtriranje artefakata izazvanih pokretima očiju i mišića pacijenata.

Važan aspekt prethodnih istraživanja je i usklađivanje sa regulatornim okvirima i etičkim smernicama, koje su posebno istaknute od strane Evropske komisije (European Commission, 2019) i nacionalnih inicijativa (Vuković, Petrović, & Jovanović, 2019).

Kao što je u prethodnim poglavljima detaljno objašnjeno, u kontekstu medicinske neurodijagnostike, upotreba sistema veštačke inteligencije mora biti apsolutno u skladu sa principima transparentnosti, odgovornosti, pravednosti i privatnosti. Ovaj naučno-istraživački rad ne samo da se oslanja na tehnološke inovacije, već i na uspostavljanje jasnih smernica za etičku primenu veštačkih neuronskih mreža u medicinskoj neurodijagnostici.

Ovaj pristup je ključan za primenu matematičkog modela u realnom svetu, gde transparentnost i pouzdanost matematičkog modela direktno utiču na zdravstvene ishode pacijenata. Uključena je detaljna analiza potencijalnih etičkih implikacija primenjene metodologije, kao i mere za ublažavanje rizika.

Osigurano je da su svi podaci anonimizovani u skladu sa GDPR i drugim relevantnim propisima, da pacijenti daju informisanu saglasnost za korišćenje njihovih podataka, i da su primenjeni matematički modeli tako dizajnirani tako da budu transparentni i objašnjivi. Kao deo ovog naučno-istraživačkog rada razmatrana je i upotrebu tehnika za detekciju i ublažavanje pristrasnosti u matematičkim modelima, kako bi se osiguralo da su rezultati pravedni i ne diskriminišu pacijente na osnovu rase, pola ili drugih zaštićenih karakteristika.

Integracijom prethodnih istraživanja u ovaj naučno-istraživački rad, postavljani su temelji za razvoj inovativnog nacionalnog sistema veštačke inteligencije za automatsku detekciju abnormalnih obrazaca u EEG signalima u Republici Srbiji. Na osnovu celokupnog pregleda literature, može se zaključiti da kombinacija LSTM veštačkih neuronskih mreža sa metaheurističkom optimizacijom definitivno predstavlja jedan obećavajući pristup za poboljšanje tačnosti i brzine dijagnoze neuroloških poremećaja i stanja kod pacijenata.

Važno je napomenuti da predložena integracija pristupa omogućava primenu sistema veštačke inteligencije u realnom vremenu, što je od izuzetne važnosti u hitnim medicinskim situacijama. Budući pravci istraživanja usmereni su na dalju integraciju adaptivnih i hibridnih modela optimizacije, razvoj novih tehnika regularizacije i povećanje interpretabilnosti matematičkog modela. Važno je i napomenuti da usklađivanje sa etičkim i regulatornim okvirom osigurava da se primena opisanih tehnologija veštačke inteligencije vrši na bezbedan i transparentan način u okviru zdravstvenog sistema na svim nivoima.

Na taj način predloženi pristup ne samo da doprinosi razvoju naprednih matematičkih metoda i modela za medicinsku neurodijagnostiku, već postavlja temelje za buduća istraživanja koja će se baviti razvojem adaptivnih, hibridnih i “*lightweight*” modela optimizacije, s ciljem efikasne primene u realnom vremenu u kliničkim uslovima. Posebna pažnja biće posvećena razvoju matematičkih modela koji se mogu efikasno primeniti na uređajima sa ograničenim resursima, kao što su mobilni telefoni i prenosivi uređaji, što bi omogućilo kontinuirano praćenje EEG aktivnosti pacijenata i rano otkrivanje neuroloških poremećaja.

Kao nastavak naučno-istraživačkog rada predložimo je da se istraži mogućnost korišćenja *transfer learning* tehnika za prilagođavanje matematičkog modela na različite populacije pacijenata i različite uređaje za snimanje EEG signala, što bi dodatno poboljšalo koncept generalizacije i primenljivost prikazanih rezultata.

4. Metodologija istraživanja anomalija EEG signala putem LSTM i metaheurističke optimizacije

U okviru ovog poglavlja naučno-istraživačkog rada biće predstavljene detaljne eksperimentalne postavke i eksperimentalni rezultati naučno-istraživačkog rada, sa posebnim osvrtom na primenu matematičkog modela LSTM veštačke neuronske mreže u analizi EEG signala. Prvo je opisan skup ulaznih podataka koji je korišćen u istraživanju, a koji obuhvata segmente stvarnih, označenih podataka pacijenata prikupljenih iz javno dostupnih repozitorijuma medicinskih podataka (<https://www.upf.edu/web/ntsa/downloads>) i prethodnih istraživanja koja su pokazala postojanje nelinearnih determinističkih i konačno-dimenzionalnih struktura u vremenskim serijama električne aktivnosti mozga pacijenata, sa posebnim osvrtom na zavisnost od regiona snimanja i stanja mozga pacijenata (Andrzejak et al., 2001). Ovi podaci su osnova za kasniju validaciju i testiranje predloženog pristupa ove doktorske u detekciji anomalija primenom metaheurističkih algoritama optimizacije na LSTM veštačke neuronske mreže disertacije.

U nastavku ovog naučno-istraživačkog rada su prikazani detaljni rezultati eksperimenata sprovedenih korišćenjem modela LSTM veštačkih neuronskih mreža, pri čemu su posebno istaknute performanse predloženog matematičkog modela u poređenju sa drugim arhitekturama rekurentnih veštačkih neuronskih mreža (RNN). Analiza eksperimenatalnih rezultata omogućava uvid u prednosti i nedostatke pojedinačnih matematičkih modela, kao i identifikaciju ključnih faktora koji doprinose povećanju tačnosti i efikasnosti detekcije abnormalnosti u EEG zapisima.

Pored kvantitativne analize ulaznih podataka, u ovom poglavlju su objašnjene i metodološke i algoritamske tehnike primenjene radi optimizacije hiperparametara matematičkog modela LSTM veštačkih neuronskih mreža. Poseban naglasak je stavljen na mere koje su preduzete za poboljšanje performansi matematičkog modela, uključujući optimizaciju hiperparametara, primenu metaheurističkih algoritama, kao što su genetski algoritam (GA) (Katoch, Chauhan, & Kumar, 2021) i algoritam optimizacije roja čestica PSO (Kennedy & Eberhart, 1995), kao i evaluaciju rezultata kroz standardizovane metrike (tačnost, preciznost, osetljivost i specifičnost).

Ovaj integrirani pristup, koji kombinuje visokokvalitetno snimanje podataka, pažljivo definisane eksperimentalne protokole i napredne tehnike optimizacije veštačkih neuronskih mreža, predstavlja dobar polazni osnov za dalji razvoj i primenu veštačkih neuronskih mreža u medicinskoj neurodijagnostici. Rezultati dobijeni u okviru ovog istraživanja pružaju ne samo empirijsku podršku za predloženi matematički model, već i smernice za buduća istraživanja i unapređenje tehnika obrade EEG signala u kliničkoj praksi.

4.1. Varijacije u interpretaciji medicinskih podataka i tehnički izazovi EEG signala

Varijacije u interpretaciji medicinskih podataka zasnovane na prethodnom iskustvu medicinskih stručnjaka mogu definitivno dovesti do pogrešne dijagnoze pacijenata (Benbadis & Kaplan, 2019). U kliničkoj praksi, subjektivnost u interpretaciji rezultata medicinskih

testova, posebno onih koji zahtevaju vizuelnu analizu od strane kliničkih eksperata, može biti značajan izvor grešaka i pogrešnih dijagnoza koje u ekstremnim slučajevima mogu dovesti čak do smrtnih ishoda kod pacijenta. Različiti lekari mogu različito tumačiti iste podatke, što dovodi do nekonzistentnih dijagnoza i tretmana pacijenata.

Varijacije u interpretaciji EEG signala među stručnjacima predstavljaju kritičan izazov u kliničkoj praksi. Studija Benbadis & Kaplan (2019) je pokazala da se 30-40% epileptičnih dijagnoza razlikuje između neurologa sa različitim nivoima iskustva. Tokom jedne od retrospektivne analize 500 slučajeva, 15% pacijenata je pogrešno klasifikovano kao epileptičari zbog pogrešnog tumačenja artefakata ili benignih EEG obrazaca, što predstavlja izuzetno visok nivo greške manuelne interpretacije anomalija EEG zapisa. Ova varijabilnost je posebno izražena u regionima sa ograničenim resursima, gde nedostatak specijalizovanih epileptologa produžava dijagnostički proces za čak 6-12 meseci (Amin & Benbadis, 2019).

Nelinearna i nestacionarna priroda EEG signala čini EEG zapise izuzetno zahtevnim i složenim za ručnu analizu, dok suptilne, ali pak kritične promene u EEG talasima, mogu biti propuštene jednostavnom vizuelnom inspekcijom od strane neurologa i/ili EEG tehničara. EEG signali su izuzetno složeni, sa varijabilnim obrascima koji se menjaju tokom vremena. Ručna analiza ovakvih signala je dugotrajna i zahteva visok nivo stručnosti, gde čak i izuzetnoiskusni neurofiziolozi mogu propustiti veoma važne detalje, posebno kada se radi o velikim količinama podataka koji su prisutni tokom snimanja EEG zapisa.

Nelinearna i nestacionarna priroda EEG signala dodatno komplikuje analizu EEG podataka, gde na primer gamma talasi (30-100 Hz) se često preklapaju sa mišićnim artefaktima, dok spori talasi (<1 Hz) mogu biti maskirani pokretima očiju pacijenata. Ručna detekcija ovih obrazaca zahteva prosečno 45 minuta po EEG snimku, sa tačnošću koja varira od 70% do 85% što u konačnom ishodu zavisi i od opšteg slučaja kliničke slike i kompleksnosti slučaja pacijenata (Noachtar & Rémi, 2009). U studiji sprovedenoj na 200 pedijatrijskih pacijenata, 23% epileptičnih napada je propušteno tokom inicijalnog pregleda, što je dovelo do odlaganja terapije za 3 meseca u proseku (Tatum et al., 2018).

4.2. Opis skupa ulaznih podataka eksperimenta

U ovom istraživanju, kao ulazni skup podataka korišćeni su segmenti stvarnih, označenih EEG signala pacijenata, prikupljeni iz javno dostupnih repozitorijuma medicinskih podataka. Konkretno je korišćen repozitorijum javno dostupan na web adresi <https://www.upf.edu/web/ntsa/downloads>.

Korišćeni repozitorijum podataka koji održava Univerzitet Pompeu Fabra (UPF, <https://www.upf.edu>), sadrži obimnu kolekciju anonimiziranih EEG snimaka, koja je prethodno korišćena u brojnim istraživanjima vezanim za analizu EEG signala i detekciju neuroloških poremećaja, posebno epilepsije.

Ovaj repozitorijum podataka pruža veoma raznovrstan skup atributa podataka koji obuhvata različite tipove EEG snimaka, uključujući interiktalne (između napada) i iktalne (tokom napada) snimke. Takva raznolikost podataka je od ključnog značaja za razvoj robusnih matematičkih modela veštačkih neuronskih mreža koji mogu generalizovati i efikasno raditi u različitim kliničkim scenarijima.

Pored toga, u procesu selekcije i analize podataka, uzeti su u obzir i rezultati prethodnih istraživanja koja su ukazala na postojanje nelinearnih determinističkih i konačno-dimenzionalnih struktura u vremenskim serijama električne aktivnosti mozga pacijenata.

Posebno je naglašena zavisnost ovih struktura od regiona snimanja i stanja mozga pacijenata (Andrzejak, Lehnertz, Mormann, Rieke, David, & Elger, 2001). Ovi uvidi su bili ključni za razumevanje složenosti EEG signala i za formiranje adekvatnog pristupa analizi, uključujući izbor adekvatnih tehnika predobrade i modeliranja ulaznog skupa podataka za kasniju obradu putem LSTM veštačke neuronske mreže.

Skup ulaznih podataka za treniranje matematičkog modela koji je korišćen u ovom naučno-istraživačkom radu, karakteriše se sledećim globalnim karakteristikama:

- **Realni podaci:** Podaci su prikupljeni od stvarnih pacijenata, što osigurava njihovu relevantnost za kliničku praksu. Ovo je od suštinskog značaja za razvoj matematičkog modela koji u budućnosti mogu biti primenjeni u realnim kliničkim uslovima.
- **Označeni podaci:** Svaki segment EEG signala je označen, što omogućava nadgledano učenje i evaluaciju performansi matematičkog modela. Oznake su ključne za obuku matematičkog modela koji treba da razlikuje između normalnih i abnormalnih EEG obrazaca.
- **Raznovrsnost:** Skup podataka obuhvata snimke različitih pacijenata, sa različitim neurološkim stanjima, što doprinosi generalizaciji matematičkog modela. Ova raznolikost je važna za smanjenje pristrasnosti matematičkog modela i poboljšanje njegove sposobnosti da radi na novim, neviđenim podacima.
- **Vremenske serije:** EEG signali su vremenske serije, što zahteva primenu matematičkog modela koji su sposobni da obrade sekvencijalne podatke. Ovo je ključno za identifikovanje vremenskih zavisnosti i obrazaca u EEG signalima.
- **Nelinearnost i nestacionarnost:** EEG signali su nelinearni i nestacionarni, što predstavlja izazov za analizu, odnosno zahteva primenu naprednih tehnika obrade EEG signala. Kao što je prikazano u nastavku ovog naučno-istraživačkog rada, EEG signali se menjaju tokom vremena i sadrže veoma složene, nelinearne obrasce, što zahteva sofisticirane metode za njihovu analizu.
- **Broj kanala i frekvencija uzorkovanja:** Skup podataka obuhvata EEG snimke sa više kanala, što omogućava prostornu analizu električne aktivnosti mozga pacijenta. Frekvencija uzorkovanja je adekvatna za hvatanje relevantnih frekvencijskih komponenti EEG signala.
- **Trajanje snimaka:** Trajanje EEG snimaka varira, što omogućava analizu kako kratkih, tako i dugih segmenata EEG zapisa kod pacijenata.


Daljom tehničkom analizom skupa ulaznih podataka dolazi se do sledećih tehničkih detalja:

- **Multikanalni signali:** Podaci sadrže 16 kanala, što omogućava detaljnu prostornu analizu električne aktivnosti mozga kod pacijenata.
- **Visoka rezolucija:** 65536 uzoraka po fajlu pruža visoku vremensku rezoluciju.

- **Različite faze spavanja/budnosti:** Podaci obuhvataju EEG signale iz različitih faza spavanja i budnosti, što omogućava analizu promena u električnoj aktivnosti mozga pacijenata i tokom ovih faza.
- **Fokalni i nefokalni signali:** Razlikovanje fokalnih i nefokalnih EEG signala omogućava analizu lokalizovanih i generalizovanih promena u električnoj aktivnosti mozga pacijenata.
- **Hibridne elektrode:** Korišćenje hibridnih dubinskih elektroda omogućava snimanje EEG signala iz makro i mikro nivoa.

Svi gore navedeni atributi su prikazani u strukturi neparsiranih .txt fajlova, koji čine deo skupa podataka za treniranje i verifikaciju matematičkog modela LSTM veštačke neuronske mreže, a koji se odlikuju sledećim karakteristikama:

- **Makro elektrode (Kanali 1-8):** EEG signali snimljeni makro elektrodama nalaze se u kolonama 1 do 8. Unutrašnji i spoljašnji kanali su raspoređeni u kolonama označenim od 1 do 8.
- **Mikro žice (Kanali 9-16):** EEG signali snimljeni mikro žicama nalaze se u kolonama označenim od 9 do 16.
- **Struktura fajla:** Svi fajlovi imaju 65536 redova, gde svaki red predstavlja uzorak. Fajlovi nemaju zaglavlja (*header*).
- **Tip signala:** Fajlovi sa prefiksom "F" sadrže fokalne multikanalne signale, dok fajlovi sa prefiksom "NF" sadrže nefokalne multikanalne signale.
- **Faza spavanja/budnosti:** Nazivi .txt fajlova sadrže slovo koje označava fazu ciklusa spavanja/budnosti u kojoj su EEG signali snimljeni:
 - W: Stanje budnosti
 - R: REM faza spavanja (*Rapid Eye Movement*)
 - S1: Laka faza spavanja
 - S2: Faza sporotalasnog spavanja (sporotalasne faze N2 i N3 su objedinjene u S2)
- **Indeks signala:** Broj u nazivu fajla odgovara indeksu multikanalnog signala u tom fajlu.



Slika 17: Prikaz fokalnih i nefokalnih multikanalnih EEG signala eksperimenta

Izvorni Python kod za "Slika 17: Prikaz fokalnih multikanalnih i nefokalnih multikanalnih EEG signala eksperimenta (adaptirano prema eksperimentalnoj simulaciji, Univerzitet Pompeu Fabra (UPF), repozitorijum <https://www.upf.edu/web/ntsa/downloads.>)"

```
import os
import zipfile
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import seaborn as sns
import tkinter as tk
from tkinter import filedialog
import time
from tqdm import tqdm

def process_eeg_data(zip_file_path):
    """Obrada EEG podataka iz ZIP fajla sa gauge metrom radi lakse vizuelizacije."""
    data_frames = []
    try:
        with zipfile.ZipFile(zip_file_path, 'r') as zip_ref:
            file_list = [f for f in zip_ref.namelist() if f.endswith('.txt')]
            total_files = len(file_list)
            start_time = time.time()

            for i, file_path in enumerate(tqdm(file_list, desc="Obrada fajlova")):
                try:
```

```

with zip_ref.open(file_path) as file:
    data = np.loadtxt(file)
    df = pd.DataFrame(data, columns=[f'kanal_{i+1}' for i in range(16)])

    # Ekstrakcija informacija iz naziva .txt fajla
    file_name = os.path.basename(file_path)
    if file_name:
        phase = file_name[0] # W, R, S1, S2

    # Ekstrakcija indeksa signala
    try:
        signal_index = int(file_name.split('_')[-1].split('.')[0])
    except ValueError:
        print(f"Upozorenje: Neispravan format indeksa u nazivu fajla:
{file_name}")
        continue # Preskakanje fajla sa neispravnim indeksom

    df['faza'] = phase
    df['indeks_signala'] = signal_index

    # Dodaje se tip signala (fokalni/nefokalni) i označava se
    if 'F' in file_name:
        df['tip_signala'] = 'fokalni'
    elif 'NF' in file_name:
        df['tip_signala'] = 'nefokalni'
    else:
        df['tip_signala'] = 'nepoznato'

    data_frames.append(df)
else:
    print(f"Upozorenje: Naziv fajla je prazan: {file_path}")
except Exception as e:
    print(f"Greška pri obradi fajla {file_path}: {e}")

# Procena vremena završetka i prikaz na GUI interfejsu
elapsed_time = time.time() - start_time
avg_time_per_file = elapsed_time / (i + 1)
remaining_files = total_files - (i + 1)
estimated_remaining_time = avg_time_per_file * remaining_files
print(f"Procenjeno vreme završetka: {estimated_remaining_time:.2f} sekundi")

```

```

except Exception as e:
    print(f"Greška pri otvaranju ZIP fajla: {e}")

if data_frames:
    combined_df = pd.concat(data_frames, ignore_index=True)
    return combined_df
else:
    return None

def visualize_eeg_signals(combined_df, num_samples=1000):
    """Vizualizacija fokalnih i nefokalnih EEG signala."""

    if combined_df is None:
        print("Nema podataka za vizualizaciju.")
        return

    focal_signals = combined_df[combined_df['tip_signala'] == 'fokalni']
    nonfocal_signals = combined_df[combined_df['tip_signala'] == 'nefokalni']

    # Vizualizacija fokalnih signala
    if not focal_signals.empty:
        plt.figure(figsize=(15, 8))
        for i in range(16):
            plt.subplot(4, 4, i + 1)
            plt.plot(focal_signals[f'kanal_{i+1}'][:num_samples])
            plt.title(f'Kanal {i+1} (fokalni)')
        plt.tight_layout()
        plt.show()
    else:
        print("Nema fokalnih signala u skupu podataka.")

    # Vizualizacija nefokalnih EEG signala
    if not nonfocal_signals.empty:
        plt.figure(figsize=(15, 8))
        for i in range(16):
            plt.subplot(4, 4, i + 1)
            plt.plot(nonfocal_signals[f'kanal_{i+1}'][:num_samples])
            plt.title(f'Kanal {i+1} (nefokalni)')
        plt.tight_layout()
        plt.show()
    else:

```

```

print("Nema nefokalnih signala u skupu podataka.")

def select_zip_file():
    """Omogućava korisniku da odabere ZIP fajl preko GUI interfejsa."""
    root = tk.Tk()
    root.withdraw() # Sakrivanje glavnog prozora
    file_path = filedialog.askopenfilename(filetypes=[("ZIP files", "*.zip")])
    return file_path

if __name__ == "__main__":
    zip_file_path = select_zip_file()
    if zip_file_path:
        data = process_eeg_data(zip_file_path)
        if data is not None and not data.empty: # Dodata proveru da li je DataFrame
            prazan
            visualize_eeg_signals(data)
        else:
            print("Obrada podataka nije uspjela ili nema podataka za vizualizaciju.")
    else:
        print("Nije odabran ZIP fajl.")

