

UNIVERZITET U BEOGRADU
ELEKTROTEHNIČKI FAKULTET



**DETEKCIJA EPILEPTIČNIH FENOMENA U PREKLINIČKIM
STUDIJAMA PRIMENOM BIOS ANALIZE EEG SIGNALA I
VEŠTAČKIH NEURALNIH MREŽA**

Master rad

Mentor:

Dr Milica Janković

Kandidat:

Andrijana Pušica
2016/3174

Beograd, Decembar 2017.

Zahvalnica

Zahvaljujem se doc. dr Draganu Hrnčiću i Marku Vorkapiću iz Laboratorije za neurofiziologiju Instituta za medicinsku fiziologiju 'Rihard Burian', Medicinski fakultet u Beogradu.

Takođe se zahvaljujem i dr Milici Janković i dr Andreju Saviću i Laboratoriji za Biomedicinsko inženjerstvo i tehnologije Univerziteta u Beogradu.

SADRŽAJ

SADRŽAJ	II
1. UVOD	3
1.1. ELEKTROENCEFALOGRAFIJA (EEG).....	4
1.2. BIOS SIGNALI.....	5
1.3. VEŠTAČKA NEURALNA MREŽA	7
2. PREKLINIČKA STUDIJA	9
2.1.1. <i>Akvizicija EEG signala</i>	11
3. IZDVAJANJE OBELEŽJA	12
3.1. FILTRIRANJE EEG SIGNALA.....	12
3.1.1. <i>Notch filter</i>	12
3.1.2. <i>Bandpass filter</i>	13
3.1.3. <i>Filter za uklanjanje bazne linije</i>	14
3.1.4. <i>Moving average filter</i>	15
3.2. BIOS DATA ANALYSER.....	16
3.2.1. <i>Izometrija i grafičko prikazivanje rekurentnosti</i>	17
3.2.2. <i>Originalnost</i>	18
3.2.3. <i>Uzastopna rekurentnost</i>	18
3.2.4. <i>Uređenost</i>	18
3.2.5. <i>Embedding plots</i>	19
3.2.6. <i>Diverzifikacija</i>	19
3.3. EKSTRAKCIJA KARAKTERISTIKA.....	19
3.4. FORMATIRANJE IZLAZA	29
4. OBUČAVANJE NEURALNE MREŽE	30
4.1. NEURAL NETWORK PATTERN RECOGNITION TOOL	30
4.2. OBUČAVANJE NEURALNE MREŽE	31
5. REZULTATI I DISKUSIJA	32
6. ZAKLJUČAK	36
LITERATURA	37
SPISAK SLIKA I TABELA	39

1. UVOD

Epilepsija je bolest koja pogađa oko 50 miliona ljudi širom sveta i manifestuje se kroz iznenadne iscrpljujuće napade tokom kojih osoba potencijalno može dodatno da se povredi [1]. U odnosu na (ne)poznavanje uzročnika koji izazivaju epilepsiju, ona se klasifikuje u dve grupe: idiopatsku i simptomatsku. Idiopatska epilepsija se javlja kod 60% populacije pogođene ovom bolešću i kod nje nije poznat tačan uzročnik. Kod simptomatske epilepsije uzročnik je poznat i može biti povreda glave, tumor na mozgu, infekcija mozga ili nedostatak dotoka kiseonika u mozak [2]. Još uvek ne postoji poznati lek za epilepsiju, već se napadi mogu držati pod kontrolom korišćenjem pogodnih medikamenata.

Uspešna automatizacija detekcije epileptičnih napada prvi put se pojavila još sredinom '70tih godina prošlog veka. Mnogi istraživači su osim neuralnih mreža za klasifikaciju koristili i metode poput poređenja sa *threshold*-om i filtriranja za detekciju abnormalnih aktivnosti unutar EEG zapisa [3]. Za postizanje preciznijih rezultata nakon filtriranja i poređenja sa *threshold*-om neki istraživači koriste i genetičke algoritme [4]. *Wavelet* transformacija kao metoda se pokazala kao prilično uspešnom u klasifikovanju patoloških delova EEG signala. Mnogo istraživači koristili su ih kao sredstvo za formiranje ulaznih parametara prilikom kreiranja neuralne mreže [5]. *Wavelet* transformacija korišćena je i kao ulaz za Bajasov *k*-nn klasifikator (*k*-*Nearest Neighbour*) u nekim radovima [6]. Osim neuralnih mreža za klasifikaciju iktalne aktivnosti od ostatka EEG signala korišćena je *Support Vector Machine* [7][8].

Poslednjih godina dokazalo se da biološki procesi poseduju osobine kreativnosti, kauzalnosti i bipolarnosti, što ih razlikuje od haotičnih procesa i šuma. Proces koji poseduju navedene karakteristike nazivaju se bios procesima. Primeri biotičnih procesa mogu se naći u raznim sferama, od bioloških procesa do ekonomije, a glavni primer biosa je varijabilnost srčanog ritma. Razdvajanje biotičnih procesa od haotičnih i stohastičkih se vrši upoređivanjem parametara diverzifikacije, originalnosti, kompleksnosti i neslučajne kompleksnosti [9].

Obzirom na relativno skoro klasifikovanje EEG signala kao biotičnih signala, njihove bios karakteristike nisu upotrebljavane za formiranje ulaznih signala za obučavanje neuralne mreže. Glavni motiv za pisanje ovog rada jeste utvrđivanje performansi neuralne mreže za klasifikaciju iktalne aktivnosti od ostatka EEG signala ukoliko su za ulazne parametre korišćene biotične karakteristike signala. Brža i efikasnija detekcija iktalne aktivnosti unutar EEG signala umnogome bi olakšala dijagnostiku i sačuvala dragoceno vreme neurologa, što je još jedan od motiva za pisanje ovog rada.

Cilj ovog rada je da se na osnovu izdvojenih bios obeležja elektroencefalografskih (EEG) signala kod pacova kojima je lindanom izazvan epileptični napad, obučeni neuralna mreža koja će automatski detektovati epileptične napade.

U nastavku uvoda je definisana elektroencefalografija kao neurofiziološka metoda registracije moždane električne aktivnosti. Potom je uveden pojam i matematički model Bios signala, kao i kriterijumi za klasifikovanje signala kao biotičnih signala. Na kraju uvodnog poglavlja je prikazan i osnovni model veštačkih neuralnih mreža.

U drugom poglavlju je opisana preklinička studija izvedena nad pacovima: od postavke eksperimenta do način akvizicije EEG signala pomoću implantiranog interfejsa i EEG akvizicionog sistema.

Detalji vezani za predobradu snimljenih EEG signala i izdvajanje obeležja za obučavanje neuralne mreže na obrađenim EEG signalima dati su u trećem poglavlju. Detaljnije objašnjenje karakteristika bios signala i način izbora obeležja na osnovu bios analize su takođe dati u ovom poglavlju.

U četvrtom poglavlju je opisana struktura primenjene neuralne mreže, način njenog treniranja, testiranja i validacije na obučavajućem skupu, kao i na test skupu.

Rezultati treniranja neuralne mreže na obučavajućem i na test skupu u vidu konfuzionih matrica su navedeni u petom poglavlju. U ovom poglavlju su i diskutovani dobijeni rezultati.


Poslednje, šesto poglavlje daje osvrt na celokupan rad, sadrži zaključke i rezime doprinosa rada, kao i smernice za dalje istraživanje.

1.1. Elektroencefalografija (EEG)

Prostiranje električnog signala kroz neurone mozga rezultira stvaranjem električnog polja kao sumu svih signala na površini glave. Elektroencefalografija (EEG) je metoda snimanja i prikazivanja merenog polja. Za detekciju polja koriste se elektrode postavljene na površini glave i to predstavlja neinvazivnu metodu merenja EEG-a. Invazivna metoda podrazumeva merenje električnog polja na samom mozgu, i signali dobijeni na ovaj način su većih amplituda, sa manjim smetnjama i daju preciznije informacije o promenama električnog polja u lokalizovanoj regiji.

Ljudski EEG se meri postavljanjem 10 do 20 elektroda na glavu sa precizno određenim pozicijama za svaku od elektroda. Zarad bolje provodnosti elektrode su pričvršćene adhezivnim gelom za kožu glave. Koliko ima elektroda, toliko ima i izlaznih kanala EEG signala, i svaki izlaz daje informaciju o moždanoj aktivnosti regije iznad koje se nalazi elektroda. Signali prikupljeni elektroencefalografijom su promenljivi i neregularni i svrstavaju se u kontinualne stohastičke signale [10]. Određene karakteristične ritmove unutar signala moguće je izdvojiti jer su uslovljeni stanjem kortikalne aktivnosti (jedna od takvih aktivnosti je i iktalna aktivnost).

U upotrebi su tri vrste elektroda za snimanje EEG signala: površinske, epiduralne i intrakortikane. Površinske elektrode korišćene za neinvazivno snimanje EEG signala su najčešće od srebra, sa presvučenim slojem srebrohlorida na njihovoj površini zbog bolje provodnosti i za kožu glave su pričvršćene adhezivnim gelom. Za tačno pozicioniranje stavljaju se na kapu koja se stavlja na glavu pacijenta kako bi pozicije elektroda tokom snimanja ostale fiksirane. Elektrode za invazivno snimanje su oblika matrice i postavljaju se direktno na korteks. Ne mogu biti pričvršćene, ali snimaju aktivnost korteksa direktno postavljene na njega. Intrakortikalne elektrode su oblika male igle i direktno se zabadaju u korteks i snimaju aktivnost neurona. Prikaz elektroda nalazi se na slici 1.1.1.



Slika 1.1.1 Prizkaz tri tipa elektroda za snimanje EEG signala: a) intrakortikalne, b) površinske, c) matrične[11][12].

1.2. Bios signali

Bios, kao pojam, uvodi se za opisivanje procesa koji se karakterišu kao kontinuirano ponavljanje originalnih obrazaca tokom vremena. Procesi okarakterisani kao biotični su kreativni što podrazumeva da sadrže sledeće karakteristike: diverzifikaciju, originalnost, kompleksnost i neslučajnu kompleksnost. Osim kreativnosti, osobina biotičnih procesa je i kauzalnost i primeri procesa koji pokazuju karakteristike biosa mogu se naći u biološkim, ekonomskim, fiziološkim, metrološkim procesima i u sekvencama unutar DNK strukture. Srčani ritam je primer biosa kao što su turbulence primer haosa.

Mnogi procesi koji ispoljavaju biotične karakteristike svrstavaju se u haotične procese ili u šum. Ono što razlikuje bios od haosa jeste kreativnost, a kreativni procesi su aperiodični i nestacionarni. Osim kreativnosti, *embedding plots* (eng. *embedding* – ugradnja, eng. *plot* – iscrtavanje; u kontekstu se odnosi na grafičke prikaze upoređivanja uzastopnih vektora vremenske serije) kauzalnih i kreativnih procesa uključuju i jednostavnu i kompleksnu komponentu varijabilnosti što ih razlikuje od stohastičkih procesa (kod njih je uključena samo kompleksna komponenta u *embedding plot*), kao i od haotičnih procesa (sa povećanjem broja vektora *embedding plot* od uređenog teži slučajnom rasporedu) [13].