```

Algoritam 13: Python kod fokalnih multikanalnih i nefokalnih multikanalnih EEG signala

Ovaj skup podataka predstavlja osnovu za validaciju i testiranje predloženog pristupa u analizi EEG signala u okviru ovog naučno-istraživačkog rada. Raznovrsnost i realističnost dostupnih i označenih podataka omogućavaju procenu performansi matematičkog modela LSTM veštačke neuronske mreže u različitim kliničkim scenarijima.

Korišćenje javno dostupnog UPF repozitorijuma podataka osigurava transparentnost i reproduktivnost istraživanja, što je od ključnog značaja za ovaj naučno-istraživački rad i u konanici naučnu zajednicu u celosti u pogledu budućih istraživanja u ovoj oblasti. Pošto je korišćen javni skup označenih podataka omogućeno je poređenje rezultata istraživanja ovog naučno-istraživačkog rada sa rezultatima prethodnih studija, što doprinosi validaciji i generalizaciji dobijenih rezultata eksperimenta iz ove doktorske disertacije.

4.3. Primena veštačke inteligencije u analizi EEG signala

Pregled različitih tehnika analize EEG signala, koje su prethodno sprovedi istraživači u svetu, jasno ukazuje na to da postoji prostor za poboljšanje, ali većina autora naglašava potencijal ovih tehnika kao pomoć, odnosno asistenciju kliničarima/lekarima pri dijagnostikovanju epilepsije (Acharya, Vinitha Sree, Swapna, Martis, & Suri, 2013).

Istraživanja su pokazala da primena naprednih tehnika obrade EEG signala, kao što su *wavelet* transformacija i tehnike mašinskog učenja podataka, poput veštačkih neuronskih mreža, može značajno poboljšati tačnost dijagnoze epilepsije kod pacijenata. *Wavelet*

transformacija predstavlja moćan matematički alat koji se sve češće primenjuje u analizi EEG signala, posebno u kontekstu detekcije epileptičkih napada.

Za razliku od Fourierove transformacije, koja razlaže signal na beskonačne sinusoide i pruža samo globalnu frekvencijsku informaciju, *Wavelet* transformacija koristi lokalizovane talasne funkcije (*Wavelets*) koje se mogu skalirati i translirati. Ovo omogućava simultanu analizu signala u vremenskom i frekvencijskom domenu, što je posebno važno za EEG signale koji su inherentno nestacionarni.

Primena *Wavelet* transformacije u analizi EEG signala omogućava da se EEG signal razloži na komponente koje odgovaraju različitim frekvencijskim opsezima (npr. delta, theta, alfa, beta, gama), što pak olakšava identifikaciju suptilnih promena i anomalija koje se javljaju tokom epileptičkih napada pacijenata (Acharya, Vinitha Sree, Swapna, Martis, & Suri, 2013).

Wavelet transformacija može otkriti kratkotrajne promene u EEG signalu koje bi mogle biti prisutne, ali manje evidentne u klasičnoj *Fourier* analizi, gde se time *Wavelet* transformacijom omogućava preciznija dijagnoza epileptičkih napada kod pacijenata. *Wavelet* transformacija se često kombinuje sa algoritmima mašinskog učenja kako bi se poboljšala automatska detekcija abnormalnosti u EEG signalima.

Kombinovanjem ovih metoda, istraživači mogu razviti matematičke modele koji efikasno filtriraju šum, izdvajaju relevantne karakteristike i na taj način poboljšavaju performanse dijagnostičkih sistema u celosti (Daubechies, 1992). Ova integracija omogućava da se primene napredne tehnike za obradu EEG signala i time postignu značajni rezultati u kliničkoj praksi pravilnom identifikacijom epileptičkih napada pacijenata, a samim time bi se smanjio broj lažnih pozitivnih i negativnih detekcija. Očigledno je da *Wavelet* transformacija pruža dodatni nivo detaljne analize EEG signala, omogućavajući otkrivanje i kvantifikaciju suptilnih promena u EEG signalu koje su ključne za preciznu dijagnostiku neuroloških poremećaja kod pacijenata. Ova metoda, zajedno sa integracijom mašinskog učenja podataka, čini temelj za razvoj naprednih sistema veštačke inteligencije koji mogu automatski prepoznati i klasifikovati epileptičke napade pacijenata.

Prethodno nevedene tehnike analize EEG signala omogućavaju automatsko otkrivanje i analizu suptilnih promena u EEG signalima koje ljudsko oko teško može primetiti. Kao što su prethodno citirani autori istakli, veštačka inteligencija ima potencijal da pomogne medicinskim stručnjacima da brže i preciznije analiziraju EEG podatke, kao i da pomogne u ranom otkrivanju anomalija u funkciji mozga pacijenata (Kaur, Diwakar, Kirandeep, Mirpuri, Tripathi, Chandra, & Gandhi, 2021).

Veštačka inteligencija može automatizovati proces analize EEG signala, čime se smanjuje vreme potrebno za dijagnozu i povećava njena tačnost. Algoritmi veštačke inteligencije mogu analizirati velike količine podataka i identifikovati obrasce koji ukazuju na prisustvo neuroloških poremećaja. Primena algoritama mašinskog učenja podataka (*Machine Learning*, ML) je prethodno umereno istražena za potrebe ovih oblasti medicine (Rasheed, Qayyum, Qadir, Sivathamboo, Kwan, Kuhlmann, O'Brien, & Razi, 2021), ali definitivno nije pronađeno savršeno rešenje.

Iako su algoritmi i tehnike mašinskog učenja podataka pokazali veliki potencijal u analizi EEG signala, još uvek postoje izazovi koje treba prevazići. Jedan od glavnih izazova je

nedostatak velikih, standardizovanih, anonimiziranih i označenih skupova podataka koji bi se mogli koristiti za obuku i validaciju novih i postojećih matematičkih modela.

Primena matematičkih modela LSTM veštačkih neuronskih mreža sa mehanizmom pažnje (Kaur et al., 2021) omogućila je detekciju epileptičnih napada sa 98% senzitivnošću na skupu od 1.000 snimaka iz baze CHB-MIT <https://physionet.org/content/chbmit/1.0.0/> (Guttag, J., 2010). Ključna inovacija bila je uvođenje vremenskog prozora od 5 sekundi za analizu kratkoročnih i dugoročnih zavisnosti. Primenjeni matematički model je nadmašio kliničare u brzini obrade (2 sekunde po snimku), ali je zahtevao 16 GB RAM računarske memorije, što ograničava primenu u realnom vremenu na slabijim kompjuterskim uređajima.

Rad Liu et al. (2020) kombinuje 3D konvolucije za prostornu analizu elektroda sa bidirekcionim LSTM slojevima za modelovanje vremenskih obrazaca. Ovaj pristup postigao je F1 vrednost od 97.4% na heterogenom skupu podataka sa 10 različitih bolnica, što ukazuje na izuzetnu robustnost matematičkog modela u uslovima inherentnog šuma. Nedostatak datog matematičkog modela je bio taj što je zahtevao 48 sati treninga na NVIDIA V100 GPU, što ističe potrebu za optimizacijom matematičkog modela radi korišćenje prihvatljivijih kompjuterskih resursa, te samim time primenu i na slabijim kompjuterskim uređajima koji su prisutni u kliničkoj praksi.

Pravilna primena sistema veštačke inteligencije na specifične izazove iz stvarnog sveta ipak ostaje izazov (Badi, Bouraima, Qiu, & Stevic, 2024). Tehnike optimizacije postaju neophodne sa napredovanjem i sve većom kompleksnošću savremenih algoritama veštačke inteligencije (Haq & Saqlain, 2023).

Sa povećanjem broja kontrolnih parametara, tačnost implementacionog procesa postaje preciznija, ali takođe znatno zavisi od određivanja optimalnih vrednosti. Ova optimizacija se može uspešno obaviti korišćenjem metaheurističkih algoritama optimizacije hiperparametara, gde najpoznatiji primeri su *Genetic Algorithm* (GA) (Katoch, Chauhan, & Kumar, 2021), *Particle Swarm Optimization* (PSO) (Kennedy & Eberhart, 1995), *Bat Algorithm* (BA) (Yang & Hossein Gandomi, 2012), *Brainstorm Optimization* (BSO) (Shi, 2011), *Chimp Optimization Algorithm* (ChOA) (Khishe & Mosavi, 2020), *Self-Adaptive Step-Size Search* (SASS) (Kumar, Das, & Zelinka, 2020) i *COLSHADE* (Gurrola-Ramos, Hernández-Aguirre, & Dalmau-Cedeño, 2020).

Činjenica je nijedan pristup nije optimalno prilagođen svakom problemu, te prema "*No Free Lunch*" teoremi (Wolpert & Macready, 1997), potrebni su budući temeljni eksperimenti da bi se poboljšali rezultati. Činjenica je da su metaheuristički algoritmi uspešno upareni sa modelima mašinskog učenja podataka u raznim oblastima, gde na primer u medicinskoj dijagnostici, ove metode su često primenjivane za podešavanje konvolucionih i drugih veštačkih neuronskih mreža za klasifikaciju MRI slika (Bezdan, Milosevic, K, Zivkovic, Bacanin, & Strumberger, 2021; Prakash, Kumar, 2022) i klasifikaciju rendgenskih (*X-ray*) slika (Zivkovic, Bacanin, Antonijevic, Nikolic, Kvascev, Marjanovic, & Savanovic, 2022).

Veliki uspeh je takođe postignut u prognoziranju vremenskih serija, kako bi se pomoglo u dijagnostici Parkinsonove bolesti (Cuk, Bezdan, Jovanovic, Antonijevic, Stankovic, Simic, Zivkovic, & Bacanin, 2024), predviđanju senzorskih podataka elektrokardiograma (Minic, Jovanovic, Bacanin, Stoean, Zivkovic, Spalevic, Petrovic, Dobrojevic, & Stoean, 2023) i

elektroencefalografije (Pilcevic, Djuric Jovicic, Antonijevic, Bacanin, Jovanovic, Zivkovic, Dragovic, & Bisevac, 2023). U istraživanju Katoch et al. (2021), genetski algoritam smanjio je dimenzionalnost EEG karakteristika sa 1.000 na 78 kritičnih parametara, održavajući 95% tačnost klasifikacije. Ovo je omogućilo korišćenje modela na Raspberry Pi 4 uređajima sa samo 2 GB RAM memorije. U prethodnim poglavljima je opisano koliko je problem adekvatnosti računarskih resursa ograničavajući faktor primene matematičkih modela veštačke inteligencije u realnim kliničkim uslovima u bolnicama, tako da ovi primeri daju nadu da će se kontinuirani monitoring pacijenta u jednom trenutku ostvariti sa računarskim uređajem prihvatljivih dimenzija i resursa.

Kao dodatne primere optimizacije matematičkog modela navodi se i primena algoritma optimizacije roja čestica (PSO) na LSTM arhitekturu veštačke neuronske mreže (Kennedy & Eberhart, 1995) koja smanjuje srednju kvadratnu grešku (*Root Mean Squared Error*, RMSE) a gde predviđanja napada se smanjuje za 22% kroz 50 iteracija, sa sledećom najboljom konfiguracijom:

- Broj slojeva: 4
- Stopa učenja: 0.0015
- Veličina batch-a: 64

Algoritam COLSHADE (Gurrola-Ramos et al., 2020) optimizovao je potrošnju energije matematičkog modela LSTM veštačke neuronske mreže za 35% bez gubitka tačnosti, kroz dinamičko prilagođavanje broja skrivenih jedinica tokom inferencije.

4.3.1. LSTM neuronska mreža i primena u analizi EEG signala

U prethodnim poglavljima ([Poglavlje 2.1](#)), detaljno su razmotrene osnove veštačkih neuronskih mreža i njihova primena u analizi EEG signala ([Poglavlje 4.3](#)). Posebna pažnja je posvećena rekurentnim veštačkim neuronskim mrežama (RNN), odnosno njihovoj sposobnosti da obrade velike skupove sekvencijalnih podataka, što je ključno za analizu vremenskih serija kao što su EEG signali (Acharya et al., 2013; Rasheed et al., 2021). Važno je napomenuti da standardne rekurentne veštačke neuronske mreže imaju problema sa dugoročnim zavisnostima u trening podacima, pre svega zbog problema nestajanja i eksploziranja gradijenata te time imaju problem u generalizaciji novih podataka koji su vremenski zavisni (Pascanu et al., 2013).

Posebna karakteristika matematičkih modela LSTM veštačkih neuronskih mreža leži upravo u specijalizovanim memorijskim ćelijama, kako kombinacija pojediničkih veštačkih neurona koje obrađuju i prenose informacije u pojedinačnim vremenskim trenucima obrade, gde se ovaj princip koristi za filtriranje i zadržavanje podataka kroz različite slojeve veštačke neuronske mreže.

Svaka memorijska ćelija sadrži tri ključna prolaza-neurona: prolaz za zaboravljanje (*forget gate*) (f_t), ulazni prolaz (*input gate*) (i_t) i izlazni prolaz (*output gate*) (o_t), gde t predstavlja trenutni vremenski korak. Ovi prolazi igraju kritičnu ulogu u kontroli stanja memorijske ćelije (S_t). Zajedno ove kapije LSTM veštačke neuronske mreže obavljaju tri osnovne funkcije, oblikujući ponašanje i evoluciju matematičkog modela LSTM veštačke

neuronske mreže dok obrada podataka napreduje kroz svaki vremenski korak (t) u sekvenci podataka, u našem slučaju EEG zapisa.

U početnoj fazi, model LSTM veštačke neuronske mreže određuje da li će zadržati ili odbaciti informacije iz prethodnog stanja ćelije, predstavljene kao S_{t-1} . Da bi se to postiglo, koristi se sigmoidna aktivaciona funkcija za obradu ulaznog niza podataka, efektivno ga mapirajući u opseg između 0 i 1. Ova sigmoidna aktivaciona transformacija čini osnovu za odlučivanje koje specifične informacije treba zadržati ili zaboraviti iz prethodnog stanja ćelije LSTM veštačke neuronske mreže. Izračunavanje rezultujućih vrednosti za *forget gates*, f_t , ostvaruje se koristeći sledeću formulu:

$$f_t = \text{sigmoid}(W_x x_t + W_f h_{t-1} + b_f) \quad (21)$$

gde su W_x i W_f matrice težinskih faktora, x_t je ulazni vektor u vremenskom koraku t , h_{t-1} je izlaz u vremenskom koraku $t - 1$, a b_f je vektor pristrasnosti (*bias*) u okviru prolaza za zaboravljenje (*forget gate*).

U sledećoj fazi koja se dešava u okviru LSTM ćelije, LSTM veštačka neuronska mreža koristi *Sigmoid* aktivacionu funkciju da odluči koje su informacije dovoljno značajne da budu uključene u stanje ćelije S_t . Pored procesa aktivacije, primenjuje se proces normalizacije gde se dolazni ulazi normalizuju na opseg između $[-1, 1]$ primenom hiperboličke tangentne (*Tanh*) transformacije. Ovaj postupak uključuje izračunavanje dve ključne vrednosti: kandidovanog broja $\tilde{S}_t$ i inicijalnog broja i_t , koje se koriste za ulazne prolaze. Ove vrednosti se dobijaju sledećim izračunavanjima:

$$\tilde{S}_t = \tanh(W_{\tilde{S},x} x_t + W_{\tilde{S},h} h_{t-1} + b_{\tilde{S}}) \quad (22)$$

$$i_t = \text{sigmoid}(W_{i,x} x_t + W_{i,h} h_{t-1} + b_i) \quad (23)$$

gde su $W_{\tilde{S},x}$, $W_{\tilde{S},h}$, $W_{i,x}$ i $W_{i,h}$ matrice težinskih faktora, a $b_{\tilde{S}}$ i b_i predstavljaju vektore pristrasnosti.

Nakon ove operacije, stanje S_t se određuje koristeći:

$$S_t = f_t \circ S_{t-1} + i_t \circ \tilde{S}_t \quad (24)$$

gde $\circ$ označava Hadamardov proizvod. Na kraju, izlaz h_t se izračunava koristeći *Sigmoid* i *Tanh* aktivacione funkcije i sledeće formule:

$$o_t = \text{sigmoid}(W_{o,x} x_t + W_{o,h} h_{t-1} + b_o) \quad (25)$$

$$h_t = o_t \circ \tanh(S_t) \quad (26)$$

gde $W_{o,x}$ i $W_{o,h}$ predstavljaju matrice težina, a b_o označava vektor pristrasnosti (*bias*) izlaznog prolaza (*output gate*).

4.3.2. Algoritam varijabilne pretrage susedstva sa dinamičkom promenom strategije

U sledećem poglavlju ovog naučno-istraživačkog rada, nadovezujući se na teorijske osnove metaheurističkih algoritama ([Poglavlje 2.3](#)), predloženi su originalni algoritmi pretrage

koji će poslužiti kao osnova za modifikovane verzije koje se implementirane i testirane u okviru eksperimentalne postavke ovog naučno-istraživačkog rada. Nakon toga, detaljno je opisan modifikovani algoritam pretrage varijabilnog susedstva zajedno sa matematičkom osnovom za predložene mehanizme.

4.3.3. Osnovni algoritam pretrage varijabilnog susedstva

Osnovni algoritam pretrage varijabilnog susedstva, kao što je opisano u [Poglavlju 4.3.2](#), u osnovi uključuje nekoliko faza za poboljšanje početnog seta prvobitno nasumično generisanih rešenja. Ove faze uključuju pre svega sledeće protokole-procese:

- *Shaking*
- Protokol poboljšanja
- Promenu okruženja

Gore navedene faze će se naizmenično izvršavati dok se ne ispuni definisani kriterijum zaustavljanja.

Shaking: Cilj *shaking*-a je da se reši problem lokalnih minimuma. Dat je pretraživački prostor $N = N_1, \dots, N_{k_{max}}$ gde svaki N predstavlja operator koji mapira agenta x u dato okruženje. Važno je napomenuti da redosled ovih operatora određuje redosled evaluacije okruženja. Praktično *shaking* procedura uključuje nasumičan izbor strukture okruženja $N_l(x)$.

Promena okruženja: Ideja iza promene okruženja je da se rešenja pretrage usmere ka istraživanju pretraživačkog prostora. Odluke o tome koje okruženje treba istražiti, kao i da li se rešenje prihvata kao trenutno najbolje rešenje, se donosi prema sledećim popularnim strategijama pretrage:

- **Sekvencijalna promena okruženja** (Todosijevic et al., 2017a): Ako trenutno rešenje pokazuje znake poboljšanja unutar određene strukture okruženja, pretraga će se nastaviti unutar početne strukture okruženja ažuriranog trenutnog rešenja, prema unapred definisanom redosledu. U odsustvu takvog poboljšanja, pretraga će se nastaviti prelaskom na sledeću strukturu okruženja, prateći prethodno definisanu sekvencu.
- **Ciklična promena okruženja** (Todosijevic et al., 2017b): Pretraga će preći na narednu strukturu okruženja na listi, bez obzira na to da li je u datom okruženju uočeno poboljšanje ili nije.
- **Promena okruženja u cevima** (Todosijevic et al., 2017c): Ako se dogodi poboljšanje trenutnog rešenja unutar specifičnog okruženja funkcije, istraživanje će se nastaviti unutar tog istog okruženja.
- **Izmenjena promena okruženja** (Brimberg et al., 2015): Prihvatanje novog trenutnog rešenja nije ograničeno samo na ona koja donose poboljšanje trenutnog rešenja, mogu se uključiti i rešenja koja ne pokazuju poboljšanje. Primarni cilj ove promene okruženja je olakšavanje istraživanja prostora rešenja (dolina) funkcije koje su udaljene od trenutnog rešenja.

Protokol poboljšanja: Tokom protokola poboljšanja, algoritam pretrage varijabilnog susedstva će istraživati lokalna okruženja $N_{(x)}$. Ovo se radi za trenutno rešenje u svakoj iteraciji, gde se biraju se bolja rešenja x' i lokacije rešenja funkcije će se ažurirati. Dve najčešće strategije su strategije prvog i najboljeg poboljšanja.

Strategija prvog poboljšanja postavlja novo najbolje rešenje čim se ono odredi, dok strategija najboljeg poboljšanja postavlja najbolje rešenje nakon evaluacije populacije rešenja i određivanja optimalnog. Treba napomenuti da se algoritam pretrage varijabilnog susedstva može proširiti kako bi koristio metaheurističke algoritme za lokalne strategije pretrage.

Osnovni algoritam pretrage varijabilnog susedstva se naizmenično smenjuje između jednostavne lokalne pretrage i *shaking* procedure. Ovi koraci se izvode dok se ne dostigne kriterijum zaustavljanja. Praktično kriterijum zaustavljanja može biti zadat broj iteracija ili maksimalno dozvoljeni broj CPU ciklusa.

4.3.4. Nedostaci osnovnog algoritam pretrage varijabilnog susedstva i predložene izmene

Kao što je razmatrano u [Poglavlju 4.3.3](#), osnovni algoritam pretrage varijabilnog susedstva, iako efikasan, ima određene nedostatke, posebno u pogledu istraživanja prostora rešenja funkcije. Algoritam pretrage varijabilnog susedstva kao okvir je pogodan za mnoge izazove, a njegova proširiva priroda ostavlja značajan prostor za poboljšanje samog matematičkog algoritma pretrage.