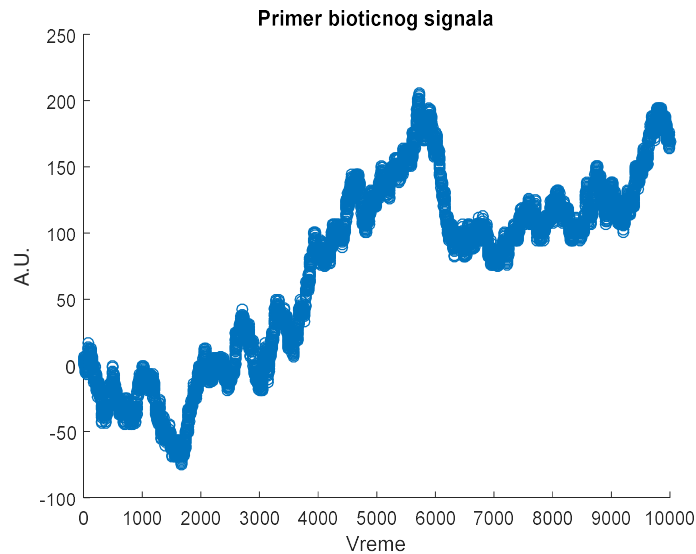
Matematički model bios procesa se može opisati rekurzivnim jednačinama (1.2.1) i (1.2.2.) koja sadrži bipolarni *feedback*. Kako je bipolarni *feedback* jedna od osnova regulacija u živom organizmu, matematičkim modelom biotičnih procesa dodatno su podržane prethodno navedene tvrdnje.

$$A_{t+1} = A_t + k * t * \sin(A_t) \quad (1.2.1.)$$

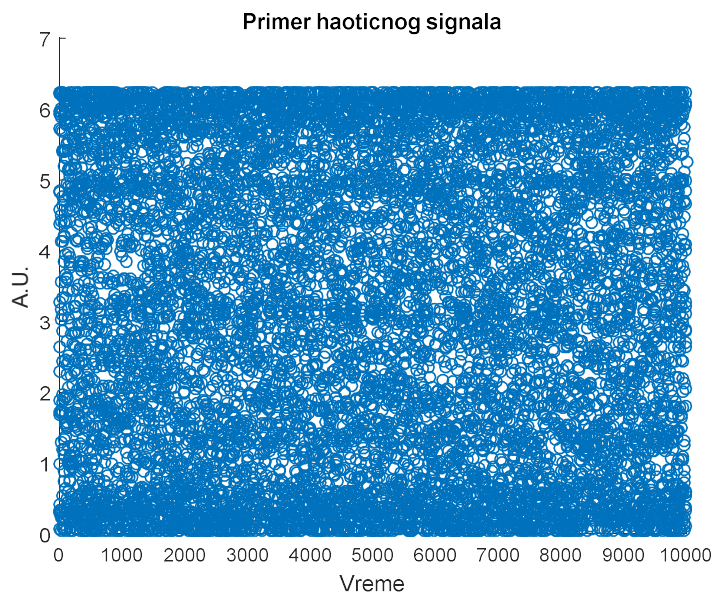
$$A_{t+1} = A_t + k * t * \sin(A_t * k * t) \quad (1.2.2)$$

Ove jednačine generišu red koji sa porastom vremena t nakon konvergiranja ka π prelazi u kaskadu bifurkacija generišući periode 2, 4, 8, ... $2n$, zatim prelazi u haos, pa u bios. Momenat prelaska sa haosa na bios se događa ukoliko je činilac g jednak ili veći od vrednosti 4,6035... [14]

Korišćenjem jednačine 1.2.1. na slici 1.2.1. dat je prikaz biotičnih procesa gde je faktor $g=4.65$, a na slici 1.2.2. dat je prikaz haotičnih procesa gde je faktor $g=4.56$.



Slika 1.2.1. Prikaz biotičnog signala dobijenog jednačinom 1.2.2. gde je faktor $g=4.65$.



Slika 1.2.2. Prikaz haotičnog signala dobijenog jednačinom 1.2.2. gde je faktor $g=4.56$.

Analiza bios procesa fokusira se na tri glavne karakteristike koje ih definišu:

1. kauzalnost
2. bipolarnost
3. kreativnost – kao najbitnija za dalje analize.

Softver korišćen za detekciju biotičnih procesa i razlike između normalnog i patološkog EEG-a jeste *Bios Data Analyser* (Chicago Center for Creative Development, Chicago). Više o

samom softveru i njegovom korišćenju za izdvajanje ulaznih parametara upotrebljenih za treniranje neuralne mreže biće u poglavlju 3.

1.3. Veštačka neuralna mreža

Veštačke neuralne mreže predstavljaju matematički model procesa koji se odvijaju u ljudskom mozgu pri obavljanju zadatka ili neke funkcije. Neuralne mreže imaju sposobnost da na osnovu ulaznih podataka kroz proces obučavanja formiraju koncepte, pojmove, kategorije itd. Sastavljene su od međusobno povezanih slojeva neurona po uzoru na biološki model, gde svaka veza između neurona ima određenu težinu (po uzoru na jačine sinaptičkih veza). Kroz proces obučavanja neuralne mreže menjaju se težine veza između neurona kako bi se dostigao željeni performans na izlazu mreže. Glavne karakteristike veštačke neuralne mreže su: masovni paralelizam – mogućnost višestrukog obavljanja različitih procesa istovremeno, sposobnost obučavanja i generalizacija – proizvodnja zadovoljavajućeg izlaza neuralne mreže i za signale koji nisu bili prisutni u toku obučavanja [15].