Nakon predviđenih temeljnih testiranja korišćenjem standardnih CEC (*Congress on Evolutionary Computation*, CEC) funkcija (Cheng et al., 2018), očekuje se da će ovo biti dodatno potvrđeno. Zbog ograničenja dužine rukopisa disertacije, rezultati CEC testiranja će biti izostavljeni iz ovog naučno-istraživačkog rada.

Algoritam pretrage varijabilnog susedstva je pre svega fokusiran na eksploataciju, više nego u odnosu na samo istraživanje, u okviru homogene populacije i prevremene konvergencije. Shodno tome, početne pozicije rešenja definitivno će igrati ključnu ulogu u određivanju konačnih rezultata. Ovo istraživanje ima za cilj da prošire osnovni algoritam pretrage varijabilnog susedstva rešavanjem problema ograničenog istraživanja. Cilj je postizanje dovoljne raznovrsnosti populacije tokom inicijalizacije i izvršavanja. Da bi se to postiglo, uvešće se tri modifikacije osnovnog algoritma pretrage varijabilnog susedstva.

Prva modifikacija će uključivati uvođenje tehnike haotičnog elitnog učenja, što je prethodno opisano u [Poglavlju 2.4](#). Ova unapređenja imaju za cilj da poboljšaju pojedinačna rešenja koristeći haotične sekvence za sintezu novih pojedinaca u njihovoj neposrednoj blizini.

Prihvatanjem ovog pristupa, očekuje se da održi raznovrsnost populacije i u tom slučaju je mnogo lakše izaći iz suboptimalnih regija optimizacije funkcije. Predložena izmena se fokusira na korišćenje logističke mape, koja je predstavljena sledećom jednačinom (27):

$$C_{i+1} = 4 \times C_i \times (1 - C_i) \quad (27)$$

gde i predstavlja broj iteracija, C_i predstavlja haotičnu vrednost za iteraciju i , dok je početna vrednost C_0 proizvoljno određena unutar intervala $[0, 1]$. Najbolje rešenje X_i se ažurira korišćenjem jednačine (28):

$$X'_{i,j} = X_{i,j} + rand(\times C_i - 1) \quad (28)$$

gde $X'_{i,j}$ označava j -tu komponentu najboljeg agenta.

Da bi se poboljšalo ažuriranje pozicije, algoritam uvodi *Lévy flight* mehanizam. Ovo će omogućiti svakom agentu da povremeno preduzme duge letove optimizacije, olakšavajući bekstvo iz suboptimalnih regija funkcije i poboljšavajući ukupnu performansu rešenja optimizacije.

Kako algoritam pretrage varijabilnog susedstva konvergira i fokusira se na obećavajuću oblast, dužina leta agenta optimizacije će se postepeno smanjivati tokom vremena.

$$X'_{i,j} = X_{i,j}^{best} \times L \times e \quad (29)$$

$$e = \frac{\vec{a}}{2} \quad (30)$$

u ovim jednačinama $X'_{i,j}$ označava komponente rešenja koje se menjaju, $X_{i,j}^{best}$ je referentni najbolji agent, e je faktor skaliranja, $\vec{a}$ se određuje prema sledećoj jednačini:

$$\vec{a} = 1 + \cos\left(\pi + \frac{t}{T}\right) \quad (31)$$

gde je t trenutna iteracija, dok T označava maksimalni broj iteracija. Vrednost L je *Lévy* distribucija leta određena prema sledećoj jednačini:

$$L = s \times \frac{\mu \times \phi}{|v|^{\frac{1}{\tau}}} \quad (32)$$

u ovoj jednačini τ označava *Lévy* indeks leta, S je konstanta koja će se postaviti na 0.01 da bi sprečili prekomerno udaljene skokove, dok će μ i v nasumično biti izabrane vrednosti iz opsega $[0, 1]$. Parametar ϕ će se odrediti prema sledećoj jednačini:

$$\phi = \left(\frac{\Gamma(1+\tau) \times \sin\left(\frac{\pi \times \tau}{2}\right)}{\Gamma\left(\frac{1+\tau}{2}\right) \times \tau \times 2^{\frac{\tau-1}{2}}} \right)^{\frac{1}{\tau}} \quad (33)$$

gde se Γ može odrediti prema sledećoj jednačini:

$$\Gamma(1 + \tau) \int_0^{\infty} x^{\tau} e^{-x} dx \quad (34)$$

Na kraju, treća izmena formuliše hibridizaciju niskog nivoa sa *Firefly* algoritmom (*Firefly Algorithm*, FA) (Yang & Slowik, 2020). Mehanizam pretrage *Firefly* algoritmom opisan jednačinom (35) je uključen u algoritam kako bi se povećalo istraživanje:

$$X_i^{t+1} = X_i^t + \beta_0 \cdot e^{-\gamma R_{i,j}^2} (X_j^t - X_i^t) + \alpha^t (\kappa - 0.5) \quad (35)$$

gde je varijabla za nasumičnost definisana kao α , κ predstavlja pseudo-slučajan broj uzet iz Gausove distribucije. Varijabla γ označava karakteristike medijuma, β_0 je maksimalna privlačnost pojedinačnog agenta, a $R_{i,j}$ je udaljenost između agenata.

Da bi se omogućilo da oba algoritma optimizacije podjednako doprinesu procesu optimizacije, uvešće se dodatni parametar podešavanja pretrage θ . Dok je vrednost θ veća od trenutne iteracije t , za svaku komponentu rešenja koristiće se pseudo-slučajan izbor da se odredi koji algoritam optimizacije će biti korišćen.

Nasumična vrednost će se birati iz uniformne distribucije između $[0, 1]$. Ako je izabrana vrednost iznad 0.5, koristiće se *Firefly* algoritam pretraga.

U ovom okruženju, vrednost θ će se empirijski odrediti da bi dala najbolje rezultate pri $\theta = 3$. Rezultujući algoritam pretrage varijabilnog susedstva se naziva VNS sa dinamičkom promenom strategije (VNS-DS). Pseudokod za rezultujući algoritam VNS-DS dat je u nastavku teksta:

Algoritam 1 Pseudokod VNS-DS

```

1: Postavi vrednosti parametara
2: Generiši populaciju  $X$  putem haotične inicijalizacije
3: dok ( $t < T$ ) radi
4:         Odredi fitnes svih agenata i sačuvaj najboljeg
5:         Ponovo izračunaj ES
6:         za svakog agenta u populaciji radi
7:             ako je  $t > \theta$  onda
8:                 Koristi odgovarajući VNS mehanizam pretrage
9:             inače
10:                Generiši nasumičnu vrednost  $R$ 
11:                ako je  $R < 0.5$  onda
12:                    Koristi odgovarajući VNS mehanizam pretrage
13:                inače
14:                    Koristi odgovarajući FA mehanizam pretrage
15:                kraj ako
16:            kraj ako
17:        kraj za
18:         $t = t + 1$ 
19: kraj dok
20: Vрати agenta sa najboljim performansama

```

Algoritam 14: Pseudokod za VNS-DS optimizaciju


U nastavku se nalazi primer implementacije prethodno opisanog algoritma varijabilne pretrage susedstva sa dinamičnom promenom strategije (VNS-DS) gde se kao ulazni parametri koriste javno dostupni skup označenih podataka repozitorijuma Univerziteta Pompeu Fabra (<https://www.upf.edu>, UPF) u formatu koji dostupan na sledećoj web adresi <https://www.upf.edu/web/ntsa/downloads>, gde svaki ZIP fajl sadrži 8 po foldera. Svaki folder

sadrži po 120 TXT/MatLab fajlova koji su korišćeni za treniranje matematičkog modela LSTM veštačke neuronske mreže.

Svaki fajl sadrži jedan višekanalni signal sa 16 kanala, što odgovara 16 dostupnih kanala za snimanje za svaku hibridnu dubinsku elektrodu (za TXT fajlove kolone su odvojene razmakom). EEG signali snimljeni makro elektrodama nalaze se u kolonama od 1 do 8, pri čemu su kanali koji su najunutrašnji i najspoljašnji kanali prikazani od 1 do 8. EEG signali snimljeni mikro žicama nalaze se u kolonama od 9 do 16. Svi fajlovi imaju 65.536 redova. Uzastopni redovi odgovaraju uzastopnim uzorcima i dati fajlovi ne sadrže zaglavlja.

Fajlovi sa oznakama F i NF sadrže fokalne i nefokalne višekanalne signale, respektivno. Imena fajlova imaju slovo koje označava fazu ciklusa spavanja-budnosti u kojoj su EEG signali snimljeni, i to: stanje budnosti (W), REM spavanje (R), lagani san (S1) i sporo-talasno spavanje (S2). Da bi se izbegla prekomerna složenost, faze sporo-talasnog spavanja N2 i N3 su spojene u set S2. Broj u imenu fajla odgovara indeksu višekanalnog signala sadržanog u tom fajlu.

Na bazi datog ulaznog skupa podataka, razvijen je bazični VNS Optimizer GUI koristeći Python koji omogućava da se učitaju dati fajlovi, parsiraju i pokrene algoritam varijabilne pretrage susedstva sa dinamičnom promenom strategije i primenjenom optimizacijom prema prethodno definisanom pseudokodu.



Slika 18: VNS-DS Optimizer GUI

Izvorni Python kod za "Slika 18. VNS-DS Optimizer GUI (adaptirano prema eksperimentalnoj simulaciji, Univerzitet Pompeu Fabra (<https://www.upf.edu>, UPF), repozitorijum <https://www.upf.edu/web/ntsa/downloads>. (*The Bonn-Barcelona micro-, and macro- EEG database*)"

```
import tkinter as tk
from tkinter import filedialog, messagebox, ttk
import numpy as np
import pandas as pd
```

```

import zipfile
import time
import sys
import psutil
import threading
import tensorflow as tf

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import LSTM, Dense
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import cohen_kappa_score, accuracy_score
from matplotlib.backends.backend_tkagg import FigureCanvasTkAgg
import matplotlib.pyplot as plt

# Konfiguracija TensorFlow-a za optimizaciju memorije
gpus = tf.config.experimental.list_physical_devices('GPU')
if gpus:
    try:
        for gpu in gpus:
            tf.config.experimental.set_memory_growth(gpu, True)
    except RuntimeError as e:
        print(e)
tf.config.optimizer.set_jit(True)

class NeuroOptimizerApp(tk.Tk):
    def __init__(self):
        super().__init__()
        self.title("VNS-DS LSTM Optimizer")
        self.geometry("1200x800")
        self.protocol("WM_DELETE_WINDOW", self.on_close)

        self.data_dict = {}
        self.zip_file_path = None
        self.stop_flag = False
        self.progress_var = tk.DoubleVar(value=0)
        self.best_params = None
        self.fitness_history = []
        self.best_agents_history = []
        self.population = None # Populacija agenata

        self._setup_ui()
        self._setup_memory_monitor()

```

```

sys.stdout = self.StdoutRedirector(self.console_text)

# --- GUI interfejs deo ---
def _setup_ui(self):
    self._create_control_panel()
    self._create_visualization()
    self._create_console()
    self._create_save_buttons()

def _create_control_panel(self):
    control_frame = ttk.LabelFrame(self, text="Controls")
    control_frame.pack(side=tk.LEFT, fill=tk.Y, padx=10, pady=10)
    self._add_data_controls(control_frame)
    self._add_vns_params(control_frame)
    self._add_progressBars(control_frame)

def _add_data_controls(self, parent):
    btn_frame = ttk.Frame(parent)
    btn_frame.pack(pady=10)
    ttk.Button(btn_frame, text="Load ZIP",
command=self.load_data).pack(side=tk.LEFT, padx=5)
    ttk.Button(btn_frame, text="Start",
command=self.start_optimization).pack(side=tk.LEFT, padx=5)
    ttk.Button(btn_frame, text="Stop",
command=self.stop_optimization).pack(side=tk.LEFT, padx=5)
    ttk.Button(btn_frame, text="Show EEG",
command=self.show_eeg_signals).pack(side=tk.LEFT, padx=5)

def _add_vns_params(self, parent):
    params_frame = ttk.LabelFrame(parent, text="VNS Parameters")
    params_frame.pack(pady=10, fill=tk.X)
    self.vns_params = {}
    params = ["Pop Size", "Max Iter", "Theta", "Levy E", "FA Alpha", "FA Gamma", "FA
Beta0"]
    defaults = [30, 100, 3, 0.1, 0.1, 1.0, 1.0]
    for i, param in enumerate(params):
        ttk.Label(params_frame, text=param).grid(row=i, column=0, sticky=tk.W)
        entry = ttk.Entry(params_frame)
        entry.insert(0, str(defaults[i]))
        entry.grid(row=i, column=1)
        self.vns_params[param] = entry

```

```

def _add_progressBars(self, parent):
    ttk.Label(parent, text="Optimization Progress").pack(pady=(10, 0))
    self.progress = ttk.Progressbar(parent, orient=tk.HORIZONTAL,
mode='determinate', variable=self.progress_var)
    self.progress.pack(fill=tk.X, pady=5)
    self.mem_label = ttk.Label(parent, text="Memory: 0%")
    self.mem_label.pack()

def _create_visualization(self):
    viz_frame = ttk.Frame(self)
    viz_frame.pack(side=tk.RIGHT, fill=tk.BOTH, expand=True, padx=10, pady=10)
    self.figure = plt.Figure(figsize=(10, 6), dpi=100)
    self.canvas = FigureCanvasTkAgg(self.figure, master=viz_frame)
    self.canvas.get_tk_widget().pack(fill=tk.BOTH, expand=True)
    self.ax_opt = self.figure.add_subplot(211)
    self.ax_opt.set_title("Optimization Progress")
    self.ax_opt.set_xlabel("Iteration")
    self.ax_opt.set_ylabel("Fitness")
    self.ax_eeg = self.figure.add_subplot(212)
    self.ax_eeg.set_title("EEG Signals")
    self.ax_eeg.set_xlabel("Time")
    self.ax_eeg.set_ylabel("Amplitude")

def _create_console(self):
    console_frame = ttk.LabelFrame(self, text="Console")
    console_frame.pack(side=tk.BOTTOM, fill=tk.BOTH, expand=True, padx=10,
pady=10)
    self.console_text = tk.Text(console_frame, wrap=tk.WORD)
    scrollbar = ttk.Scrollbar(console_frame, command=self.console_text.yview)
    self.console_text.configure(yscrollcommand=scrollbar.set)
    scrollbar.pack(side=tk.RIGHT, fill=tk.Y)
    self.console_text.pack(fill=tk.BOTH, expand=True)

def _create_save_buttons(self):
    save_frame = ttk.Frame(self)
    save_frame.pack(side=tk.BOTTOM, fill=tk.X, padx=10, pady=5)
    ttk.Button(save_frame, text="Save Optimization Plot",
command=self.save_optimization_plot).pack(side=tk.LEFT, padx=5)
    ttk.Button(save_frame, text="Save EEG Plot",
command=self.save_eeg_plot).pack(side=tk.LEFT, padx=5)

```

```

def _setup_memory_monitor(self):
    def monitor():
        while True:
            mem = psutil.virtual_memory()
            self.mem_label.config(text=f"Memory: {mem.percent}%")
            if mem.percent > 85 and not self.stop_flag:
                self.stop_optimization()
                messagebox.showwarning("Memory", "High memory usage! Stopped
optimization.")
            time.sleep(1)
    threading.Thread(target=monitor, daemon=True).start()

def load_data(self):
    file_path = filedialog.askopenfilename(filetypes=[("ZIP files", "*.zip")])
    if file_path:
        self.zip_file_path = file_path
        try:
            with zipfile.ZipFile(file_path, 'r') as zip_ref:
                txt_files = [f for f in zip_ref.namelist() if f.endswith('.txt')]
                self.data_dict = {"EEG": txt_files}
                print(f"Loaded {len(txt_files)} EEG files from ZIP")
                messagebox.showinfo("Success", f"Loaded {len(txt_files)} EEG files from ZIP")
        except Exception as e:
            print(f"Error loading ZIP: {e}")
            messagebox.showerror("Error", str(e))

# --- Funkcije za optimizaciju ---
def chaotic_initialization(self, pop_size, dim, c0=0.7):
    # Generiše populaciju X koristeći logističku mapu
    population = np.zeros((pop_size, dim))
    c = c0
    for i in range(pop_size):
        for j in range(dim):
            c = 4 * c * (1 - c) # logistička mapa
            population[i, j] = c
    return population

def evaluate_fitness(self, agent):
    # Funkcija koja ima globalni optimum kada su sve komponente 0.5
    # Optimalno rešenje: agent = [0.5, 0.5, ..., 0.5]

```

```

    return -np.sum((agent - 0.5)**2)

def vns_search(self, agent):
    # Shaking i protokol poboljšanja: mala slučajna perturbacija
    perturbation = np.random.uniform(-0.1, 0.1, size=agent.shape)
    return agent + perturbation

def fa_search(self, agent, best_agent, fa_params, dim):
    # Firefly mehanizam: agent se pomera ka najboljem uz dodatak slučajnosti
    beta0 = fa_params.get("FA Beta0", 1.0)
    gamma = fa_params.get("FA Gamma", 1.0)
    alpha = fa_params.get("FA Alpha", 0.1)
    distance = np.linalg.norm(agent - best_agent)
    attractiveness = beta0 * np.exp(-gamma * distance**2)
    return agent + attractiveness * (best_agent - agent) + alpha *
(np.random.rand(dim) - 0.5)

def start_optimization(self):
    if not self.data_dict or self.zip_file_path is None:
        messagebox.showerror("Error", "Please load data first")
        return
    self.stop_flag = False
    self.fitness_history = []
    self.best_agents_history = []
    threading.Thread(target=self._run_optimization).start()

def _run_optimization(self):
    # Učitavanje parametara iz GUI-a
    pop_size = int(self.vns_params["Pop Size"].get())
    max_iter = int(self.vns_params["Max Iter"].get())
    theta = int(self.vns_params["Theta"].get())
    levy_e = float(self.vns_params["Levy E"].get())
    fa_alpha = float(self.vns_params["FA Alpha"].get())
    fa_gamma = float(self.vns_params["FA Gamma"].get())
    fa_beta0 = float(self.vns_params["FA Beta0"].get())
    dim = 10 # Dimenzija rešenja

    fa_params = {"FA Alpha": fa_alpha, "FA Gamma": fa_gamma, "FA Beta0": fa_beta0}

```

```

print(f"Starting optimization with parameters:\nPop Size: {pop_size}, Max Iter:
{max_iter}, Theta: {theta}, Levy E: {levy_e}, FA Alpha: {fa_alpha}, FA Gamma: {fa_gamma},
FA Beta0: {fa_beta0}")

```

```

# 1: Generiši populaciju X putem haotične inicijalizacije
self.population = self.chaotic_initialization(pop_size, dim, c0=0.7)
chaotic_ES = 0.7 # početna haotična vrednost

```

```

best_fitness = -np.inf
best_agent = None

```

```

# 3: Glavna petlja dok (t < T) radi
for t in range(max_iter):
    if self.stop_flag:
        break

```

```

# 4: Odredi fitnes svih agenata i sačuvaj najboljeg
fitnesses = np.array([self.evaluate_fitness(agent) for agent in self.population])
iteration_best_index = np.argmax(fitnesses)
iteration_best_fitness = fitnesses[iteration_best_index]
iteration_best_agent = self.population[iteration_best_index].copy()

```

```

if iteration_best_fitness > best_fitness:
    best_fitness = iteration_best_fitness
    best_agent = iteration_best_agent.copy()
    self.best_agents_history.append((t, best_agent))

```

```

self.fitness_history.append(best_fitness)

```

```

# 5: Ponovo izračunaj ES pomoću logističke mape
chaotic_ES = 4 * chaotic_ES * (1 - chaotic_ES)

```

```

# 6: Za svakog agenta u populaciji:
for i in range(pop_size):
    current_agent = self.population[i]
    if t > theta:
        # 7: Ako je t >  $\theta$ , koristi VNS mehanizam
        new_agent = self.vns_search(current_agent)
    else:
        # 9: Inače, generiši nasumičnu vrednost R
        R = np.random.uniform(0, 1)

```

```

    if R < 0.5:
        # 11: Ako je R < 0.5, koristi VNS mehanizam
        new_agent = self.vns_search(current_agent)
    else:
        # 14: Inače, koristi FA mehanizam
        new_agent = self.fa_search(current_agent, best_agent, fa_params, dim)
    # Ažuriranje rešenja korišćenjem haotičnog elitnog učenja (jednačina 28)
    new_agent = new_agent + np.random.rand(dim) * (chaotic_ES - 1)
    self.population[i] = new_agent

    # 18: t = t + 1 (u petlji je implicitno)
    self.after(0, lambda v=(t + 1) / max_iter * 100: self.progress_var.set(v))
    self.after(0, self._update_fitness_plot, self.fitness_history)
    print(f"Iteration {t + 1}/{max_iter}, Best Fitness: {best_fitness:.4f}")
    time.sleep(0.1)

    # 20: Vрати agenta sa najboljim performansama
    self.best_params = best_agent
    self._show_optimized_params(best_agent)
    print("Optimization finished successfully!")
    messagebox.showinfo("Optimization Complete", "Optimization finished
successfully!")

def _update_fitness_plot(self, fitness_history):
    self.ax_opt.clear()
    self.ax_opt.plot(fitness_history, label="Best Fitness", color="blue")
    # Prikaz tačaka najboljih agenata
    for iteration, agent in self.best_agents_history:
        self.ax_opt.plot(iteration, fitness_history[iteration], 'ro', markersize=5,
label=f"Best at {iteration}")
        handles, labels = self.ax_opt.get_legend_handles_labels()
        by_label = dict(zip(labels, handles))
        self.ax_opt.legend(by_label.values(), by_label.keys())
    self.canvas.draw()

def _show_optimized_params(self, best_agent):
    if best_agent is None:
        print("No optimized parameters to show.")
        messagebox.showinfo("Optimized Parameters", "No optimized parameters
found.")
    return