Svaki neuron koji čini veštačku neuralnu mrežu sastoji se od tri bazična elementa:

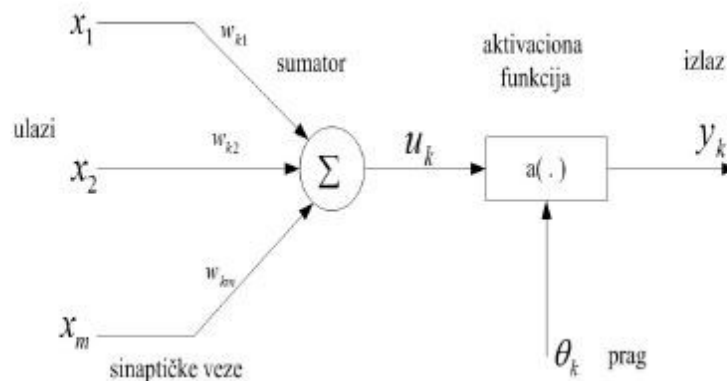
1. aktivacione funkcije
2. sumatora
3. skupa sinaptičkih težina

Nelinearni model neurona opisan je jednačinom:

$$u_k = \sum_{j=1}^m w_{jk} x_j \quad (1.3.1.)$$

gde je w_{jk} težinski faktor neurona k od neurona j , x_j izlaz neuron j , a u_k izlaz posmatranog neurona k .

Odgovarajući grafički prikaz nelinearnog modela neurona opisanog prethodnom jednačinom dat je na slici 1.3.1.



Slika 1.3.1. Prikaz nelinearnog modela neurona opisanog jednačinom 1.3.1.[15]


Aktivaciona funkcija može imati različite oblike i među njima je načešći sigmoidalan. Jednačina koja odgovara sigmoidalnom obliku funkcije je sledeća:

$$a(v) = \frac{1}{1+e^{-bv}} \quad (1.3.2.)$$

gde je parametar b parametar nagiba.

Unutar mreže neuroni su međusobno povezani tako što su organizovani u slojeve, i svaki neuron iz jednog sloja je povezan sa neuronima iz sledećeg sloja. Način organizacije slojeva neurona, organizacije sinaptičkih težina i način prostiranja signala od ulaza ka izlazu određuje kakvu će arhitekturu i primenu imati neuralna mreža. Razlikujemo jednoslojne i višeslojne neuronske mreže, kao i mreže sa prostiranjem signala unapred i rekurentne neuronske mreže.

Neuralna mreža korišćena za klasifikaciju iktalne aktivnosti unutar EEG-a jeste višeslojna neuronska mreža sa prostiranjem signala unapred za prepoznavanje oblika. Prikaz takve neuralne mreže dat je na slici 1.3.2.



Slika 1.3.2. Prikaz neuralne mreže sa ulaznim, izlaznim i sakrivenim slojem.

Višeslojna neuronska mreža sadrži ulazni, izlazni i sloj skrivenih neurona. Izlaz i -tog neurona u sloju $l+1$ neuralne mreže, dat je jednačinom:

$$o_i^{l+1} = \sum_{j=1}^{S_i} w_{ij}^{l+1} o_j^l + b_i^{l+1} \quad (1.3.3.)$$

gde je S_i broj neurona u sloju l , w_{ij}^{l+1} težinski faktor na neuronu j u sloju l , b_i^{l+1} je bias neurona, a o_j^l izlaz neurona j u sloju l .

Koristeći prethodnu jednačinu može se izračunati greška u sloju L ukoliko je poznat izlaz neuronske mreže:

$$E = \sum_{p=1}^P \sum_{m=1}^M (d_{pm} - o_{pm}^L)^2 \quad (1.3.4.)$$

gde je d_{pm} poznati izlaz neurona m u sloju L , a o_{pm}^L izlaz koji je generisala neuralna mreža za neuron m u sloju L , za jedna uzorak treniranja p (tokom jedne iteracije ili epohe).


2. PREKLINIČKA STUDIJA

Opis prekliničke studije i akvizicija EEG signala čija obrada je osnova ovog rada data je ovom poglavlju.

Studija je rađena na 6 jedinki odraslih *Wister albino* pacova u saradnji sa lekarima iz Laboratorije za neurofiziologiju, Institut za medicinsku fiziologiju Medicinskog fakulteta u Beogradu. Za studiju postoji odgovarajuća dozvola Etičkog komiteta.

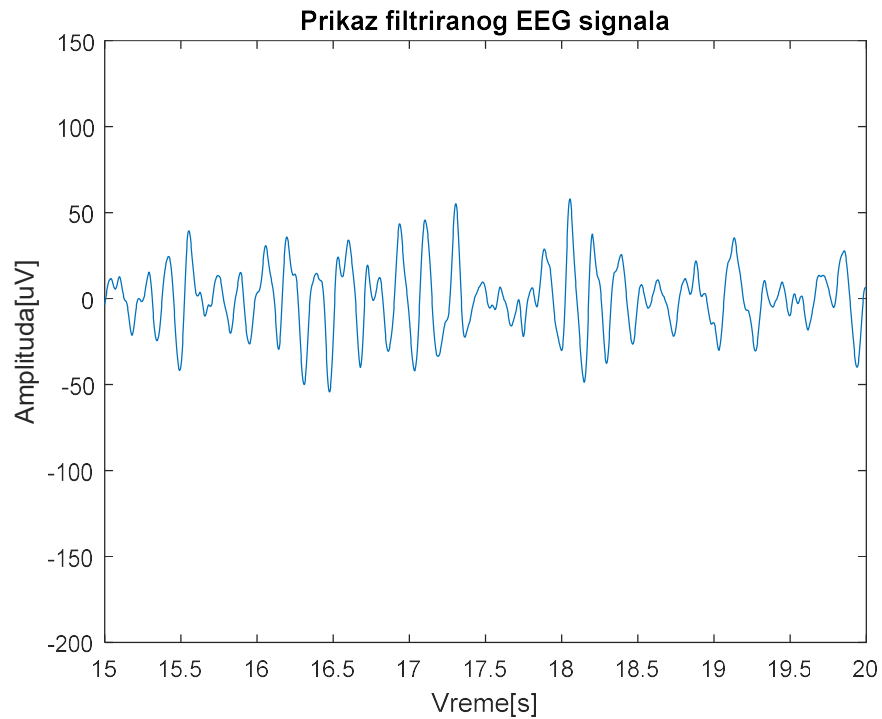
Na pacovima je izvršena ugradnja elektroda koje su u direktnom kontaktu sa mozgom zarad akvizicije EEG signala. Elektrode su postavljene u stereostatičkom ramu kako bi bile fiksirane tokom cele sudije. Tokom ugradnje pacovi su bili anestetizirani i imali su oporavak od 7 dana pre prvih veštačkih izazivanja epileptičnih napada.

Epileptični napadi su izazivani dozom lindana (8 mg/kg). Nakon primljene doze, moždana aktivnost pacova snimana je pomoću *NeuroSciLaBG* ((UNO-LUX NS, Beograd) akvizicionog sistema. Na slici 2.1.1. je šematski dat prikaz sistema korišćenog za snimanje i čuvanje signala.




Slika 2.1.1. Prikaz sistema za snimanje i čuvanje EEG signala.

U eksperimentu je korišćena invazivna metoda merenja EEG-a. Tri elektrode postavljene su na parijetalni, oksipitalni i frontalni režanj mozga pacova. Signali su snimani u trajanjima od pola sata do nekoliko sati. Kako su pre snimanja veštački izazivani epileptični napadi kod pacova, oni se tokom snimanja pojavljuju sa različitom učestanošću i različitog trajanja. Osim šiljaka koji su prouzrokovani pražnjenjem neurona u snimljenom EEG signalu pacova pojavljuju se i šiljci velike amplitude koji jesu uzrokovani epilepsijom, ali ne predstavljaju napad. Na slici 2.1.1. prikazan je izgled filtriranog EEG signala bez epileptičnih napada snimljenog na pacovu, dok je na slici 2.1.2 prikazan filtriran EEG signal na kojem je prisutna iktalna aktivnost.



Slika 2.1.2. Prikaz 5 sekundi filtriranog EEG signala snimljenog na pacovu bez prisustva iktalne aktivnosti.



Slika 2.1.3. Prikaz 5 sekundi filtriranog EEG signala snimljenom na pacovu na kom se nalazi iktalna aktivnost.

2.1.1. Akvizicija EEG signala

Akvizicija EEG signala sa pacova vršena je pomoću *NeuroSciLaBG* (UNO-LUX NS, Beograd) akvizicionog sistema. Sistem ima mogućnost snimanja više kanala, tako da za neke pacove postoje snimci EEG signala sa dva kanala. Snimanje signala je vršeno 60 minuta pre i posle tretiranja pacova dozom lindana.



Slika 2.1.1.1. NeuroSciLaBG sistem

Snimljeno je sedam signala različitih trajanja. Signali su potom obrađeni u softveru *Matlab 2016b* (*Mathworks, USA*) i na njih su primenjeni sledeći filtri: *notch* filter, filter za uklanjanje bazne linije, filter propusnik opsega od 0 do 80 Hz i *Moving average* filter, o čemu će više biti reči u poglavlju 3.

3. IZDVAJANJE OBELEŽJA

Da bi obučavanje neuralne mreže bilo uspešno potrebno je odrediti ulazne podatke sa posebnom pažnjom kako bi neuralna mreža imala što bolji performans. U ovom poglavlju biće opisan način obrade korišćenih EEG signala kao i odabir karakteristika bios signala korišćenih za kreiranje neuralne mreže.

Karakteristike za ulazne podatke neuralne mreže izdvajane su na delovima signala sa vremenskim prozorom od 15 sekundi, koji je duž obrađivanog signala pomezan za 5 sekundi. Na svaki takav segment primenjene su sve tehnike filtriranja EEG signala navedenim u nastavku i za svaki od njih je izdvojeno 6 karakteristika koje definišu bios signale.


3.1. Filtriranje EEG signala

U prethodnom poglavlju opisan je način snimanja EEG signala na pacovima. Signale je potrebno obraditi kako bi se otklonili nepotrebni šumovi i artefakti do kojih je moglo doći usled snimanja. Za obradu signala upotrebljene su sledeće metode filtriranja: *notch* filtar na frekvenciji od 50 Hz, *bandpass* filtar u opsegu od 0 Hz do 80 Hz, filtar za skidanje bazne linije i *moving average* filtar petnaestog reda. Signali su obrađeni pomoću *Matlab 2016b* (*Mathworks, USA*) softvera.

3.1.1. Notch filtar


Usled mrežnog uticaja koji postoji kao posledica neispravnog uzemljenja ili okolnih aparata, u signalu se javlja šum na 50 Hz. Filtar koji se koristi pri uklanjanju mrežnog uticaja je *notch* filtar.