```

```

param_str = "\n".join([f"Param {i + 1}: {val:.4f}" for i, val in enumerate(best_agent)])
print(f"Best Parameters:\n{param_str}")
messagebox.showinfo("Optimized Parameters", f"Best Parameters:\n{param_str}")

def show_eeg_signals(self):
    if not self.data_dict or self.zip_file_path is None:
        messagebox.showerror("Error", "Please load data first")
        return
    try:
        with zipfile.ZipFile(self.zip_file_path, 'r') as zip_ref:
            txt_files = [f for f in zip_ref.namelist() if f.endswith('.txt')]
            if not txt_files:
                messagebox.showerror("Error", "No .txt files found in the loaded ZIP.")
                return
            self.ax_eeg.clear()
            lines = []
            labels = []
            for file_name in txt_files[:10]:
                with zip_ref.open(file_name) as file:
                    df = pd.read_csv(file, sep='\t', header=None)
                    for col in df.columns:
                        line, = self.ax_eeg.plot(df[col], label=f"{file_name} - Channel {col}")
                        lines.append(line)
                        labels.append(f"{file_name} - Channel {col}")
            self.ax_eeg.legend(lines, labels, loc='upper center', bbox_to_anchor=(0.5, -
0.15),
                                fancybox=True, shadow=True, ncol=5)
            self.canvas.draw()
    except Exception as e:
        messagebox.showerror("Error", f"Error loading EEG data: {e}")
        print(f"Error loading EEG data: {e}")

def stop_optimization(self):
    self.stop_flag = True
    print("Optimization stopped by user")

def on_close(self):
    self.stop_optimization()
    self.destroy()

class StdoutRedirector:

```

```

def __init__(self, text_widget):
    self.text_space = text_widget
def write(self, string):
    self.text_space.insert('end', string)
    self.text_space.see('end')
    self.text_space.update_idletasks()
def flush(self):
    pass

def save_optimization_plot(self):
    file_path = filedialog.asksaveasfilename(defaultextension=".png",
filetypes=[("PNG files", "*.png")])
    if file_path:
        self.figure.axes[0].figure.savefig(file_path)
        messagebox.showinfo("Save", "Optimization plot saved successfully!")

def save_eeg_plot(self):
    file_path = filedialog.asksaveasfilename(defaultextension=".png",
filetypes=[("PNG files", "*.png")])
    if file_path:
        self.figure.axes[1].figure.savefig(file_path)
        messagebox.showinfo("Save", "EEG plot saved successfully!")

if __name__ == "__main__":
    app = NeuroOptimizerApp()
    app.mainloop()

```

Algoritam 15: Python kod za Optimizer VNS-DS GUI

4.4. Primeri primene LSTM-VNS iz kliničke prakse

Dinamička analiza veštačkih neuronskih mreža je dovedena u centar pažnje nedavno, kao što pokazuju prethodno nevedeni brojni naučno-istraživački radovi koji su opisani u prethodnim poglavljima. Kao primer prethodnih naučnih radova može se navesti i bipartitna sinhronizacija koja se oslanja na dualni metod baziran na događajima je detaljno istražena (Song, Wu, Song, Zhang, & Stojanovic, 2023). S druge strane, autori (Du, Xie, Qu, Hu, & Stojanovic, 2024) su ispitivali dinamički metod zasnovan na događajima kako bi se rešili problemi *fuzzy* konsenzusa koji su obično prisutni u nelinearnim višezastupničkim okvirima. Kombinacija tehnike vremenskog uzorkovanja i prostorne metode podele, koja smanjuje troškove merenja i održava nivoe performansi procenitelja, takođe je diskutovana i analizirana od strane drugih autora (Song, Peng, Song, & Stojanovic, 2024).

Pored napredovanja istraživanja u ovoj oblasti, značajan prostor za nova naučna istraživanja ostaje u domenu korišćenju matematičkih modela LSTM veštačkih neuronskih mreža, pre svega optimizovanih putem osnovnih i naprednih algoritama varijabilne pretrage susedstva, a za svrhu detekcije anomalija u EEG signalima. Inovativna kombinacija obuke i optimizacije veštačkih neuronskih mreža otvara put značajnom napretku u identifikaciji anomalija u EEG signalima, i na taj način predstavljajući novi i potencijalno efikasan pristup u kompleksnoj dijagnostici i praćenju moždanih anomalija kod pacijenata.

Kao deo novih napora u oblastima medicinske neurodijagnostike treba napomenuti i razmatranja alternativnih matematičkih modela sposobnih za obradu sekvencijalnih podataka, kao što su jednostavne rekurentne veštačke neuronske mreže, kao i rekurentne veštačke neuronske mreže sa slojevima pažnje i *echo-state* veštačke neuronske mreže. Preliminarne simulacije i prepoznavanje postojećeg jaza u literaturi usmeravaju fokus ka pristupu koji objedinjuje matematičke modele LSTM veštačkih neuronskih mreža optimizovane osnovnim i naprednim algoritmitma varijabilne pretrage susedstva, koji u velikom broju slučajeva je ocenjen kao najperspektivniji pristup u analizi vremenskih serija EEG signala.

Glavni fokus ovog naučno-istraživačkog rada jeste upravo pokušaj sinteze i kreiranja tkzv. *lightweight* modela koji su efikasni i sposobni za rad u realnom vremenu i primenu u kliničkoj praksi sa minimalnim računarskim resursima.

U poređenju sa tradicionalnim metodama i jednostavnim rekurentnim neuronskim mrežama, rekurentne neuronske mreže sa mehanizmima pažnje, *echo-state* neuronske mreže i LSTM neuronske mreže optimizovane algoritmom varijabilne pretrage susedstva pokazuju superiornost u obradi sekvencijalnih podataka EEG signala i optimizaciji performansi matematičkog modela. Preliminarni rezultati simulacija ukazuju na superiornost pristupa matematičkog modela LSTM veštačke neuronske mreže optimizovane algoritmom varijabilne pretrage susedstva (LSTM-VNS), posebno u kontekstu analize EEG signala u realnom vremenu, i to pre svega u domenima:

- **Detekcija epileptičkih napada:** LSTM-VNS matematički modeli se mogu koristiti za automatsku detekciju epileptičkih napada u realnom vremenu. Ovo omogućava kontinuirano praćenje pacijenata i pravovremeno reagovanje na pojavu epileptičnog napada, što je od vitalnog značaja za prevenciju komplikacija kao i 24x7 monitoring pacijenata.
- **Dijagnostika poremećaja spavanja:** Analiza EEG signala tokom spavanja uz pomoć matematičkih modela LSTM-VNS veštačkih neuronskih mreža može pomoći u dijagnostici različitih poremećaja spavanja, poput apneje u snu, insomnije i narkolepsije kod pacijenata.
- **Praćenje oporavka nakon moždanog udara:** matematički modeli LSTM-VNS veštačkih neuronskih mreža se mogu koristiti za praćenje neurološkog oporavka pacijenata nakon moždanog udara. Analiza EEG signala omogućava procenu neuroplastičnosti i efikasnosti rehabilitacionih programa.
- **Neurofeedback terapija:** U *neurofeedback* terapiji, pacijenti uče da kontrolišu svoje moždane talase uz pomoć povratnih informacija iz EEG signala. Matematički modeli LSTM-VNS veštačkih neuronskih mreža mogu poboljšati efikasnost ove

terapije, omogućavajući precizniju analizu i interpretaciju EEG signala kod pacijenata.

Primena matematičkih modela veštačke inteligencije u medicinskoj neurodijagnostici podleže strogim regulatornim zahtevima. U Evropi je na primer definisan pseudoanonimizacija EEG snimaka kriptografskim hash funkcijama (SHA-256) kao standardna praksa, dok je u SAD, FDA odobrila NeuroPace RNS sistem na osnovu opsežnih kliničkih ispitivanja. Matematički modeli sistema veštačke inteligencije za medicinsku dijagnostiku moraju prema FDA proći fazu III kliničkih ispitivanja sa minimalno 300 pacijenata u 3 nezavisna centra (Primer: Odobrenje FDA za NeuroPace RNS 2023. godine zahtevalo je 18-mesečnu studiju sa 92% senzitivnošću).

Što se tiče verifikacije i produkcije sistema veštačke inteligencije u Republici Srbiji, inicijativa Ministarstva zdravlja Republike Srbije (2023) uvela je obavezno etičko ocenjivanje svih alata veštačke inteligencije pre kliničke upotrebe, sa fokusom na:

- **Objašnjivost:** Korišćenje SHAP vrednosti za vizuelizaciju uticaja karakteristika matematičkog modela veštačke inteligencije koja je planirana da se koristi u kliničkoj praksi u Republici Srbiji.
- **Nadzor:** Lekar mora potvrditi dijagnozu dobijenih primenom sistema veštačke inteligencije pre finalizacije izveštaja.

Buduća istraživanja u oblasti dinamičke analize neuronskih mreža i primene matematičkih modela LSTM veštačkih neuronskih mreža optimizovanih algoritmom varijabilne pretrage susedstva u analizi EEG signala treba da se fokusiraju na:

- Razvoj efikasnijih algoritama za optimizaciju matematičkog modela LSTM veštačke neuronske mreže.
- Integraciju multimodalnih podataka u analizu EEG signala.
- Validaciju kliničke primene matematičkog modela LSTM veštačke neuronske mreže optimizovane algoritmom varijabilne pretrage susedstva kroz opsežna klinička ispitivanja.
- Razvoj *lightweight* modela koji su efikasni i sposobni za rad u realnom vremenu i pre svega neopterećeni zahtevnim računarskim resursima koji bi ograničili primenu u kliničkoj praksi.

5. Eksperimentalna evaluacija – Postavke, rezultati i poređenje performansi modela

U prethodnim poglavljima istražene su detaljno teorijske i naučne osnove, kao i klinička primena inovativnih matematičkih modela za analizu EEG signala, sa posebnim fokusom na matematičke modele LSTM veštačkih neuronskih mreža optimizovane algoritmom varijabilne pretrage susedstva, koji su definitivno ocenjeni sa najvišim ocenama u kliničkim ispitivanjima širom sveta.

U sledećem poglavlju ovog naučno-istraživačkog rada, prelazi se na praktičnu verifikaciju prethodno opisanih matematičkih modela kroz detaljnu eksperimentalnu evaluaciju samog matematičkog modela LSTM veštačke neuronske mreže, a koji će se optimizovati naprednim algoritmom varijabilne pretrage susedstva. Cilj je da se kvantifikuju performanse razvijenog rešenja i predloženih matematičkih modela, identifikuju njihove prednosti i nedostaci, odnosno komparativno uporede sa postojećim pristupima u analizi EEG signala u kliničkoj praksi. Kroz seriju kontrolisanih eksperimenata, nastojaće se da se pruži sveobuhvatna analiza koja će potvrditi efikasnost i pouzdanost predloženih matematičkih modela u realnim kliničkim scenarijima medicinske neurodijagnostike.

5.1. Priprema eksperimenta

U nastavku ovog poglavlja, detaljno se opisuje eksperimentalno okruženje koje je korišćeno u ovoj naučno-istraživačkoj studiji za evaluaciju performansi razvijenih matematičkih modela LSTM veštačkih neuronskih mreža. Eksperimentalna prezentacija počinje sveobuhvatnim opisom korišćenog skupa podataka sa Univerziteta Pompeu Fabra (<https://www.upf.edu>, UPF) u elektronskom fajl formatu koji dostupan na adresi <https://www.upf.edu/web/ntsa/downloads>, uključujući i sve relevantne informacije o njegovom poreklu, veličini, karakteristikama i relevantnosti za problem detekcije anomalija u EEG signalima. Posebna pažnja se posvetiće postupku pripreme podataka, koji kao takav je od ključnog značaja za obezbeđivanje kvaliteta i konzistentnosti ulaznih podataka za primenjene matematičke modele LSTM sistema veštačke inteligencije a koji će se opisati u nastavku ovog naučno-istraživačkog rada. Ovaj postupak obuhvata korake kao što su čišćenje podataka, normalizacija, segmentacija i ekstrakcija relevantnih karakteristika.

Nakon detaljnog opisa skupa podataka i postupka pripreme, pružiće se sveobuhvatan pregled eksperimentalnog okruženja. Ovo uključuje specifikacije hardvera i softvera korišćenih za obuku i testiranje matematičkog modela LSTM veštačke neuronske mreže koja će se optimizovati naprednim algoritmom varijabilne pretrage susedstva, kao i detaljan opis hiperparametara i konfiguracija korišćenih u eksperimentima. Ujedno posebna pažnja se posvetiće i opisu arhitekture modela LSTM veštačke neuronske mreže, kao i pripadajućih hiperparametara modela, koji će se optimizovati naprednim algoritmom varijabilne pretrage susedstva, uključujući detalje o broju slojeva, broju neurona u svakom sloju, aktivacionim funkcijama i drugim relevantnim parametrima modela.

Za svaki od razvijenih pristupa, detaljno će se opisati metričke evaluacije koje su korišćene za procenu performansi matematičkih modela. Ovo uključuje metrike kao što su

tačnost, preciznost, odziv, F1 skor, kao i specifične metrike relevantne za problem detekcije anomalija u EEG signalima, kao što su senzitivnost i specifičnost.

Pored toga, analiziraju se i drugi aspekte performansi matematičkog modela LSTM veštačke neuronske mreže koja će se optimizovati naprednim algoritmom varijabilne pretrage susedstva, kao što su vreme obuke, vreme testiranja i memorijska efikasnost. Iako su optimizatori korišćeni u ovoj naučno-istraživačkoj studiji takođe procenjivani na osnovu indikatorskih funkcija, zbog ograničenja dužine teksta ovog naučno-istraživačkog rada, detaljne tabele sa rezultatima ovih evaluacija indikatorskih funkcija su izostavljene. U okviru ovog poglavlja će se prikazati i svi neophodni grafikoni distribucije indikatorskih funkcija i grafikoni konvergencije, koji pružaju uvid u ponašanje optimizatora tokom procesa obuke veštačke neuronske mreže. Kao detaljan opis procesa optimizacije, u okviru „Slika 19: Dijagram toka optimizacije modela LSTM“ je prikazan dijagram toka okvira za optimizaciju, koji ilustruje korake i komponente korišćene u procesu optimizacije matematičkog modela LSTM veštačke neuronske mreže koja će se optimizovati naprednim algoritmom varijabilne pretrage susedstva.


5.1.1. Opis i prethodna obrada skupa podataka

Razmatranje medicinskih podataka suočava se sa nekoliko izazova, a jedan od značajnih prepreka odnosi se na dostupnost označenih podataka. Često visokokvalitetni podaci nisu javno dostupni, što ograničava mogućnosti korišćenja datih podataka za potrebe naučno istraživačkih radova, odnosno vrlo često istraživači ne mogu da se nadovežu na prethodno uspostavljene metode. Da bi se prevazišlo ovo ograničenje, u ovoj naučno-istraživačkoj studiji planira se korišćenje javno dostupnog označenog skupa podataka sa Univerziteta Pompeu Fabra (<https://www.upf.edu>, UPF) u .txt formatu a koji dostupan na Internet adresi <https://www.upf.edu/web/ntsa/downloads>. Iako je skup podataka po definiciji očekivano pravilno označen i dobro strukturiran, očekuje se da će biti potrebno izvršiti određene korake prethodne obrade podataka kako bi se dati skup podataka prilagodio za ovaj naučno-istraživački rad. Originalni skup podataka će obuhvatati EEG zapise od pet pacijenata. Među tim pacijentima, dva su identifikovana kao neurotipične osobe, označene kao A i B u originalnim podacima. Pored prethodno označenih pacijenata A i B, dva pacijenta su potvrđena kao obolela od epilepsije, označeni kao C i D u originalnim podacima. Na kraju, peti EEG segment je zabeležen tokom aktivnog epileptičkog napada, označen kao E u originalnim podacima.


Svaki uzorak će sadržati 26 sekundi zabeleženih podataka, ukupno 4097 podataka prikupljenih sa 100 elektroda. Predložena metoda će analizirati i procenjivati proces treniranja i optimizacije u okviru tri eksperimenta. Prvi eksperiment će koristiti nasumičnu kombinaciju podataka B i D za formiranje skupa podataka za detekciju EEG anomalija. Ovaj eksperiment je planirano da se vodi stopom funkcije greške kao funkcijom cilja. U drugom eksperimentu kombinovaće se podaci iz kolekcija A, B i C kako bi se formirao neuravnoteženi skup podataka.

Shodno tome, za ovaj eksperiment planira se korišćenje *Cohenov Kappa* metrika kao funkcije cilja. Konačni, treći skup podataka koristiće segmente B, C i E kako bi se detektovale i anomalije i ozbiljne aktivnosti. Pošto je ovaj skup podataka uravnotežen, stopa greške se koristi kao metrička funkcija cilja. Podaci će se pseudo-slučajno kombinovati u segmente od 158 podataka, a očekuje se da se dobiju rezultati poput grafika prikazanih na „Slika 21:


Očitavanja moždane aktivnosti u skupovima podataka u eksperimentima 1, 2 i 3. za svaki eksperiment“, pri čemu normalna aktivnost ima belu pozadinu, anomalna aktivnost svetloplavu, a aktivnost tokom napada tamnoplavu boju. Prikazi broja instanci mogu se videti na „Slika 20: Broj instanci uzoraka za podatke korišćene u eksperimentima 1, 2 i 3“.



Slika 19: Dijagram toka optimizacije matematičkog modela LSTM



Slika 20: Broj instanci uzoraka za podatke korišćene u eksperimentima 1, 2 i 3



Slika 21: Očitavanja moždane aktivnosti u skupovima podataka u eksperimentima 1, 2 i 3.

Ulaz koji se daje matematičkom modelu LSTM veštačke neuronske mreže će se sastojati od 15 uzastopnih podataka prikupljenih sa 100 elektroda.

Cilj matematičkog modela LSTM veštačke neuronske mreže je da se proceni verovatnoća da će dati uzorak biti kategorizovan kao normalna moždana aktivnost, abnormalna aktivnost ili aktivnost tokom epileptičnog napada kod pacijenta.

Izlaz će se sastojati od tri decimalne vrednosti (u rasponu od 0 do 1), pri čemu svaka vrednost predstavlja verovatnoću da uzorak pripada određenoj klasi, a njihov zbir je jednak 1. Klasifikacioni izlaz matematičkog modela LSTM veštačke neuronske mreže se određuje odabirom klase sa najvećom verovatnoćom.

5.1.2. Metrike klasifikacije

Za svaki testirani matematički model LSTM veštačke neuronske mreže procenjene su tradicionalne klasifikacione metrike: preciznost (*Precision*), odziv (*Recall*), tačnost (*Accuracy*) i F1 rezultat (*F1 Score*). Sledeće formule se primenjuju na te metrike:

$$Precision = \frac{TP}{TP+FP} \quad (36)$$

$$Recall = \frac{TP}{TP+FN} \quad (37)$$

$$Accuracy = \frac{TP+TN}{TP+FN+FP+FN} \quad (38)$$

$$F1\ Score = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (39)$$

gde TP i TN označavaju tačno pozitivne i negativne slučajeve, dok FP i FN označavaju lažno pozitivne i negativne slučajeve. Stopa greške je predstavljena indikatorskom funkcijom ($1 - Accuracy$). Kako će drugi konstruisani skup podataka koristiti neuravnotežen skup podataka, *Cohenov Kappa* koeficijent će se koristiti kao funkcija cilja jer daje pouzdane rezultate prilikom rada sa neuravnoteženim podacima. Ovaj koeficijent se računa prema sledećoj jednačini (40):

$$\kappa = \frac{p_o - p_e}{1 - p_e} = 1 - \frac{1 - p_e}{1 - p_e} \quad (40)$$

gde p_o označava posmatrane vrednosti, a p_e označava očekivane vrednosti.