Notch filtar je filtar nepropusnik opsega učestanosti, koji iz signala uklanja samo onaj deo koji se nalazi na jednoj, unapred zadatoj frekvenciji (u ovom slučaju je frekvencija od 50 Hz). U softveru *Matlab 2016* postoji ugrađena funkcija *iirnotch* za koju se definiše frekvencija na koju će biti postavljen filtar. Na slici ispod dat je prikaz odziva *notch* filtra dobijenog funkcijom *iirnotch* na frekvenciji od 60 Hz.



Slika 3.1.1. Prikaz odziva notch filtra dobijenog funkcijom *iirnotch* na frekvenciji od 60 Hz.[16]

Na sledećoj slici dat je prikaz od 15. do 20. sekunde signala RAT2, gde je crvenom bojom i zvezdicama prikazan nefiltrirani signal, a plavom bojom i kružićima signal na koji je već primenjen *notch* filtar.




Slika 3.1.2 Prikaz signala sa primenjenim *notch* filtrom i sirovog signala od 15. do 20. sekunde.

3.1.2. *Bandpass* filtar

Filtri obično imaju naziv u skladu sa tim koji opseg frekvencija propuštaju. Stoga se iz samog naziva zaključuje da *bandpass* filtar odstranjuje sve frekvencije ispod i iznad zadanog opsega. Koristi se za odstranjivanje nepotrebnih niskih ili visokih frekvencija, ili za uklanjanje i niskih i visokih frekvencija koje u samom signalu predstavljaju smetnju.

Za filtriranje signala RAT2 iskorišćena je posebno napisana funkcije *bpf.m* za koju je potrebno definisati donju i gornju frekvenciju propusnog opsega, i signal u vremenskom domenu na kom je potrebno izvršiti filtriranje. Na slici 3.1.3 prikazani su uporedo delovi signala filtriranog *notch* i *bandpass* filtrom i sirovog signala od 15. do 20. sekunde.



Slika 3.1.3. Uporedni prikaz delova signala filtriranog *notch* i *bandpass* filtrom i sirovog signala od 15. do 20. sekunde.

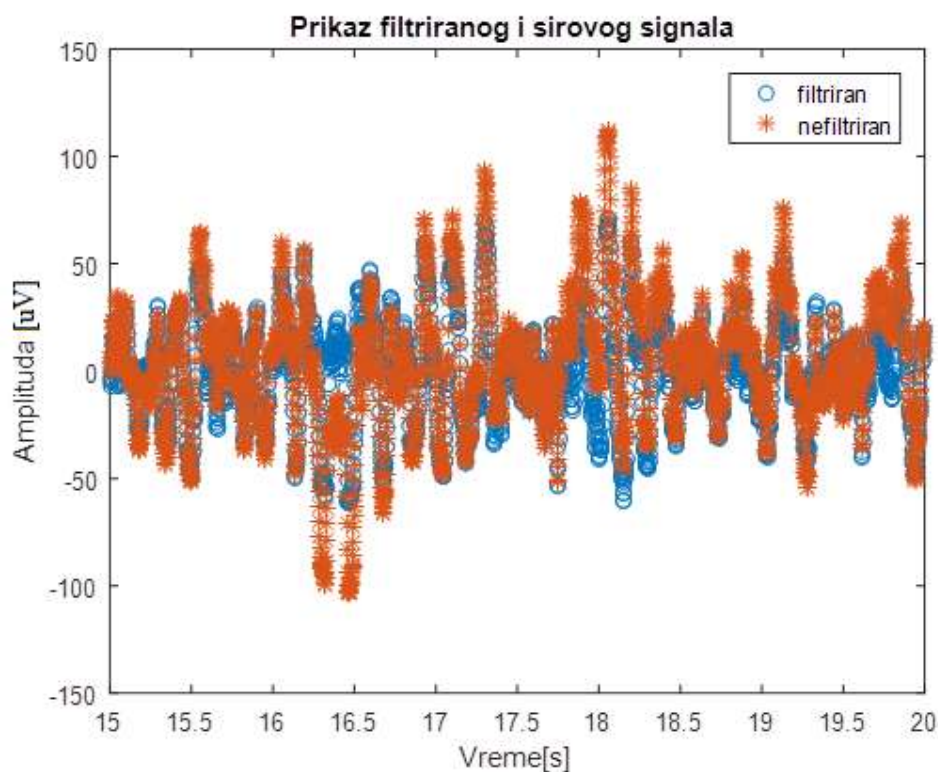
3.1.3. Filtar za uklanjanje bazne linije

Signali snimljeni na živim bićima uvek u sebi sadrže informacije ne samo o aktivnosti vezanim za merenu funkciju, već sadrže informaciju o aktivnosti celog organizma. Zato se u snimljenom signalu može primetiti varijabilnosti bazne linije, i uglavnom su frekvencije manje od 0.5 Hz. Primenjeni filter za uklanjanje bazne linije ima sledeću funkciju prenosa:

$$H(z) = \frac{1-z^{-1}}{1-\alpha z^{-1}} \frac{1+\alpha}{2}, \quad (3.1.1)$$

gde α predstavlja pol filtra za odstranjivanje niskofrekventne komponente signala.

Za filtriranje bazne linije signala RAT2 korišćena je gore pomenuta funkcija prenosa sa polom na vrednosti 0.97, uz pomoć *Matlab*-ove ugrađene funkcije *filtfilt*. Prikaz delova signala na koji su primenjeni *notch*, *bandpass* i filter za uklanjanje bazne linije uporedo sa sirovim signalom, dat je na slici ispod.

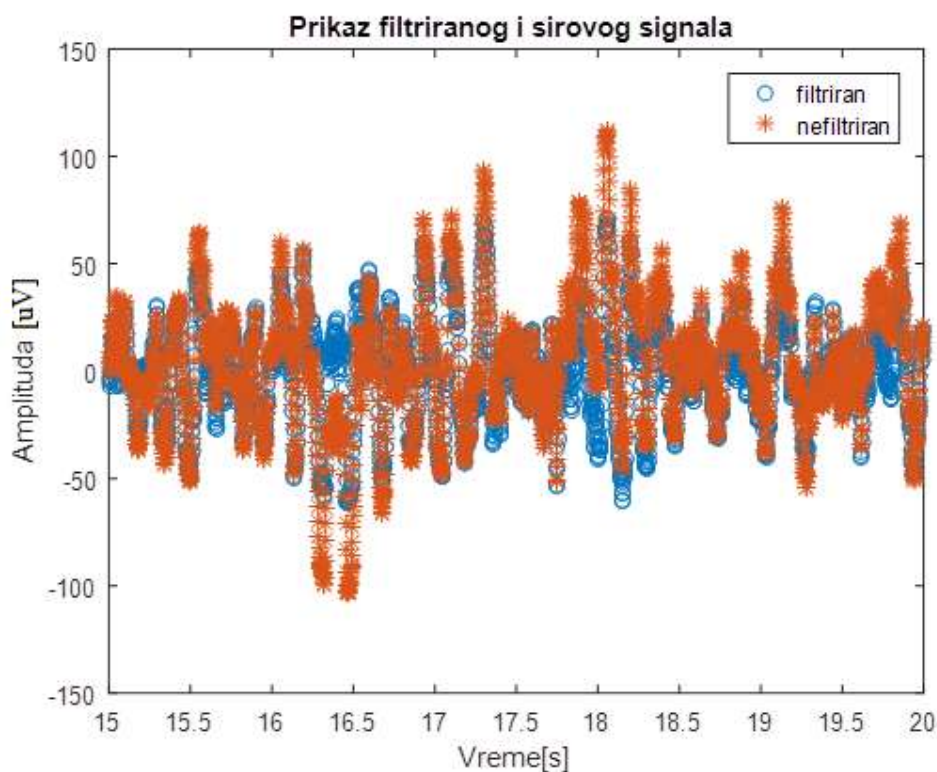


Slika 3.1.4. Uporedni prikaz signala filtriranog *notch*, *bandpass* i filtrom za uklanjanje bazne linije sa sirovim signalom.

3.1.4. *Moving average filter*

Poslednji korak u filtriranju EEG signala je njegovo 'uglađivanje' pomoću *Moving average* (MA) filtra. Ukoliko postoji samo jedno snimanje signala od interesa potrebno je potisnuti *random* šum, i to se potiče upravo MA filtrom. Filter se tako naziva jer se vremenska statistika računa korišćenjem nekoliko semplova signala duž vremenske ose i vremenski prozor semplova se pomera (*moving-window averaging*) da bi se dobio izlaz u različitim trenucima [15].

Za filtriranje signala RAT2 MA filtrom korišćen je MA filter 15. reda, jer pokazuje najbolje rezultate (u odnosu na ostale ostale isprobane redove od 13 do 19). Na sledećoj slici dat je prikaz od 15. do 20. sekunde potpuno filtriranog signala navedenim filtrima u poglavljima od 3.1.1 do 3.1.4 uporedo sa sirovim signalom.



Slika 3.1.5. Uporedni prikaz signala filtriranog *notch*, *bandpass*, MA filtrom i filtrom za otklanjanje bazne linije sa sirovim signalom.

3.2. Bios Data Analyser

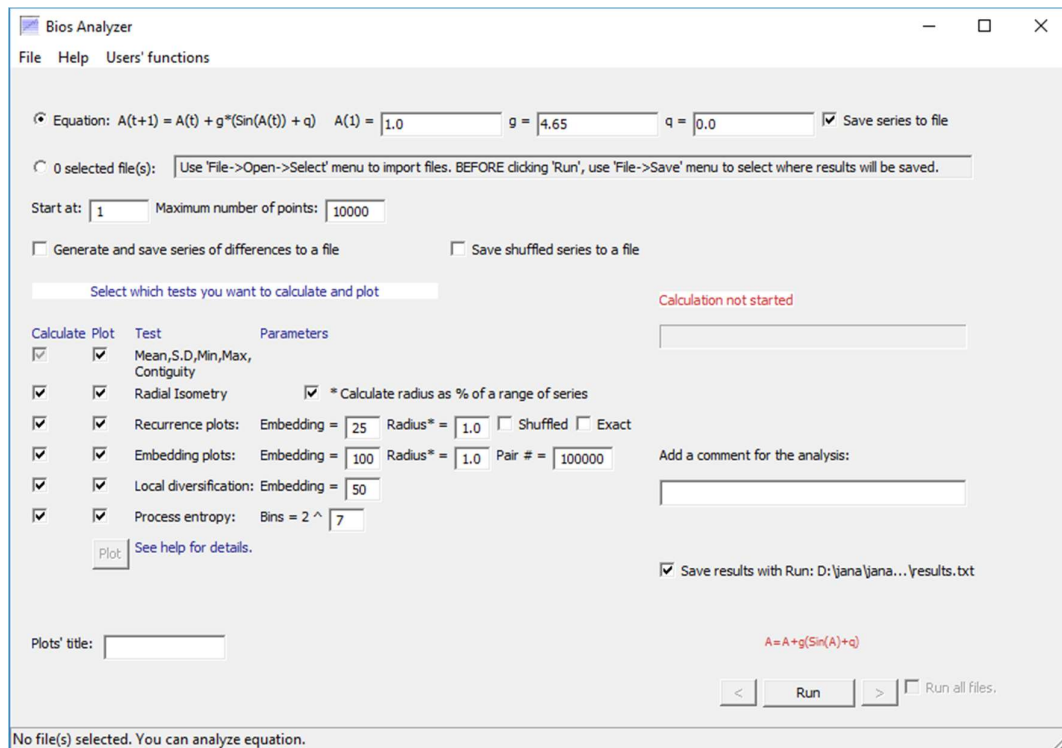
Bios signali predstavljaju kauzalne i kreativne procese. Proces se smatra kreativnim ukoliko u svom vremenskom domenu poseduje sledeće karakteristike: postojanje jednostavne i kompleksne komponente varijabilnosti, ispoljavanje naizmeničnog obrasca, diverzifikaciju, originalnost, neslučajnu kompleksnost i nereverzibilnost.