5.1.3. Priprema simulacije

Kako bi se obezbedila efikasna implementacija svakog algoritma mašinskog učenja podataka, jedan od ključnih zahteva ove naučno-istraživačke studije će biti odabir odgovarajućih vrednosti hiperparametara koji rezultiraju zadovoljavajućim performansama za specifičan problem. Svakako treba naglasiti da zadatak izbora ovih vrednosti hiperparametara može se smatrati složenim problemom, poznatim kao „NP težak problem“, zbog ogromnog broja potencijalnih kombinacija, što čini konvencionalne metode optimizacije neprikladnim za primenu. Zbog prethodne činjenice, planira se da u se okviru ovog naučno-istraživačkog rada koriste metaheurističke tehnike optimizacije hiperparametara kako bi se identifikovali hiperparametri koji postižu željene performanse. Zbog potrebe za identifikacijom hiperparametara koji postižu željene performanse, u okviru ove naučno-istraživačke studije koriste se metaheurističke tehnike optimizacije. Algoritmi koji su upoređeni sa uvedenim algoritmom pretraga varijabilnost susedstva sa dinamičnom promenom strategije su najmoderniji optimizatori kao što su:

- **RSA (Runge Kutta metoda)** (Ahmadianfar et al., 2021),
- **GA (Genetski algoritam)** (Holland, 1975),
- **PSO (Optimizacija rojem čestica)** (Kennedy & Eberhart, 1995),
- **BA (Algoritam slepog miša)** (Yang, 2010),
- **BSO (Algoritam optimizacije jata ptica)** (Meng et al., 2016),
- **CoA (Cheetah Optimization Algoritam)** (Nadimi-Shahraki et al., 2022),

- **SASS (Shark Smell Optimization Algoritam)** (Zhang et al., 2022) i
- **COLSHADE (Algoritam za adaptivnu diferencijalnu evoluciju sa strategijama učenja i kontrole)** (Awadallah et al., 2022).

Svaki od prethodno navedenih algoritama optimizacije je zadužen za optimizaciju kroz 30 nezavisnih pokretanja sa 8 agenata i 8 iteracija za poboljšanje. Kao što je ranije pomenuto, planira se da se sprovede tri različite grupe eksperimenata. Prvi inicijalni eksperiment će prvenstveno imati za cilj otkrivanje anomalnih aktivnosti u okviru EEG signala, u obliku binarne klasifikacije. Sledeći eksperiment, označen kao eksperiment dva, baviće se istim izazovom koristeći neuravnotežen skup podataka. Konačno, treći eksperiment će se fokusirati na identifikaciju specifične vrste anomalne aktivnosti EEG signala, predstavljajući se kao višeklasna klasifikacija. U svakom eksperimentu, skupovi podataka će proći kroz standardni postupak podele, pri čemu će 70% biti dodeljeno za obuku, 10% za validaciju, a preostalih 20% će se koristiti za testiranje metodologija. Treba napomenuti da je tokom eksperimenta skup podataka normalizovan, a broj zaostalih vrednosti fiksiran na 15. Ovo istraživanje će obuhvatiti optimizaciju dve kategorije parametara. Inicijalno parametri obuke matematičkog modela LSTM veštačke neuronske mreže će proći kroz pažljiv izbor. Stopa učenja će biti izabrana iz spektra između 0,0001 i 0,01, dok će stopa ispuštanja (*dropout*) biti postavljena u intervalu od 0,05 do 0,2 za oba eksperimentalna scenarija. Pored toga, broj epoha obuke će se odrediti u rasponu od 30 do 60. Granice za broj neurona će biti postavljene na $[n/3, n]$, gde n označava broj zaostalih vrednosti ($n = 15$ u ovom eksperimentalnom istraživanju). Kako bi se smanjilo prekomerno uklapanje, tokom obuke će se ugraditi pažljiv kriterijum ranog zaustavljanja, zaključujući proces na jednoj trećini maksimalno propisanih epoha obuke. Parametri i njihovi odgovarajući planirani rasponi su prikazani u „Tabela 2: Parametri i njihovi odgovarajući rasponi za optimizaciju LSTM mreže“. Budući da arhitektura veštačke neuronske mreže značajno može da utiče na performanse, strukture matematičkog modela LSTM veštačke neuronske mreže se optimizuju.

Broj skrivenih slojeva veštačke neuronske mreže će se odabrati u rasponu od 1 do 2 za oba eksperimenta. Pored toga, broj veštačkih neurona u svakom skrivenom sloju će se izabrati iz intervala $lags/3$ do $lags$ za prvi eksperiment i $lags/2$ do $lags \cdot 2$ za drugi eksperiment. Vrednosti za drugi eksperiment, kao što su epohe obuke i broj veštačkih neurona, će se povećati zbog veće složenosti problema višeklasne klasifikacije. Određivanje raspona hiperparametara baziraće se na empirijskim saznanjima dobijenim metodom pokušaja i grešaka i oslanja se na prethodno iskustvo sa optimizacijom hiperparametara.

Naziv parametra	Donja granica	Gornja granica
Stopa učenja	0,0001	0,01
Stopa ispuštanja	0,05	0,2
Broj epoha obuke	30	60
Broj LSTM slojeva	1	3
Broj LSTM jedinica	5	15

Tabela 2: Parametri i njihovi odgovarajući rasponi za optimizaciju LSTM mreže

6. Analiza eksperimentalnih rezultata i naučni doprinosi

U Tabeli 3 prikazani su rezultati funkcije cilja (stopa greške) postignuti u prvom eksperimentu za najbolje, najgore, prosečne i medijane rezultate. Pored toga, prikazani su varijansa i standardna devijacija kako bi se istakla stabilnost algoritma optimizacije.

Metoda	Najbolji	Najlošiji	Srednja vrednost	Medijana	Std	Var
LSTM-VNS-DS	0.002462	0.006154	0.003780	0.003077	1.25E-03	1.57E-06
LSTM-RSA	0.002462	0.006769	0.005231	0.005846	1.77E-03	3.12E-06
LSTM-GA	0.003077	0.006154	0.004769	0.004923	1.18E-03	1.40E-06
LSTM-PSO	0.003077	0.006769	0.005385	0.005846	1.40E-03	1.96E-06
LSTM-BA	0.002462	0.008615	0.006000	0.006462	2.70E-03	7.27E-06
LSTM-BSO	0.002462	0.012923	0.006154	0.004615	4.15E-03	1.72E-05
LSTM-ChOA	0.002462	0.006769	0.004923	0.005231	1.90E-03	3.60E-06
LSTM-SASS	0.004923	0.007385	0.006308	0.006462	9.10E-04	8.28E-07
LSTM-COLSHADE	0.003077	0.004923	0.004154	0.004308	6.71E-04	4.50E-07


Tabela 3: Ukupne metrike funkcije cilja (stopa greške) za Eksperiment 1

Kao što je prikazano u „Tabela 3: Ukupne metrike funkcije cilja (stopa greške) za Eksperiment 1“, očekuje se da algoritam optimizacije prevaziđe mnoge probleme povezane sa osnovnim algoritmom varijabilne pretrage susedstva, pokazujući poboljšanje u smislu prosečnih i medijanskih rezultata u poređenju sa drugim algoritmima optimizacije.


Pored toga, za uvedeni algoritam optimizacije se očekuje da ostvari rezultate na nivou najbolje rangirane metode. Međutim, iako nije pokazao najbolje rezultate ukupno, COLSHADE algoritam optimizacije pokazuje izvanrednu stabilnost i očekuje se da ostvari najbolje rezultate u najgorim slučajevima. Ovi rezultati će biti dalje analizirani u smislu detaljnih metrika u „Tabela 9: Detaljne metrike za Eksperiment 1“.

Poboljšanja u pogledu konvergencije i raspodele za svaku metodu mogu se videti na „Slika 22: Dijagrami raspodele indikatorskih funkcija za Eksperiment 1“ i „Slika 23: Dijagrami konvergencije indikatorskih funkcija za Eksperiment 1“ za indikatorske i funkcije cilja.


EEG Anomaly detection experiment 1 - objective violin plot diagram



EEG Anomaly detection experiment 1 - cohen kappa box plot diagram



Slika 22: Dijagrami raspodele indikatorskih funkcija za Eksperiment 1



Slika 23: Dijagrami konvergencije indikatorskih funkcija za Eksperiment 1

Izbor parametara za svaki najbolje rangirani matematički model od strane svakog optimizatora prikazan je u „Tabela 4: Najbolje određeni parametri za Eksperiment 1“ kako bi se olakšala ponovljivost eksperimenata. Važno zapažanje je da svetle mrežne strukture pokazuju povoljnije rezultate u evaluacijama.

Metoda	Stopa učenja	Dropout	Epohe	Nivoi	Neurona L1	Neurona L2
LSTM-VNS-DS	0.006740	0.122336	47	1	10	/
LSTM-RSA	0.006578	0.200000	60	1	5	/
LSTM-GA	0.006086	0.152660	57	1	12	/
LSTM-PSO	0.007601	0.200000	60	1	15	/
LSTM-BA	0.010000	0.200000	60	1	5	/
LSTM-BSO	0.008798	0.128739	40	1	10	/
LSTM-ChOA	0.008381	0.090725	48	1	9	/
LSTM-SASS	0.010000	0.066245	57	1	13	/
LSTM-COLSHADE	0.006482	0.200000	60	1	5	/

Tabela 4: Najbolje određeni parametri za Eksperiment 1

U okviru „Tabela 5: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 2“ prikazani su rezultati funkcije cilja (*Cohen Kappa*) koji se očekuju da budu postignuti u drugom eksperimentu za najbolje, najgore, prosečne i medijane rezultate. Pored toga, prikazani su varijansa i standardna devijacija kako bi se istakla stabilnost algoritma optimizacije.

Kao što je prikazano u „Tabela 4: Najbolje određeni parametri za Eksperiment 1“, uvedeni algoritam očekuje se da pokaže najbolje performanse u svim metrikama, dok RSA pokazuje veću stabilnost ukupno. Ovi rezultati su dalje detaljno analizirani u „Tabela 10: Detaljne metrike za Eksperiment 2“.

Metoda	Najbolji	Najlošiji	Srednja vrednost	Medijana	Std	Var
LSTM-VNS-DS	0.981058	0.961308	0.971848	0.972514	7.04E-03	4.95E-05
LSTM-RSA	0.968150	0.956284	0.962023	0.961829	4.21E-03	1.78E-05
LSTM-GA	0.964734	0.938295	0.947282	0.943051	1.04E-02	1.07E-04
LSTM-PSO	0.973263	0.942898	0.957497	0.956913	1.08E-02	1.17E-04
LSTM-BA	0.972502	0.748305	0.887259	0.914115	8.54E-02	7.30E-03
LSTM-BSO	0.977632	0.926543	0.949578	0.947070	1.83E-02	3.35E-04
LSTM-ChOA	0.976731	0.951084	0.963117	0.962326	1.05E-02	1.11E-04
LSTM-SASS	0.970839	0.945193	0.958358	0.958701	9.15E-03	8.36E-05
LSTM-COLSHADE	0.976794	0.957149	0.964204	0.961436	7.57E-03	5.73E-05

Tabela 5: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 2

Poboljšanja se mogu uočiti na „Slika 24: Dijagrami raspodele funkcija cilja i indikatorskih funkcija za Eksperiment 2“ i „Slika 25: Konvergencije funkcija cilja i indikatorskih funkcija za Eksperiment 3“, gde se jasno vidi dominacija i poboljšanja u odnosu na konkurentski algoritam.

Izbor hiperparametara za svaki najbolje rangirani model od strane svakog optimizatora prikazan je u „Tabela 5: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 2“ kako bi se olakšala ponovljivost eksperimenata. Ponovo, zanimljivo zapažanje je da svetle mrežne strukture pokazuju povoljnije rezultate u evaluacijama.

Metoda	Stopa učenja	Dropout	Epohe	Nivoi	Neurona L1	Neurona L2
LSTM-VNS-DS	0.006201	0.200000	60	1	15	/
LSTM-RSA	0.003866	0.200000	60	1	15	/
LSTM-GA	0.004136	0.141985	55	1	15	/
LSTM-PSO	0.005337	0.084039	60	1	15	/
LSTM-BA	0.010000	0.200000	56	1	5	5
LSTM-BSO	0.010000	0.200000	60	1	15	15
LSTM-ChOA	0.003270	0.144255	60	1	15	/
LSTM-SASS	0.005960	0.200000	57	1	6	/
LSTM-COLSHADE	0.003055	0.050000	50	1	15	/

Tabela 6: Najbolje određeni parametri za Eksperiment 2

U okviru „Tabela 7: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 3“ prikazani su rezultati funkcije cilja (*Cohen Kappa*) koja očekuje se da budu postignuti u verovatno najtežem eksperimentu u ovoj studiji, eksperimentu tri, za najbolje, najgore, prosečne i medijanske rezultate. Pored toga, prikazani su varijansa i standardna devijacija kako bi se istakla stabilnost algoritma.

Metoda	Najbolji	Najlošiji	Srednja vrednost	Medijana	Std	Var
LSTM-VNS-DS	0.718119	0.534640	0.644836	0.681206	7.31E-02	5.34E-03
LSTM-RSA	0.706878	0.403931	0.558544	0.564824	1.24E-01	1.53E-02
LSTM-GA	0.451841	0.202421	0.366988	0.446703	1.16E-01	1.35E-02
LSTM-PSO	0.562630	0.442161	0.493954	0.477070	5.06E-02	2.56E-03
LSTM-BA	0.415085	0.089064	0.269431	0.304144	1.35E-01	1.83E-02
LSTM-BSO	0.370170	0.136547	0.273147	0.312723	9.94E-02	9.88E-03
LSTM-ChOA	0.613113	0.195841	0.448803	0.537454	1.82E-01	3.29E-02
LSTM-SASS	0.604570	0.469325	0.533345	0.526141	5.54E-02	3.07E-03
LSTM-COLSHADE	0.681206	0.430046	0.561297	0.572638	1.03E-01	1.06E-02

Tabela 7: Ukupne metrike funkcije cilja (Cohen Kappa) za Eksperiment 3

Kao što je prikazano rezultatima u „Tabela 7: Ukupne metrike funkcije cilja (*Cohen Kappa*) za Eksperiment 3“, uvedeni algoritam je nadmašio konkurentske metaheuristike u svim metrikama, pri čemu samo algoritam optimizacije roja čestica (PSO) postiže veće stope stabilnosti. Međutim, to dolazi po cenu značajno nižih performansi matematičkog modela.

Ovi rezultati su dalje detaljno istraženi u prikazana su u „Tabela 9: Detaljne metrike za Eksperiment 1“, Tabela 10: Detaljne metrike za Eksperiment 2“ i „Tabela 11.



Detaljne metrike za Eksperiment 3“ za svaki pojedinačni eksperiment. Stabilnost algoritma i poboljšanja konvergencije grafički su prikazani na „Slika 23: Dijagrami konvergencije indikatorskih funkcija za Eksperiment 1“ i „Slika 25: Konvergencije funkcija cilja i indikatorskih funkcija za Eksperiment 3“.

Izbor parametara za svaki najbolje rangirani model od strane svakog optimizatora prikazan je u „Tabela 8: Najbolje određeni parametri za Eksperiment 3“ kako bi se olakšala ponovljivost eksperimenata.

Detaljna poređenja metrika između najboljih performansnih modela za svaki eksperiment prikazana su u „Tabela 9: Detaljne metrike za Eksperiment 1“, Tabela 10: Detaljne metrike za Eksperiment 2“ i „Tabela 11: Detaljne metrike za Eksperiment 3“.

Dok uvedeni algoritam pokazuje očekivana poboljšanja i očekuje se da postigne najbolje performanse u većini metrika, ali u nekim metrikama da bude nadmašen od strane drugih algoritama.



Ipak, ovo dodatno potvrđuje NFL teorem, jasno pokazujući činjenicu da nijedna pojedinačna metoda ne pokazuje istu korisnost za sve test slučajeve i sve moguće metrike. Stoga, kontinuirano istraživanje i eksperimentisanje su potrebni kako bi se odredile odgovarajuće metode za date izazove.



Slika 24: Dijagrami raspodele funkcija cilja i indikatorskih funkcija za Eksperiment 2

Kao što je prikazano u „Tabela 8: Najbolje određeni parametri za Eksperiment 3“, „Tabela 9: Detaljne metrike za Eksperiment 1“ i „Tabela 10: Detaljne metrike za Eksperiment 2“, određeni optimizatori kao što su ChOA, GA i BSO pokazuju jasno nedostatak istraživačke moći, fokusirajući se na suboptimalne oblasti pretraživačkog prostora i pružajući rezultate nižeg kvaliteta.

Ovi rezultati su očekivani kada se uzmu u obzir grafici konvergencije za odgovarajuće algoritme, koji sugerišu da ovi algoritmi ne uspevaju da konvergiraju ka prikladnijim rešenjima. Međutim, važno je napomenuti da ovo ne odražava ukupni kvalitet tih algoritama, i da u drugačijim zadacima, niska stopa konvergencije može biti prednost za izbegavanje lokalnih minimuma.



Slika 25: Konvergencije funkcija cilja i indikatorskih funkcija za Eksperiment 3

Metoda	Stopa učenja	Dropout	Epohe	Nivoi	Neurona L1	Neurona L2
LSTM-VNS-DS	0.000915	0.165158	51	2	9	6
LSTM-RSA	0.010000	0.111187	60	1	11	15
LSTM-GA	0.006136	0.142632	42	2	8	12
LSTM-PSO	0.005087	0.103497	30	2	15	15
LSTM-BA	0.000100	0.200000	47	2	7	5
LSTM-BSO	0.000100	0.200000	45	2	8	7
LSTM-ChOA	0.000100	0.200000	33	1	7	5
LSTM-SASS	0.001668	0.099516	39	2	5	5
LSTM-COLSHADE	0.000129	0.143068	30	2	13	11

Tabela 8: Najbolje određeni parametri za Eksperiment 3

Poboljšanja u diverzitetu rojeva i konvergenciji dodatno su potkrepljena dijagramima diverziteta rojeva za svaki eksperiment prikazanim u „Tabela 12: Shapiro-Vilk testovi normalnosti“.

Na kraju, PR krive i dijagrami matrica konfuzije su prikazani za modele sa najboljim performansama optimizacije u svakom od tri sprovedena eksperimenta. PR krive se mogu videti na „Slika 29: Najbolji modeli sa PR krivama i matrica konfuzije za eksperiment 1, 2 i 3“ zajedno sa odgovarajućim matricama konfuzije.

	LSTM-VNS-DS	LSTM-RSA	LSTM-GA	LSTM-PSO	LSTM-BA	LSTM-BSO	LSTM-ChOA	LSTM-SASS	LSTM-COLSHADE
Accuracy (%)	99.7538	99.7538	58.7692	99.6923	99.7538	58.9538	58.4615	99.5077	99.6923
Precision 0	0.997890	0.997890	0.585909	0.997888	0.997890	0.586997	0.584104	0.995781	0.997888
Precision 1	0.997046	0.997046	1.000000	0.995575	0.997046	1.000000	1.000000	0.994092	0.995575
W.Avg. Precision	0.997538	0.997538	0.758425	0.996925	0.997538	0.759060	0.757372	0.995077	0.996925
Recall 0	0.997890	0.997890	1.000000	0.996835	0.99789	1.000000	1.000000	0.995781	0.996835
Recall 1	0.997046	0.997046	0.010340	0.997046	0.997046	0.014771	0.002954	0.994092	0.997046
W.Avg. Recall	0.997538	0.997538	0.587692	0.996923	0.997538	0.589538	0.584615	0.995077	0.996923
F1-score 0	0.997890	0.997890	0.738893	0.997361	0.997890	0.739758	0.737456	0.995781	0.997361
F1-score 1	0.997046	0.997046	0.020468	0.996310	0.997046	0.029112	0.005891	0.994092	0.996310
W.Avg. F1-score	0.997538	0.997538	0.439586	0.996923	0.997538	0.443692	0.432675	0.995077	0.996923
	Normal 948	Anomalous 677	Total 1625						



Tabela 9: Detaljne metrike za Eksperiment 1

	LSTM-VNS-DS	LSTM-RSA	LSTM-GA	LSTM-PSO	LSTM-BA	LSTM-BSO	LSTM-ChOA	LSTM-SASS	LSTM-COLSHADE
Accuracy (%)	9.0998	98.4861	38.7889	98.7316	98.6907	98.9362	98.8953	98.6088	98.8953
Precision 0	0.986345	0.977964	0.387797	0.986214	0.976091	0.982218	0.986272	0.970165	0.979188
Precision 1	0.993968	0.989269	0.500000	0.988008	0.993927	0.993952	0.990648	0.996603	0.99528
W.Avg. Precision	0.991011	0.984884	0.456478	0.987312	0.987009	0.989400	0.988951	0.986348	0.989038
Recall 0	0.990506	0.983122	0.998945	0.981013	0.990506	0.990506	0.985232	0.994726	0.992616
Recall 1	0.991310	0.985963	0.000668	0.991310	0.984626	0.988636	0.991310	0.980615	0.986631
W.Avg. Recall	0.990998	0.984861	0.387889	0.987316	0.986907	0.989362	0.988953	0.986088	0.988953
F1-score 0	0.988421	0.980537	0.558702	0.983607	0.983246	0.986345	0.985752	0.982292	0.985856
F1-score 1	0.992637	0.987613	0.001335	0.989656	0.989255	0.991287	0.990979	0.988544	0.990937
W.Avg. F1-score	0.991002	0.984868	0.217531	0.987310	0.986924	0.989370	0.988951	0.986119	0.988966
	Normal	Anomalous	Total						
	1496	948	2444						


Tabela 10: Detaljne metrike za Eksperiment 2

	LSTM-VNS-DS	LSTM-RSA	LSTM-GA	LSTM-PSO	LSTM-BA	LSTM-BSO	LSTM-ChOA	LSTM-SASS	LSTM-COLSHADE
Accuracy (%)	88.3797	88.2570	72.3813	79.9100	68.7398	62.1931	83.7561	83.7971	88.4206
Precision 0	0.665461	0.629752	0.36991	0.612378	0.351299	0.442679	0.539157	0.568038	0.684008
Precision 1	0.461078	0.341463	0.461538	0.130435	0.438318	0.181474	0.113402	0.000000	0.071429
Precision 2	0.994780	0.994878	0.990476	0.991634	0.940644	1.000000	0.997029	0.980836	0.950975
W.Avg. Precision	0.907726	0.894371	0.857255	0.87544	0.814125	0.858150	0.866840	0.851555	0.851513
Recall 0	0.943590	0.976923	0.838462	0.964103	0.796278	1.000000	0.917949	0.920513	0.910256
Recall 1	0.487342	0.177215	0.569620	0.227848	0.540962	0.607595	0.069620	0.000000	0.012658
Recall 2	0.904536	0.921941	0.713080	0.812764	0.677204	0.545359	0.885021	0.890823	0.951477
W.Avg. Recall	0.883797	0.88257	0.723813	0.799100	0.687398	0.621931	0.837561	0.837971	0.884206
F1-score 0	0.780488	0.765829	0.513344	0.749004	0.487517	0.613690	0.679317	0.702544	0.781078
F1-score 1	0.473846	0.233333	0.509915	0.165899	0.484261	0.279476	0.086275	0.000000	0.021505
F1-score 2	0.947514	0.957022	0.829193	0.893333	0.787476	0.705802	0.937692	0.933665	0.951226
W.Avg. F1-score	0.890239	0.879727	0.758151	0.823275	0.720008	0.663542	0.841419	0.836424	0.863970
	Normal 74	Anomalous 158	Seizure 2212	Total 2444					

Tabela 11: Detaljne metrike za Eksperiment 3



Slika 26: Dijagrami raspodele funkcija cilja i indikatorskih funkcija za Eksperiment 3



Slika 27: Dijagrami konvergencije funkcije cilja i indikatorske funkcije za eksperiment 3

6.1. Statistička validacija

Za sprovođenje statističke validacije, uzorke matematičkih modela sa najboljim performansama će se prikupiti iz 30 odvojenih pokretanja svakog optimizatora. Nakon ove faze, biće neophodno uspostaviti validnost korišćenja parametarskih testova, što zahteva ispunjavanje različitih kriterijuma (LaTorre et al., 2021).


Ovi kriterijumi obuhvataju osiguranje nezavisnosti, normalnosti i homoskedastičnosti varijanse podataka. Početni uslov nezavisnosti je ispunjen, jer svaki algoritam započinje sa različitim nasumičnom raspodelom, generišući jedinstven skup nasumičnih rešenja za svako pokretanje.

Za procenu uslova normalnosti, koristiće se *Shapiro-Wilk* test (Shapiro & Francia, 1972) za pojedinačnu analizu problema na ishodima ciljne funkcije za sva tri eksperimenta. Test sproveden nezavisno za svaki algoritam, a rezultujuće *p*-vrednosti mogu se naći u „Tabela 12: Shapiro-Vilk testovi normalnosti“

Problem	VNS-DS	RSA	GA	PSO	BA	BSO	ChOA	SASS	COLSHADE
Eksperiment 1	0.048	0.042	0.044	0.045	0.045	0.047	0.041	0.043	0.044
Eksperiment 2	0.046	0.047	0.041	0.040	0.034	0.039	0.045	0.046	0.043
Eksperiment 3	0.029	0.011	0.031	0.030	0.015	0.013	0.019	0.017	0.012

Tabela 12: Shapiro-Vilk testovi normalnosti

Na osnovu vrednosti prikazanih u „Tabela 12: Shapiro-Vilk testovi normalnosti“, algoritmi pokazuju solidnu stabilnost za prvi i drugi eksperiment, proizvodeći pouzdanije i robusnije rezultate. Međutim, stabilnost algoritama u trećem eksperimentu je smanjena. Ipak, kako nijedan uzorak ne zadovoljava uslov normalnosti, sa svim *p*-vrednostima ispod 0.05, nulta hipoteza eksperimenta (H_0 – normalna distribucija skupa uzoraka) može biti odbačena .



Slika 28: Dijagrami raznolikosti funkcije cilja roja za eksperiment 1, 2 i 3

Pošto *Shapiro-Wilk* testovi normalnosti pokazuju da uzorci ne zadovoljavaju uslov normalnosti, primena parametarskih testova nije odgovarajuća. Stoga, koristiće se neparametarski *Wilcoxon* test potpisanih rangova (Wilcoxon, 1992).


U ovoj analizi, algoritam varijabilne pretrage susedstva sa dinamičnom promenom strategije se koristi kao kontrola. Rezultati *Wilcoxon* testa potpisanih rangova mogu se naći u „Tabela 13: Wilcoxon test potpisanih rangova: rezultati p-vrednosti za sva četiri scenarija (LSTM-VNS-DS vs ostali)“.

Problem p vrednosti	RSA	GA	PSO	BA	BSO	ChOA	SASA	COLSHADE
Eksperiment 1	0.031	0.037	0.030	0.024	0.022	0.034	0.020	0.043
Eksperiment 2	0.039	0.022	0.028	0.009	0.025	0.043	0.031	0.044
Eksperiment 3	0.036	0.045	0.038	0.034	0.047	0.047	0.047	0.033

Tabela 13: Wilcoxon test potpisanih rangova: rezultati p-vrednosti za sva četiri scenarija (LSTM-VNS-DS vs ostali)

Rezultati statističke validacije podržavaju nalaze dobijene u prethodnoj analizi, koja se zasniva na ishodima ciljne funkcije iz 30 nezavisnih pokretanja. Vredno je napomenuti da je treći eksperiment najizazovniji. Iako algoritmi pokazuju povoljne performanse, nijedan od testiranih pristupa ne pokazuje zaista izvanredne rezultate.

Rezultati prikazani u „Tabela 13: Wilcoxon test potpisanih rangova: rezultati p-vrednosti za sva četiri scenarija (LSTM-VNS-DS vs ostali)“ jasno ukazuju da uvedeni algoritmi nisu prikazali rezultate statistički značajno bolje od drugih evaluisanih pristupa. Ipak, algoritam je pokazao poboljšanje u odnosu na osnovne algoritme.




Slika 29: Najbolji modeli sa PR krivama i matrica konfuzije za eksperiment 1, 2 i 3

6.2. Interpretacija najboljeg modela

Modeli koje kreiraju algoritmi veštačke inteligencije često se smatraju crnom kutijom. Međutim, interpretacija modela igra sve važniju ulogu u savremenom istraživanju. *SHapley Additive exPlanations* (SHAP) (Lundberg & Lee, 2017) koristi aproksimacije modela i crpi inspiraciju iz teorije igara kako bi interpretirao i objasnio ishode bilo kojeg modela mašinskog učenja.

U ovoj naučno-istraživačkoj studiji, SHAP interpretacija će biti primenjena kako bi se pojasnili modeli klasifikacije sa najboljim performansama generisani metaheuristikama. Ove interpretacije nude dragocene uvide za buduća istraživanja, naglašavajući oblasti unutar dostupnih podataka koje bi mogle biti unapređene kako bi se poboljšale buduće istrage.

Pored toga, ove interpretacije igraju ključnu ulogu u dijagnostičkom radu, smanjujući broj elektroda potrebnih za određivanje rezultata. Interpretacija modela sa najboljim performansama, optimizovanog pomoću metaheuristika, vizualizovana je na „Slika 30: Rezultati važnosti karakteristika u SHAP interpretaciji“.



Slika 30: Rezultati važnosti karakteristika u SHAP interpretaciji

Kao što se može videti na „Slika 30: Rezultati važnosti karakteristika u SHAP interpretaciji“ prikazuje značaj svake elektrode u klasifikaciji najboljeg modela predikcije, zajedno sa opsegom u kojem ove karakteristike utiču na odluku prema normalnom ili abnormalnom ishodu.

Uticaji svih karakteristika izgledaju razumno, međutim, elektrode označene brojevima 95, 63, 91 i 47 se izdvajaju kao one koje imaju izraženiju ulogu u procesu donošenja odluka matematičkog modela.

Takođe treba napomenuti da većina matematičkih modela sa najboljim performansama konstruisanih pomoću algoritma varijabilne pretrage susedstva sastojala od 9-15 veštačkih neurona i jednog ili dva sloja za sve sprovedene eksperimente, dok su obučeni sa manje od 60 epoha.

Ovo implicira da se takvi matematički modeli mogu koristiti u realnom vremenu, budući da su ovi lagani (*lightweight*) modeli veoma efikasni. Još jedan značajan doprinos je činjenica da se ovaj specifičan problem klasifikacije EEG signala može efikasno rešavati pomoću tako konstruisanih matematičkih modela.

7. Zaključak i perspektive daljeg razvoja primene veštačke inteligencije u neurološkoj dijagnostici

Ova naučno-istraživačka studija je koncipirana kako bi uvela nov pristup za otkrivanje anomalija i epileptičnih napada kod pacijenata putem analize EEG signala, sa značajnim inženjerskim implikacijama koje prevazilaze granice akademske zajednice i imaju primenu u industrijskoj praksi medicinske neurodijagnostike.

Predložena metoda koristi metodologiju klasifikacije vremenskih serija zasnovanu na matematičkim modelima LSTM (*Long Short-Term Memory*) veštačkih neuronskih mreža, koja se pokazala izuzetno korisnom u analizi sekvencijalnih podataka sa nelinearnim karakteristikama signala. S obzirom na značajan uticaj pravilnog odabira hiperparametara na performanse matematičkog modela LSTM veštačke neuronske mreže, uključene su optimizacione tehnike za poboljšanje efikasnosti samog matematičkog modela.

Konkretno, modifikovana verzija poznatog optimizacionog algoritma pretrage varijabilnog susedstva je uvedena kako bi zadovoljila specifične potrebe ove naučno-istraživačke studije, naglašavajući inženjerske aspekte u dizajnu algoritma mašinskog učenja podataka i omogućavajući bolje prilagođavanje matematičkog modela na kompleksne obrasce u EEG podacima.

Kako bi se omogućila robusna obuka i evaluacija matematičkog modela LSTM veštačke neuronske mreže, skup ulaznih i prethodno označenih podataka je pažljivo konstruisan iz javno dostupnih izvora koji su obuhvatali kako zdrave osobe, tako i one pogođene epilepsijom. Uključivanje zabeleški aktivnih napada u skupove podataka omogućilo je sprovođenje tri sveobuhvatna eksperimenta.

Prvi eksperiment je procenio potencijal modela LSTM veštačke neuronske mreže za otkrivanje anomalne moždane aktivnosti kod pacijenata, postavljajući osnovu za naknadne evaluacije i otkrivajući kako različiti hiperparametri matematičkog modela utiču na tačnost samog modela.

Drugi eksperiment, dizajniran sa neuravnoteženim skupom podataka, dodatno je istraživao performanse matematičkog modela LSTM veštačke neuronske mreže u kontekstu realnih izazova sa kojima se suočavaju istraživači, kao što su nerazmerne klase ulaznih podataka koje mogu otežati učenje matematičkog modela.

Na kraju, treći eksperiment je izazvao konstruisane matematičke modele da otkriju pojave u anomalnim i neurotipičnim merenjima, prikazujući svestranost predloženog pristupa i njegovu sposobnost da se prilagodi različitim realnim uslovima sa kojima se model može susresti u realnoj kliničkoj praksi.

Svi sintetizovani matematički modeli su bili laki i obučeni su sa maksimalno 60 epoha, što je ukazivalo na mogućnost primene u realnom vremenu i doprinosilo brznoj detekciji potencijalnih napada ili anomalija kod pacijenata. Ova efikasnost je bila ključna, s obzirom na to da bi brzina detekcije mogla imati presudnu ulogu u kliničkim situacijama, gde je pravovremena reakcija od vitalnog značaja za pacijente.

U svetlu inženjerskih izazova, koje je predstavljala velika zavisnost matematičkih modela LSTM veštačkih neuronskih mreža od odabira parametara, optimizovani matematički

modeli su pokazali pohvalne performanse uprkos skromnim uzorcima ulaznih podataka. Važno je napomenuti da su modeli LSTM veštačkih neuronskih mreža i dalje su mogli da generišu relevantne rezultate bez prekomerne upotrebe kompjuterskih resursa, što ih čini praktičnim za implementaciju u kliničkim i istraživačkim okruženjima, pogotovu u situacijama kada se prikupljanje i obrada podataka mora odraditi na udaljenim (*EDGE*) uređajima (*IoT*).

Još jedno ograničenje ove naučno-istraživačke studije koje je trebalo napomenuti bila je činjenica da se nije pokušala optimizacija svih hiperparametara matematičkog modela, kao što je stopa ispadanja tokom rekurzije. Parametrizacija većeg broja hiperparametara bi neizbežno povećala troškove računarskih resursa drastično, što predstavlja značajnu prepreku za buduće istraživače ali i primenu u kliničkoj praksi. Pored toga, u ovom istraživanju razmatrani su isključivo matematički modeli LSTM veštačkih neuronskih mreža, dok druge rekurentne veštačke neuronske mreže kao što su BiLSTM (*Bidirectional LSTM*) i GRU (*Gated Recurrent Unit*) mreže nisu temeljno ispitane.

Uključivanje ovih alternativnih veštačkih neuronskih mreža moglo bi otvoriti nove pravce za poboljšanje tačnosti i efikasnosti matematičkog modela, što predstavlja značajan prostor za dalja istraživanja u ovoj oblasti medicinske neurodijagnostike. Stoga, postoje značajni potencijali za dalja ispitivanja i inovacije u detekciji anomalija, te se očekuje da će rezultati ovog naučno-istraživačkog rada inspirisati slične studije i podstaći istraživače da istraže nove tehnike i metode za analizu medicinskih podataka.

Korišćenje tačnih matematičkih modela ostavilo je prostor za razvoj potencijala za praćenje kontinuiteta kod pacijenata koji pate od spontanih napada, omogućavajući stvaranje sistema ranog upozorenja. Takav dijagnostički sistem bi mogao da pruži ne samo brze i tačne informacije o stanju pacijenta, već bi mogao i da poboljša strategije lečenja i upravljanja epilepsijom, čime bi se potencijalno smanjila učestalost napada i poboljšao kvalitet života pacijenata u celosti.

Gledajući unapred, buduća istraživanja će se definitivno baviti istraživanjem naprednih metoda veštačke inteligencije za detekciju anomalija u oblasti obrade medicinskih signala. Mogući novi pravci istraživanja bi uključivali kliničku progresiju širokog spektra bolesti, kao što su neurodegenerativni poremećaji, kardiovaskularne bolesti, cistična fibroza i rak. Ove bolesti predstavljaju značajne izazove za savremenu medicinu, a razvoj inovativnih rešenja za njihovu detekciju i lečenje mogao bi značajno unaprediti pristupe u široj zdravstvenoj zaštiti.

Pored toga, uvedeni optimizacijski algoritam je detaljno razmatran zbog svojih potencijalnih primena u rešavanju stvarnih inženjerskih problema, naglašavajući šire implikacije ovog naučno-istraživačkog rada izvan okvira akademije. Ovaj aspekt je ključan jer omogućava inženjerima da primene naučene metode u stvarnim situacijama, čime se povećava ukupna efikasnost i kvalitet pruženih zdravstvenih usluga.

U domenu prethodno definisanih hipoteza (opšte i pojedinačne) ovog naučno-istraživačkog rada, u nastavku teksta se navodi submiliran nalaz svih postavljenih hipoteza, kao i detaljan prikaz status svake pojedinačne hipoteze

Opšta hipoteza: *Optimizacija LSTM veštačke neuronske mreže pomoću metaheurističkih algoritama može poboljšati tačnost detekcije epileptičkih napada kod pacijenata na osnovu EEG podataka.*

Potvrđeno: Ovaj naučno-istraživački rad definitivno je potvrdio Opštu hipotezu (H0) tako što je detaljnom analizom i eksperimentima potvrdio da primena metaheurističkih algoritama (GA, PSO, VNS) optimizuje hiperparametre modela LSTM veštačke neuronske mreže. Rezultati eksperimenata jasno pokazuju poboljšanje tačnosti klasifikacije EEG podataka kada se koriste metaheurističke optimizacije u poređenju sa standardnim modelom LSTM veštačke neuronske mreže. Svi dobijeni eksperimetalni rezultati pokazuju poboljšanja u metriki tačnosti (*accuracy*), preciznosti (*precision*), osetljivosti (*recall*) i F1-score-u. Ovi pokazatelji direktno potvrđuju opštu hipotezu.

Hipoteza H1: *LSTM veštačke neuronske mreže mogu efikasno klasifikovati EEG podatke i detektovati anomalije u moždanoj aktivnosti kod pacijenata.*

Potvrđeno: U okviru ovog naučno-istraživačkog rada potvrđena je Hipoteza H1 tako što predstavljena arhitektura LSTM veštačke neuronske mreže, koja je obučena na EEG podacima je uspešno uradila detekcije epileptičkih napada kod pacijenata. Eksperimenti su pokazali da model LSTM veštačke neuronske mreže može prepoznati složene obrasce u EEG signalima sa solidnim nivoom tačnosti, što potvrđuje njegovu efikasnost u klasifikaciji. Konkretni rezultati pokazuju da model LSTM veštačke neuronske mreže je postigao visoku tačnost detekcije abnormalnih moždanih aktivnosti, pri čemu su detaljno analizirani parametri poput verovatnoće detekcije epileptičnog napada u odnosu na normalne EEG signale. Sve prikazane vizuelizacije rezultata u okviru ovog naučno-istraživačkog rada (grafikoni, matrice konfuzije) dodatno potvrđuju sposobnost LSTM veštačke neuronske mreže da uspešno klasifikuje EEG podatke.

Hipoteza H2: *Metaheuristički algoritmi mogu značajno unaprediti performanse modela LSTM veštačke neuronske mreže u detekciji epileptičnih napada kod pacijenata.*

Potvrđeno: U ovoj naučno-istraživačkoj studiji uključena su testiranje modela LSTM veštačke neuronske mreže, uz primenu metaheurističkih optimizacija, konkretno genetskog algoritma (GA) i optimizacije roja čestica (PSO). Upoređeni su rezultati standardnog modela LSTM veštačke neuronske mreže i modela optimizovanih prethodno spomenutim metodama optimizacije hiperparametara, pri čemu je demonstrirano značajno poboljšanje u preciznosti i brzini klasifikacije epileptičnih napada kod pacijenata. Rezultati pokazuju da su optimizovani matematički modeli LSTM veštačke neuronske mreže postižu bolji balans između tačnosti i efikasnosti detekcije, što potvrđuje da metaheurističke metode poboljšavaju performanse modela LSTM veštačke neuronske mreže. Priložene tabele sa eksperimentalnim rezultatima jasno pokazuju kvantitativna poboljšanja u metrikama performansi, pri čemu PSO i GA optimizovani matematički modeli daju bolje rezultate u poređenju sa neoptimizovanim modelima.

Hipoteza H3: *Modifikovana pretraga putem algoritma varijabilne pretrage susedstva (VNS) može dodatno poboljšati prilagođavanje modela LSTM specifičnostima EEG signala.*

Potvrđeno: U ovoj disertaciji je opisano kako se modifikovana verzija algoritma varijabilne pretrage susedstva (VNS) uspešno primenjuje na optimizaciju hiperparametara modela LSTM veštačke neuronske mreže. Eksperimenti su pokazali da je VNS omogućio dodatna poboljšanja u tačnosti klasifikacije EEG signala, naročito u situacijama sa ograničenom količinom podataka. Upoređeni su rezultati klasične optimizacije hiperparametara i VNS metode, gde je pokazano da algoritmom varijabilne pretrage susedstva VNS poboljšava stabilnost i preciznost matematičkog modela LSTM veštačke neuronske mreže u različitim uslovima testiranja.

Na ovaj način je potvrđeno kroz Opštu (H0) i sve pojedinačne hipoteze (H1, H2, H3) da algoritam varijabilne pretrage susedstva VNS doprinosi boljoj generalizaciji matematičkog modela LSTM veštačke neuronske mreže na EEG podatke, što potvrđuje da izabrani pristup dodatno optimizuje proces detekcije epileptičnih napada.

Ovim naučno-istraživačkim radom je potvrđeno da sve postavljene hipoteze su ispunjene na osnovu eksperimentalnih rezultata, analiza u okviru naučno-istraživačkog rada, te konkretni pokazatelji (tačnost, preciznost, F1-score) jasno potvrđuju da:

- *Matematički modeli LSTM veštačkih neuronskih mreža mogu uspešno klasifikovati EEG podatke.*
- *Metaheuristički algoritmi optimizacije uspešno poboljšavaju performanse matematičkog modela LSTM veštačkih neuronskih mreža.*
- *Algoritam varijabilne pretrage susedstva (VNS) dodatno unapređuje matematički model LSTM veštačkih neuronskih mreža, posebno u slučaju EEG zapisa.*

Na kraju, ovo istraživanje je pružilo osnovu za dalja ispitivanja i inovacije u detekciji EEG anomalija, te potencijalno doprinelo unapređenju pristupa u oblasti zdravstvene zaštite, čime bi se stvorili uslovi za inovativne intervencije i poboljšanje životnog standarda pacijenata.

7.1. Oblici primene veštačke inteligencije u neurološkoj dijagnostici

Dalji razvoj primene veštačke inteligencije u neurološkoj dijagnostici zahteva multidisciplinarni pristup koji uključuje stručnjake iz oblasti neuronauke, računarstva, statistike i kliničke prakse. Integracija matematičkih modela veštačke inteligencije u kliničke tokove i praksu zahteva pažljivo razmatranje etičkih i regulatornih pitanja, kao i obezbeđivanje transparentnosti i objašnjivosti matematičkih modela veštačke inteligencije.

U kontekstu ovog naučno-istraživačkog rada, koji se fokusira na detekciju anomalija u EEG signalima pomoću modela LSTM veštačkih neuronskih mreža optimizovanih algoritmom varijabilne pretrage susedstva sa dinamičnom promenom strategije, dalji razvoj bi mogao uključiti sledeće aspekte opisane u nastavku ove naučno-istraživačke studije.

7.1.1. Integracija multimodalnih podataka

Buduća istraživanja treba da se fokusiraju na integraciju multimodalnih podataka, kao što su MRI, CT i PET snimci, koji zajedno sa EEG podacima bi poboljšali tačnost i robusnost novih matematičkih modela veštačke inteligencije u domenu medicinske neurodijagnostike. Integracija multimodalnih podataka omogućava sveobuhvatnije razumevanje neuroloških poremećaja i poboljšava dijagnostičku tačnost. U samom naučno-istraživačkom radu, fokus je svakako na analizi EEG signala, ali multimodalni pristup i integracija sa MRI snimcima bi mogla pružiti dodatne informacije o strukturalnim promenama u mozgu, što bi poboljšalo detekciju anomalija i poboljšanje životnog standarda pacijenata.

7.1.2. Personalizovana medicina

Matematički modeli veštačke inteligencije mogu se koristiti za razvoj personalizovanih pristupa dijagnostici i lečenju neuroloških poremećaja. Analizom individualnih pacijenata, matematički modeli veštačke inteligencije mogu predvideti odgovor na terapiju, optimizovati i u krajnjoj instanci personalizovati planove lečenja pacijenata. U budućim naučno-istraživačkim studijama, akcenat bi mogao biti na optimizovanim matematičkim modelima LSTM veštačkih neuronskih mreža koji bi se mogli prilagoditi individualnim karakteristikama pacijenata, što bi omogućilo personalizovanu detekciju epileptičkih napada ili drugih neuroloških događaja.

7.1.3. Realno vremenska analiza i praćenje

Razvoj sistema veštačke inteligencije koji bi mogli da prijem ulaznih podataka svedu na trenutne ulazne podatke direktno dobijene iz EEG uređaja (elektroda), bi praktično značilo da ti novi napredni sistemi veštačke inteligencije mogu da vrše akviziciju i analizu EEG signala u realnom vremenu. Na ovaj način bi se omogućilo kontinuirano praćenje (monitoring) pacijenata i pravovremeno otkrivanje neuroloških događaja. Ovi sistemi mogu se koristiti u bolničkim i kućnim uslovima, poboljšavajući kvalitet života pacijenata. Ova doktorska disertacija, sa fokusom na *lightweight* modele, je samo početak u analizi i definisanju budućih matematičkih modela za razvoj sistema veštačke inteligencije za praćenje EEG signala u realnom vremenu, sa minimalnim računarskim resursima, što je ključno za rano otkrivanje epileptičkih napada i kontinuirani monitoring pacijenata.

7.1.4. Objašnjiva veštačka inteligencija (XAI)

Razvoj objašnjivih matematičkih modela veštačke inteligencije je od ključnog značaja za izgradnju poverenja u sisteme veštačke inteligencije u medicinskoj praksi. XAI (*Explainable Artificial Intelligence*) tehnike omogućavaju lekarima i istraživačima da razumeju kako matematički modeli veštačke inteligencije donose odluke, što je od suštinskog značaja za kliničku primenu. U okviru ovog naučno-istraživačkog rada, opisana je primena SHAP interpretacije kao korak ka objašnjivosti matematičkih modela veštačke inteligencije, ali dalja

istraživanja bi mogla uključiti razvoj interaktivnih vizualizacija koje bi lekarima i istraživačima omogućile da bolje razumeju predikcije matematičkih modela veštačke inteligencije.

7.1.5. Korišćenje transfer učenja

Transfer učenje (*Transfer Learning*), kao tehnika u mašinskom učenju, omogućava da se model obučen na Transfer učenje, primeni na drugi skup podataka. U kontekstu medicinskih signala, Transfer učenje može značajno poboljšati performanse matematičkog modela veštačke inteligencije, posebno kada su dostupni mali skupovi podataka. Na primeru ove naučno-istraživačke studije, Transfer učenje bi se moglo koristiti za prilagođavanje matematičkog modela veštačke inteligencije na specifične grupe pacijenata ili za prenos znanja sa velikih javnih skupova podataka na manje kliničke skupove podataka.

7.1.6. Razvoj integrisanih sistema za podršku odlučivanju

Integracija modela veštačke inteligencije u integrisane sisteme za kliničku podršku odlučivanju (*Clinical Decision Support System*, CDSS) omogućava lekarima da donose informisane odluke na osnovu analiza multimodalnih modela veštačke inteligencije. Integrisani sistemi za kliničku podršku odlučivanju su sistemi koji mogu pružiti preporuke za dijagnostiku, lečenje i praćenje pacijenata. Ono što je važno napomenuti jeste da matematički modeli veštačke inteligencije i algoritmi mašinskog učenja koji su istraženi u okviru ovog naučno-istraživačkog rada bi se mogli u budućnosti integrisati u postojeće Integrisane sisteme za kliničku podršku (CDSS), pružajući lekarima informacije u realnom vremenu o EEG signalima pacijenata i preporuke za dalje dijagnostičke ili terapijske procedure.

7.1.7. Razvoj AI alata za kućno praćenje

Razvoj softverkih alata i uređaja koji su bazirani na sistemima veštačke inteligencije, a koji se odnose na kućno praćenje neuroloških poremećaja, omogućava pacijentima da prate svoje stanje kod kuće i dobijaju pravovremene povratne informacije. Ovi alati mogu poboljšati kvalitet života pacijenata i smanjiti potrebu za čestim posetama bolnici. Kao što je opisano u okviru ovog naučno-istraživačkog rada *lightweight* modeli su idealni za implementaciju u kućnim uređajima za praćenje EEG signala, pružajući pacijentima kontinuiranu 24x7 podršku.

7.1.8. Razvoj AI modela za detekciju retkih neuroloških bolesti

Razvoj modela veštačke inteligencije za detekciju retkih neuroloških bolesti predstavlja jedan izuzetan tehnički ali i društveni izazov, pre svega zbog nedostatka velikih skupova označenih i anonimiziranih podataka, kao i pravno-etičkih principa koji se moraju prilagoditi tehnološkom razvoju i slučajevima korišćenja u medicinskoj dijagnostici. Tako na primer primena tehnika transfer učenja i sintetičkih podataka može poboljšati performanse matematičkih modela veštačke inteligencije za detekciju retkih bolesti. Kao što je opisano u

okviru ove doktorske disertacije, tehnike generisanja sintetičkih EEG signala bi se mogle koristiti za obuku matematičkih modela na retkim neurološkim poremećajima i samim time iskoristiti saznanja o distribucijama skupova podataka i prethodni eksperimenti koji su obavljani na manjim skupovima označenih podataka.

7.1.9. Razvoj AI modela za predviđanje neuroloških bolesti

Razvoj modela veštačke inteligencije za predviđanje neuroloških bolesti omogućava identifikaciju osoba sa visokim rizikom za razvoj neuroloških poremećaja. Matematički modeli veštačke inteligencije koji su analizirani u okviru ovog naučno-istraživačkog rada mogu se koristiti u okviru medicinske neurodijagnostike kako za rano otkrivanje bolesti i tako i za preventivne mere koje bi svakako olakšale život pacijenata. Optimizovani matematički modeli LSTM veštačkih neuronskih mreža koju su obrađeni u okviru doktorske disertacije bi se mogli koristiti za predviđanje rizika od epileptičkih napada ili drugih neuroloških događaja na osnovu analize prethodnih dugoročnih i trenutnih EEG podataka pacijenata.

7.2. Inženjerske implikacije i primena optimizacionih algoritama

Optimizacioni algoritmi koji su primenjeni na matematičke modele veštačkih neuronskih mreža, i koji su detaljno opisani u okviru ovog naučno-istraživačkog rada, predstavljaju izuzetno važnu komponentnu sistema veštačke inteligencije pre svega zbog njihovih potencijalnih primena u rešavanju realnih inženjerskih problema, naglašavajući šire implikacije ovog naučno-istraživačkog rada izvan okvira akademije i realne primene u industriji, poput medicinske neurodijagnostike.

Ovaj aspekt je ključan jer omogućava inženjerima da primene naučene metode u stvarnim situacijama, čime se povećava ukupna efikasnost i kvalitet pruženih proizvoda i usluga, u ovom konkretnom slučaju iz domena medicinske neurodijagnostike.

7.2.1. Optimizacija hiperparametara mašinskog učenja

Optimizacioni algoritmi se koriste za optimizaciju hiperparametara sistema veštačke inteligencije, kao što su broj slojeva, broj neurona i stopa učenja. Optimizacija hiperparametara poboljšava performanse matematičkog modela i smanjuje vreme obuke, kao i potrebne računarske resurse.

U ovom kontekstu, primena algoritma varijabilnog susedstva (VNS) za optimizaciju hiperparametara dugoročne kratkoročne memorije (LSTM) modela veštačke neuronske mreže rezultirala je poboljšanim performansama u detekciji anomalija u okviru EEG signala. Ovaj pristup omogućava preciznije podešavanje matematičkog modela, što je ključno za postizanje visoke tačnosti u medicinskoj neurodijagnostici.

7.2.2. Optimizacija raspoređivanja resursa

Optimizacioni algoritmi se koriste za optimizaciju raspoređivanja resursa u sistemima sa trenutnom obradom podataka i odzivom u realnom vremenu, kao što su sistemi za praćenje pacijenata i sistemi za detekciju anomalija. Optimizacija raspoređivanja resursa poboljšava efikasnost sistema veštačke inteligencije i smanjuje troškove.

Optimizovani matematički modeli LSTM veštačkih neuronskih mreža se mogu koristiti za efikasno raspoređivanje računarskih resursa u sistemima sa odzivom u realnom vremenu, kao što je praćenje elektroencefalografskih (EEG) signala. Ovo je posebno važno u situacijama gde je potrebno obraditi velike količine podataka u kratkom vremenskom periodu, kao što je praćenje pacijenata u jedinicama intenzivne nege.

7.2.3. Optimizacija kontrolnih sistema

Optimizacioni algoritmi se koriste za optimizaciju kontrolnih sistema u medicinskim uređajima, kao što su insulinske pumpe i respiratori. Optimizacija kontrolnih sistema poboljšava tačnost i pouzdanost medicinskih uređaja.

Iako se ovaj naučno-istraživački rad ne bavi direktno kontrolnim sistemima, optimizovani modeli LSTM veštačkih neuronskih mreža se mogu koristiti za kontrolu medicinskih uređaja na osnovu analize EEG signala. Na primer, optimizovani matematički modeli LSTM veštačke neuronske mreže može analizirati EEG signale pacijenta i automatski prilagoditi parametre respiratora kako bi se optimizovala ventilacija kod pacijenta.

7.2.4. Optimizacija dizajna medicinskih uređaja

Optimizacioni algoritmi se koriste za optimizaciju dizajna medicinskih uređaja, kao što su implantati i protetika. Optimizacija dizajna medicinskih uređaja poboljšava funkcionalnost i udobnost za pacijente.

Optimizovani matematički modeli LSTM veštačke neuronske mreže se mogu koristiti za analizu EEG signala i prilagođavanje parametara medicinskih uređaja, kao što su neurostimulatori, kako bi se optimizovala terapija za svakog pacijenta. Ovo omogućava personalizovan pristup lečenju, što je ključno za postizanje boljih ishoda.

7.2.5. Optimizacija protoka podataka

Optimizacioni algoritmi se koriste za optimizaciju protoka podataka u medicinskim informacionim sistemima, kao što su sistemi za elektronske zdravstvene kartone i sistemi za telemedicine.

Optimizacija protoka podataka poboljšava efikasnost i sigurnost medicinskih informacionih sistema. Praktično optimizovani matematički modeli LSTM veštačke neuronske mreže se mogu koristiti za analizu velikih skupova EEG podataka i optimizaciju protoka informacija u sistemima za telemedicine, omogućavajući brzu i efikasnu dijagnostiku i praćenje

pacijenata. Ovo je posebno važno u ruralnim područjima gde pacijenti definitivno nemaju lak pristup specijalističkim uslugama.

7.3. Etička i regulatorna razmatranja

Primena sistema veštačke inteligencije u neurološkoj dijagnostici zahteva pažljivo razmatranje etičkih i regulatornih pitanja. Osiguravanje privatnosti, anonimizacija i sigurnosti podataka pacijenata, kao i transparentnost i objašnjivost modela veštačke inteligencije, ključni su za izgradnju poverenja u sisteme veštačke inteligencije u medicinskoj praksi.

7.3.1. Privatnost i sigurnost podataka

Modeli veštačke inteligencije se obučavaju na velikim skupovima podataka pacijenata, što postavlja pitanja o privatnosti i sigurnosti podataka. Osiguravanje anonimizacije podataka i primena sigurnosnih mera ključni su za zaštitu privatnosti pacijenata.

Korišćenje javno dostupnih skupova podataka smanjuje rizik od kršenja privatnosti, ali dalja istraživanja bi trebalo da se fokusiraju na razvoj tehnika za anonimizaciju kliničkih podataka i korišćenje sintetičkih podataka na bazi poznatih distribucija. Ovo uključuje razvoj algoritama mašinskog učenja podataka koji mogu ukloniti lične informacije iz podataka bez gubitka njihove korisnosti za obuku matematičkog modela veštačke inteligencije.

7.3.2. Transparentnost i objašnjivost

Sistemi veštačke inteligencije se često smatraju crnim kutijama, što otežava razumevanje kako dati sistemi veštačke inteligencije donose konačne odluke. Razvoj transparentnih i objašnjivih matematičkih modela veštačke inteligencije ključan je za izgradnju poverenja u sisteme veštačke inteligencije u medicinskoj praksi.

Primena SHAP interpretacije je korak ka objašnjivosti matematičkih modela veštačke inteligencije, ali dalja istraživanja bi trebalo da se fokusiraju na razvoj interaktivnih vizualizacija i alata za interpretaciju matematičkih modela veštačke inteligencije. Ovo omogućava lekarima da razumeju kako matematički modeli veštačke inteligencije donose odluke i samim time procene pouzdanost predloženih odluka koje mogu da imaju uticaje na treatment pacijenata.

7.3.3. Odgovornost i nadzor

Primena sistema veštačke inteligencije u kliničkoj praksi zahteva definisanje adekvatne odgovornosti i nadzora. Lekari treba da budu odgovorni za odluke koje donose na osnovu analiza koje sprovode matematički modeli veštačke inteligencije, a regulatorni organi treba da obezbede nadzor nad razvojem i primenom svih sistema veštačke inteligencije koji imaju svojou primenu u društvu i na posletku kliničkoj praksi kada je u pitanju oblast poput medicinske neurodijagnostike.

Naglašavanje uloge lekara u verifikaciji odluka i informacija koje je predstavio sistem veštačke inteligencije, poput predikcije i dijagnoze, je ključno za osiguravanje odgovornosti i nadzora. Ovo uključuje razvoj smernica i standarda za upotrebu sistema veštačke inteligencije u medicinskoj praksi.

7.3.4. Pristrasnost i pravičnost

Sistemi veštačke inteligencije mogu biti pristrasni ako se obučavaju na nebalansiranim skupovima podataka. Osiguravanje pravičnosti i izbegavanje diskriminacije ključni su za etičku primenu matematičkih modela veštačke inteligencije u medicinskoj praksi.

Korišćenje neuravnoteženih skupova podataka u jednom od eksperimenata naglašava potrebu za pažljivim razmatranjem pristrasnosti u matematičkim modelima veštačke inteligencije. Ovo svakako uključuje I razvoj tehnika za detekciju i ublažavanje pristrasnosti matematičkih modela veštačke inteligencije.

7.3.5. Autonomija pacijenata

Primena sistema veštačke inteligencije u medicinskoj praksi treba da poštuje autonomiju pacijenata. Pacijenti treba da budu informisani o primeni sistema veštačke inteligencije i da imaju pravo da odbiju korišćenje sistema veštačke inteligencije.

Naglašavanje transparentnosti i objašnjivosti matematičkog modela veštačke inteligencije je ključno za osiguravanje autonomije pacijenata. Ovo uključuje razvoj jasnih i razumljivih informacija o upotrebi sistema veštačke inteligencije u medicinskoj praksi.

7.4. Zaključak

Ova naučno-istraživačka studija je pružila solidnu osnovu za dalja ispitivanja i inovacije u detekciji anomalija u EEG signalima, otvarajući vrata za potencijalno značajno unapređenje pristupa u oblasti zdravstvene zaštite.

Kroz razvoj i primenu optimizovanih matematičkih modela LSTM veštačkih neuronskih mreža, demonstrirana je mogućnost stvaranja uslova za inovativne intervencije koje mogu direktno uticati na poboljšanje životnog standarda pacijenata.

Dalji razvoj primene sistema veštačke inteligencije u neurološkoj dijagnostici zahteva sveobuhvatan, multidisciplinarni pristup. Neophodna je bliska saradnja između stručnjaka iz različitih oblasti, uključujući neuronauku, računarstvo, statistiku i kliničku praksu.

Integracija multimodalnih podataka, kao što su MRI, CT i PET snimci, zajedno sa EEG podacima, predstavlja ključni korak ka poboljšanju tačnosti i robusnosti matematičkih modela veštačke inteligencije.

Ovakva integracija omogućava sveobuhvatnije razumevanje kompleksnih neuroloških poremećaja i značajno unapređuje dijagnostičku tačnost.

Razvoj personalizovanih pristupa dijagnostici i lečenju neuroloških poremećaja je još jedan važan pravac daljeg razvoja koji se može očekivati u bliskoj budućnosti.

Sistemi veštačke inteligencije, prilagođeni individualnim karakteristikama pacijenata, mogu predvideti odgovor na terapiju i optimizovati planove lečenja, čime se povećava efikasnost terapijskih intervencija kod pacijenata.

Analiza i praćenje EEG signala u realnom vremenu, potpomognuti razvojem efikasnih sistema veštačke inteligencije, predstavlja ključni napredak u kontinuiranom praćenju pacijenata i podršci po modelu 24x7.

Ovi sistemi, primenljivi kako u bolničkim, tako i u kućnim uslovima, omogućavaju pravovremeno otkrivanje neuroloških događaja i značajno poboljšavaju kvalitet života pacijenata.

Objašnjiva veštačka inteligencija (XAI) igra ključnu ulogu u izgradnji poverenja u sisteme veštačke inteligencije u medicinskoj praksi. XAI tehnike omogućavaju lekarima da razumeju kako matematički modeli veštačke inteligencije donose odluke, što je od suštinskog značaja za kliničku primenu i donošenje informisanih odluka.

Korišćenje transfer učenja, kao tehnike mašinskog učenja, omogućava efikasnu primenu modela obučanih na velikim skupovima podataka na specifične, manje skupove podataka, što je posebno korisno u kontekstu retkih neuroloških bolesti.

Razvoj integrisanih sistema za podršku kliničkom odlučivanju (CDSS) omogućava lekarima da donose informisane odluke na osnovu analiza matematičkih modela veštačke inteligencije, pružajući preporuke za dijagnostiku, lečenje i praćenje pacijenata.

Alati i uređaji koji su bazirani na veštačkoj inteligenciji, a koji se koriste za kućno praćenje neuroloških poremećaja, omogućavaju pacijentima da prate svoje stanje kod kuće, dobijajući pravovremene povratne informacije, čime se poboljšava kvalitet života i smanjuje potreba za čestim posetama bolnici.

Razvoj novih matematičkih modela veštačke inteligencije za detekciju retkih neuroloških bolesti, iako predstavlja izazov zbog nedostatka velikih skupova podataka, može se unaprediti primenom tehnika transfer učenja i sintetičkih podataka.

Ono što možemo očekivati u bliskoj budućnosti da uređaji bazirani na matematičkim modelima veštačke inteligencije će biti sposobni za predviđanje neuroloških bolesti i na taj način će omogućiti identifikaciju osoba sa visokim rizikom, ujedno omogućavajući rano otkrivanje i preventivne mere kod različitih neuroloških oboljenja.

Integracija matematičkih modela veštačke inteligencije sa genetskim podacima omogućava identifikaciju genetskih faktora rizika, otvarajući put za razvoj personalizovanih terapija i predviđanje odgovora na lečenje.

Primena optimizacionih algoritama u inženjerskim problemima, kao što su optimizacija hiperparametara matematičkih modela sistema veštačke inteligencije, optimizacija raspoređivanja resursa, optimizacija kontrolnih sistema, optimizacija dizajna medicinskih uređaja i optimizacija protoka podataka, može značajno unaprediti efikasnost i kvalitet pruženih zdravstvenih usluga, čime se direktno doprinosi poboljšanju životnog standarda pacijenata.

Pored toga svega prethodno navedenog, vrlo je važno još jednom napomenuti da pažljivo razmatranje etičkih i regulatornih pitanja, kao što su privatnost i sigurnost podataka pacijenata, transparentnost i objašnjivost matematičkih modela veštačke inteligencije, odgovornost i nadzor, pristrasnost i pravičnost, kao i autonomija pacijenata u prihvatanju ili ne prihvatanju odluka i dijagnoza sistema veštačke inteligencije, su esencijalni za izgradnju poverenja u sisteme veštače inteligencije u medicinskoj praksi.

Literatura

- [1] Abbasi, B., & Goldenholz, D. M. (2019). *Machine learning applications in epilepsy*. *Epilepsia*, 60(10), 2037–2047. <https://doi.org/10.1111/epi.16333>
- [2] Acharya, U. R., Vinitha Sree, S., Swapna, G., Martis, R. J. & Suri, J. S. (2013). *Automated EEG analysis of epilepsy: A review*. *Knowledge-Based Systems*, 45, 147–165. <https://doi.org/10.1016/j.knosys.2013.02.014>
- [3] Amin, U. & Benbadis, S. R. (2019). *The role of EEG in the erroneous diagnosis of epilepsy*. *Journal of Clinical Neurophysiology*, 36(4), 294–297. <https://doi.org/10.1097/WNP.0000000000000572>
- [4] Andrzejak, R. G., Lehnertz, K., Mormann, F., Rieke, C., David, P. & Elger, C. E. (2001). *Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state*. *Physical Review E*, 64(6), 061907. <https://doi.org/10.1103/PhysRevE.64.061907>
- [5] Badi, I., Bouraima, M. B., Qiu, Y. & Stevic, Z. (2024). *Optimizing priority sequencing rules in parallel machine scheduling: An evaluation and selection approach using hybrid MCDM techniques*. *Decision Making Advances*, 2(1), 22–31. <https://doi.org/10.31181/dma21202422>
- [6] Benarous, L., Gavaret, M., Soda Diop, M., Tobarias, J., de Ghaisne de Bourmont, S., 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. <https://doi.org/10.1016/j.cnp.2018.12.001>
- [7] 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. <https://doi.org/10.1684/epd.2020.1151>
- [8] Benbadis, S. R. & Kaplan, P. W. (2019). *The dangers of over-reading an EEG*. *Journal of Clinical Neurophysiology*, 36(4), 249. <https://doi.org/10.1097/WNP.0000000000000598>
- [9] Bendjoudi, A., & Benyettou, A. (2014). *A hybrid approach for the classification of satellite images using MLP and genetic algorithm*. ResearchGate. <https://www.researchgate.net/publication/265784353>

- [10] Bezdan, T., Milosevic, S., Zivkovic, M. Bacanin, N. & Strumberger, I. (2021). *Optimizing convolutional neural network by hybridized elephant herding optimization algorithm for magnetic resonance image classification of glioma brain tumor grade*. In 2021 Zooming Innovation in Consumer Technologies Conference (ZINC) (pp. 171–176). IEEE. <https://doi.org/10.1109/ZINC52049.2021.9499297>
- [11] Brimberg, J., Mladenović, N. & Urošević, D. (2015). *Solving the maximally diverse grouping problem by skewed general variable neighborhood search*. Information Sciences, 295, 650–675. <https://doi.org/10.1016/j.ins.2014.10.043>
- [12] Brar, D. S., Nayik, G. A. & Tolcha, T. D. (2023). *Chemical and functional characteristics to detect sugar syrup adulteration in honey from different botanical origins*. International Journal of Food Properties, 26(1), 1390–1413. <https://doi.org/10.1080/10942912.2023.2218066>
- [13] Casson, A. J. (2019). Wearable EEG technology: Current status and future prospects. IEEE Sensors Journal, 19(13), 4950–4958. <https://doi.org/10.1109/JSEN.2019.2904694>
- [14] Casson, A. J., Yates, D. C. & Rodrigues, J. (2010). Wearable EEG and beyond: A review of recent advances in ambulatory EEG. Journal of Neural Engineering, 7(1), 011001. <https://doi.org/10.1088/1741-2560/7/1/011001>
- [15] Cheng, R., Li, M., Tian, Y., Xiang, X., Zhang, X., Yang, S., Jin, Y. & Yao, X. (2018). Benchmark functions for the CEC'2018 competition on many-objective optimization. Technical report.
- [16] Chopra, J., Kumar, A., Aggarwal, A. K. & Marwaha, A. (2018). An efficient watermarking for protecting signature biometric template. In 2018 5th International Conference on Signal Processing and Integrated Networks (SPIN) (pp. 413–418). IEEE. <https://doi.org/10.1109/SPIN.2018.8474269>
- [17] Cover, T. M., & Thomas, J. A. (2006). Elements of information theory (2nd ed.). Wiley.
- [18] Cuk, A., Bezdan, T., Jovanovic, L., Antonijevic, M., Stankovic, M., Simic, V., Zivkovic, M. & Bacanin, N. (2024). Tuning attention-based long-short term memory neural networks for Parkinson's disease detection using modified metaheuristics. Scientific Reports, 14(1), 4309. <https://doi.org/10.1038/s41598-024-54680-y>
- [19] Daubechies, Ingrid. 1992. *Ten Lectures on Wavelets*. Philadelphia, PA: Society for Industrial and Applied Mathematics (SIAM). ISBN 0-89871-274-2. 357 pages.

- [20] Devi V, K., Mani, J., Shaker, H. & Jovanovic, L. (2023). Sunspot occurrence forecasting with metaheuristic optimized recurrent neural networks. *Theoretical and Applied Computational Intelligence*, 1(1), 15–26. <https://doi.org/10.31181/tacil120231>
- [21] Draper, N. R. & Smith, H. (1998). *Applied regression analysis* (3rd ed.). Wiley.
- [22] Du, Z., Xie, X., Qu, Z., Hu, Y. & Stojanovic, V. (2024). Dynamic event-triggered consensus control for interval type-2 fuzzy multi-agent systems. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 1–10. <https://doi.org/10.1109/TCSI.2024.3371492>
- [23] European Commission. (2019). Ethics guidelines for trustworthy AI. <https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>
- [24] Foreman, S. A., Giedt, J., Meurice, Y., & Unmuth-Yockey, J. (2017). *RG inspired Machine Learning for lattice field theory*. ResearchGate. https://www.researchgate.net/figure/Schematic-representation-of-Frank-Rosenblatts-perceptron-3_fig1_320241761
- [25] Goodfellow, I., Bengio, Y. & Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org>
- [26] Graves, A. (2013). Speech recognition with deep recurrent neural networks. In 2013 IEEE International Conference on Acoustics, Speech and Signal Processing (pp. 6645–6649). IEEE. <https://doi.org/10.1109/ICASSP.2013.6639347>
- [27] Gurrola-Ramos, J., Hernández-Aguirre, A. & Dalmau-Cedeño, O. (2020). Colshade for real-world single-objective constrained optimization problems. In 2020 IEEE Congress on Evolutionary Computation (CEC) (pp. 1–8). IEEE. <https://doi.org/10.1109/CEC48606.2020.9185583>
- [28] Guttag, J. (2010). CHB-MIT Scalp EEG Database (version 1.0.0). PhysioNet. <https://doi.org/10.13026/C2K01R>
- [29] Hajjaliasghari, M., Sadeghian, A., & Moradi, M. H. (2020). *A conceptual review of neural networks*. ResearchGate. https://www.researchgate.net/figure/A-The-structure-of-the-McCulloch-and-Pitts-neuron-model-i-i-i-i-i-stands-for-the_fig1_346206645

- [30] Hansen, P., Mladenovic, N. & Urošević, D. (2006). Variable neighborhood search and local branching. *Computers & Operations Research*, 33(10), 3034–3045. <https://doi.org/10.1016/j.cor.2005.02.033>
- [31] Haq, H. B. & Saqlain, M. (2023). An implementation of effective machine learning approaches to perform Sybil attack detection (SAD) in IoT network. *Theoretical and Applied Computational Intelligence*, 1(1), 1–14. <https://doi.org/10.31181/taci1120232>
- [32] Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.
- [33] 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>
- [34] Katoch, S., Chauhan, S. S. & Kumar, V. (2021). A review on genetic algorithm: Past, present, and future. *Multimedia Tools and Applications*, 80(5), 8091–8126. <https://doi.org/10.1007/s11042-020-10139-6>
- [35] Kaur, P., Kumari, M. & Gupta, P. (2021). Deep learning in EEG signal analysis: A review. *Neural Computing and Applications*, 33(8), 2611–2630. <https://doi.org/10.1007/s00521-020-05016-3>
- [36] Kaur, T., Diwakar, A., Kirandeep, Mirpuri, P., Tripathi, M., Chandra, P. S. & Gandhi, T. K. (2021). Artificial intelligence in epilepsy. *Neurology India*, 69(3), 560–566. <https://doi.org/10.4103/0028-3886.317233>
- [37] Kennedy, J. & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks* (Vol. 4, pp. 1942–1948). IEEE. <https://doi.org/10.1109/ICNN.1995.488968>
- [38] Khishe, M. & Mosavi, M. R. (2020). Chimp optimization algorithm. *Expert Systems with Applications*, 149, 113338. <https://doi.org/10.1016/j.eswa.2020.113338>
- [39] Kumar, A., Das, S. & Zelinka, I. (2020). A self-adaptive spherical search algorithm for real-world constrained optimization problems. In *Proceedings of the 2020 Genetic and Evolutionary Computation Conference Companion* (pp. 13–14). ACM. <https://doi.org/10.1145/3377929.3398186>
- [40] 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/10.1016/j.swevo.2021.100973>

- [41] LeCun, Y., Bengio, Y. & Hinton, G. (2015). *Deep learning*. Nature, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- [42] Liu, T., Truong, N. D., Nikpour, A., Zhou, L. & Kavehei, O. (2020). *Epileptic seizure classification with symmetric and hybrid bilinear models*. IEEE Journal of Biomedical and Health Informatics, 24(10), 2844–2851. <https://doi.org/10.1109/JBHI.2020.2984128>
- [43] Lundberg, S. M. & Lee, S.-I. (2017). *A unified approach to interpreting model predictions*. In Advances in Neural Information Processing Systems (Vol. 30). <https://proceedings.neurips.cc/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf>
- [44] McCulloch, W. S. & Pitts, W. (1943). *A logical calculus of the ideas immanent in nervous activity*. The Bulletin of Mathematical Biophysics, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- [45] Minic, A., Jovanovic, L., Bacanin, N., Stoean, C., Zivkovic, M., Spalevic, P., Petrovic, A., Dobrojevic, M. & Stoean, R. (2023). *Applying recurrent neural networks for anomaly detection in electrocardiogram sensor data*. Sensors, 23(24). <https://doi.org/10.3390/s23249878>
- [46] Niedermeyer, E. & da Silva, F. L. (2005). *Electroencephalography: Basic principles, clinical applications, and related fields* (5th ed.). Lippincott Williams & Wilkins.
- [47] Noachtar, S. & Rémi, J. (2009). *The role of EEG in epilepsy: A critical review*. Epilepsy & Behavior, 15(1), 22–33. <https://doi.org/10.1016/j.yebeh.2009.02.035>
- [48] Oppenheim, A. V. & Schafer, R. W. (2010). *Discrete-time signal processing* (3rd ed.). Prentice Hall.
- [49] 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. <https://doi.org/10.1016/j.nicl.2014.09.017>
- [50] Pascanu, R., Mikolov, T. & Bengio, Y. (2013). *On the difficulty of training recurrent neural networks*. In Proceedings of the 30th International Conference on Machine Learning (pp. 1310–1318). PMLR. <https://proceedings.mlr.press/v28/pascanu13.html>

- [51] Pilcevic, D., Djuric Jovicic, M., Antonijevic, M., Bacanin, N., Jovanovic, L., Zivkovic, M., Dragovic, M. & Bisevac, P. (2023). *Performance evaluation of metaheuristics-tuned recurrent neural networks for electroencephalography anomaly detection*. *Frontiers in Physiology*, 14. <https://doi.org/10.3389/fphys.2023.1267011>
- [52] Prakash, S. P. & Kumar, M. V. (2022). *Hybrid GLFIL enhancement and encoder animal migration classification for breast cancer detection*. *Computer Systems Science and Engineering*, 41(2), 735–749. <https://doi.org/10.32604/csse.2022.020533>
- [53] Radomirovic, B., Bacanin, N., Jovanovic, L., Simic, V., Njegus, A., Pamucar, D., Koppen, M., Zivkovic, M. (2024) *Optimizing Long-short Term Memory Neural Networks for Electroencephalogram Anomaly Detection using Variable Neighborhood Search with Dynamic Strategy Change*. *Complex & Intelligent Systems*. <https://link.springer.com/article/10.1007/s40747-024-01592-z>
- [54] Rasheed, K., Qayyum, A., Qadir, J., Sivathamboo, S., Kwan, P., Kuhlmann, L., O'Brien, T. & Razi, A. (2021). *Machine learning for predicting epileptic seizures using EEG signals: A review*. *IEEE Reviews in Biomedical Engineering*, 14, 139–155. <https://doi.org/10.1109/RBME.2020.3008792>
- [55] Ross, S. M. (2014). *Introduction to probability models* (11th ed.). Academic Press.
- [56] Rudin, W. (1976). *Principles of mathematical analysis* (3rd ed.). McGraw-Hill.
- [57] Rumelhart, D. E., Hinton, G. E. & Williams, R. J. (1986). *Learning representations by back-propagating errors*. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- [58] Sak, H., Senior, A. & Beaufays, F. (2014). *Long short-term memory recurrent neural network architectures for large scale acoustic modeling*. In *Proceedings of the 15th Annual Conference of the International Speech Communication Association* (pp. 338–342). ISCA. https://www.isca-speech.org/archive/interspeech_2014/i14_0338.html
- [59] Saqlain, M. & Saeed, M. (2024). *From ambiguity to clarity: Unraveling the power of similarity measures in multi-polar interval-valued intuitionistic fuzzy soft sets*. *Decision Making Advances*, 2(1)
- [60] Saqlain, M. & Saeed, M. (2024). *Recent advances in deep learning for biomedical signal processing*. *Biomedical Signal Processing and Control*, 75, 103343. <https://doi.org/10.1016/j.bspc.2023.103343>

- [61] 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>
- [62] Shi, Y. (2011). *Brain storm optimization algorithm*. In Y. Tan, Y. Shi, Y. Chai & G. Wang (Eds.), *Advances in Swarm Intelligence* (pp. 303–309). Springer. https://doi.org/10.1007/978-3-642-21515-5_36
- [63] Song, X., Peng, Z., Song, S. & Stojanovic, V. (2024). *Anti-disturbance state estimation for PDT-switched RDNNs utilizing time-sampling and space-splitting measurements*. Communications in Nonlinear Science and Numerical Simulation, 132, 107945. <https://doi.org/10.1016/j.cnsns.2024.107945>
- [64] Song, X., Wu, N., Song, S., Zhang, Y. & Stojanovic, V. (2023). *Bipartite synchronization for cooperative-competitive neural networks with reaction–diffusion terms via dual event-triggered mechanism*. Neurocomputing, 550, 126498. <https://doi.org/10.1016/j.neucom.2023.126498>
- [65] Stewart, J. (2015). *Calculus: Early transcendentals* (8th ed.). Cengage Learning.
- [66] 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. <https://doi.org/10.1016/j.clinph.2018.01.019>
- [67] Thukral, R., Gulshan, K., Kumar, A. & Arora, A. S. (2020). *Effects of different radiations of electromagnetic spectrum on human health*. In 2020 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS) (pp. 1–6). IEEE. <https://doi.org/10.1109/SCEECS48394.2020.154>
- [68] Todosijević, R., Hanafi, S., Urošević, D. & Jarboui, B. (2017). *A general variable neighborhood search for the swap-body vehicle routing problem*. Computers & Operations Research, 78, 468–479. <https://doi.org/10.1016/j.cor.2016.01.016>
- [69] Todosijević, R., Mjirda, A., Mladenović, M., Hanafi, S. & Gendron, B. (2017). *A general variable neighborhood search variants for the travelling salesman problem with draft limits*. Optimization Letters, 11(6), 1047–1056. <https://doi.org/10.1007/s11590-014-0788-9>
- [70] Todosijević, R., Urošević, D., Mladenović, N. & Hanafi, S. (2017). *A general variable neighborhood search for solving the uncapacitated r-allocation p-hub median*

problem. Optimization Letters, 11(6), 1109–1121. <https://doi.org/10.1007/s11590-015-0867-6>

- [71] Tochaiwat, K., Pultawee, P. & Rinchumphu, D. (2023). *Sales rate forecasting of single detached houses using artificial neural network technique*. Decision Making: Applications in Management and Engineering, 6(2), 772–786. <https://doi.org/10.31181/dmame622023707>
- [72] Vuković, D., Petrović, M. & Jovanović, M. (2019). *Implementation of artificial intelligence in healthcare: The case of Serbia*. Journal of Medical Systems, 43(5), 1–9. <https://doi.org/10.1007/s10916-019-1234-5>
- [73] Wilcoxon, F. (1992). *Individual comparisons by ranking methods*. In S. Kotz & N. L. Johnson (Eds.), *Breakthroughs in statistics: Methodology and distribution* (pp. 196–202). Springer. https://doi.org/10.1007/978-1-4612-4380-9_16
- [74] Wolpert, D. H. & Macready, W. G. (1997). *No free lunch theorems for optimization*. IEEE Transactions on Evolutionary Computation, 1(1), 67–82. <https://doi.org/10.1109/4235.585893>
- [75] Yang, X.-S. & Gandomi, A. H. (2012). *Bat algorithm: A novel approach for global engineering optimization*. Engineering Computations, 29(5), 464–483. <https://doi.org/10.1108/02644401211235834>
- [76] Yang, X.-S. & Slowik, A. (2020). *Firefly algorithm*. In *Swarm intelligence algorithms* (pp. 163–174). CRC Press.
- [77] Zhang, Y., Dong, Z., Liu, S., Wang, Y. & Shen, D. (2020). *Multi-modal classification of Alzheimer's disease and mild cognitive impairment using deep learning*. NeuroImage: Clinical, 25, 102181. <https://doi.org/10.1016/j.nicl.2020.102181>
- [78] Zivkovic, M., Bacanin, N., Antonijevic, M., Nikolic, B., Kvascev, G., Marjanovic, M. & Savanovic, N. (2022). *Hybrid CNN and XGBoost model tuned by modified arithmetic optimization algorithm for COVID-19 early diagnostics from X-ray images*. Electronics, 11(22). <https://doi.org/10.3390/electronics11223798>

Spisak akronima

ANN Artificial Neural Network

EEG Electroencephalography

AI Artificial Intelligence

RNN Recurrent Neural Network

LSTM Long-Short Term Memory

VNS Variable Neighborhood Search

MRI Magnetic Resonance Imaging

PET Positron Emission Tomography

ML Machine Learning

SVC Support Vector Classifiers

SVM Support Vector Machine

RF Random Forest

DTI Diffusion Tensor Imaging

CNN Convolutional Neural Network

GA Genetic Algorithm

PSO Particle Swarm Optimization

BA Bat Algorithm

BSO Brainstorm Optimization

ChOA Chimp Optimization Algorithm

SASS Self-Adaptive Step-Size Search

COLSHADE

NTSA NeuroTechnology and Systems Analysis

BPTT Backpropagation Through Time

ReLU Rectified Linear Unit

SVC Support Vector Classifiers

SVM Support Vector Machine

BiLSTM Bidirectional LSTM

GRU Gated Recurrent Unit

MLP Multilayer Perceptron

SDG Stochastic Gradient Descent

PMF Probability Mass Function

PDF Probability Density Function

MSE Mean Squared Error

GNN Graph Neural Networks

DNN Deep Neural Network

CSP Common Spatial Patterns

CV Computer Vision

NLP Natural Language Processing

NLU Natural Language Understanding

GDPR General Data Protection Regulation

HIPAA Health Insurance Portability and Accountability Act

PHI Protected Health Information

SHAP SHapley Additive exPlanations

LIME Local Interpretable Model-agnostic Explanations

XAI Explainable Artificial Intelligence

IoT Internet of Things

CDSS Clinical Decision Support System

Adam Adaptive Moment Estimation

RMSprop Root Mean Square Propagation

Adagrad Adaptive Gradient

AdaDelta Adaptive Delta

Nadam Nesterov-accelerated Adaptive Moment Estimation

AMSGrad Adaptive Moment Estimation with AMSGrad fix

BFGS Broyden–Fletcher–Goldfarb–Shanno algorithm

L-BFGS Limited-memory Broyden–Fletcher–Goldfarb–Shanno algorithm

EOG Electrooculography

EMG Electromyography

REM Rapid Eye Movement

RMSE Root Mean Squared Error

CEC Congress on Evolutionary Computation