Program koji omogućava proračunavanje biotičnih osobina je *Bios Data Analyser*, besplatan softver napisan od grupe autora iz Čikaškog centra za kreativni razvoj Univerziteta Illinois. Glavne prednosti *Bios Data Analyser* softvera su: mogućnost simultane analize više fajlova (procesa), mogućnost obrade dugačkih signala sa više i od milion odbiraka, grafičko prikazivanje rezultata i njihovo čuvanje u .xls formatu, generisanje statistike prilikom obrade većeg broja fajlova i vrlo jednostavan grafički interfejs za korišćenje [18].

Osim gore navedenih prenosti *Bios Data Analyser* softvera takođe je moguće odabrati samo željene testove za koje se po slobodnom izboru mogu postaviti parametri. Ukoliko je potrebno obraditi samo jedan deo učitano signala, on se može ograničiti postavljanjem broja početnog sempla signala i definisanjem dužine signala u semplovima.

Testovi koji se izvršavaju unutar programa *Bios Data Analyser* su:

1. Izračunavanje srednje vrednosti, standardne devijacije, minimuma, maksimuma i *contiguity* (eng. *contiguity* - susednost)
2. *Radial isometry* - testovi kauzalnosti kroz izračunavanje rekurentnosti i uzastopne rekurentnosti kao funkcije radijusa
3. *Recurrence plots* - Izometrijsku rekurentnost (iscrtavanje rekurentnih grafika vremenskog niza, o čemu će biti više reči u poglavlju 3.2.1)
4. *Embedding plots* - grafički prikazi upoređivanja uzastopnih vektora vremenske serije uz mogućnost menjanja broja poređenih vektora za sledeće osobine: izometrija, uzastopna izometrija, rekurentnost/originalnost, uređenje (eng. *arrangement* - uređenje)
5. *Local diversification* – standardna devijacija; porast varijanse sa porastom dužine vektora
6. Entropija procesa – različitosti i simetrije vektora vremenskog niza.



Slika 3.2.1 Prikaz interfejsa softvera *Bios Data Analyser*

U nastavku će detaljnije biti opisane metode za razlikovanje bios i kreativnih signala od haotičnih i stohastičkih signala, na kojima se zasnivaju proračuni unutar *Bios Data Analyser* softvera.

3.2.1. Izometrija i grafičko prikazivanje rekurentnosti

Kvantifikacija izometrije je jedna od glavnih analiza kada se razmatraju kreativni procesi, jer omogućava dalja merenja ostalih karakteristika poput originalnosti, neslučajnu kompleksnost i vremenske promene, i pokazuje kauzalnost koja razdvaja bios procese od stohastičkih. Rekurentne

metode otkrivaju obrasce u vremenskom domenu upoređujući niz sukcesivnih članova vremenskog intervala tražeći, definišući i iscrtavajući rekurentne veze među vektorima. *Bios Data Analyser* softver omogućava korisniku da sam izabere koliko vektora želi da se uporedi.

Izometrija je tip kvantifikovanja rekurentnog merenja za vektore iste dužine. Dužina vektora se računa traženjem Euklidske norme (kvadratni koren sume kvadrata članova vektora za koji se računa Euklidska norma). Dva vektora se smatraju izometričnim ukoliko je apsolutna vrednost razlike njihovih Euklidskih normi manja od graničnog radijusa zadatog od strane korisnika [14].

3.2.2. Originalnost

Softver *Bios Data Analyser* vrši izračunavanje i upoređivanje rekurentnosti uzastopnih vektora vremenske serije i njihovih izmešanih kopija, sa ciljem merenja originalnosti i neslučajne kompleksnosti. Originalnost kao karakteristiku definiše činjenica da mnogi prirodni procesi, koji se definišu kao kreativni, poseduju manju izometriju u odnosu na rekurentne prikaze njihovih izmešanih kopija.

Kao što je navedeno, izometrija se predstavlja kao histogram Euklidskih normi određenih za 2, 3, 4, ..., 50 vektora. Svaka serija A_t se upoređuje sa 5 izmešanih kopija A_s . Pareto raspodela frekvencija omogućava merenje promene izometrije između originalnog signala i srednje vrednosti njegovih izmešanih kopija A_s . Upoređuju se frekvencije F serija A_t i A_s sa ciljem određivanja originalnosti, uređenosti i slučajnosti. Ukoliko je $F(A_t) > F(A_s)$ to predstavlja uređenost koja se može uočiti u periodičnim procesima. Ako je $F(A_t) = F(A_s)$ ukazuje se na slučajne procese, jer je mešanje vremenskih serija ne dovodi do promene frekvencije. Ukoliko je $F(A_t) < F(A_s)$, to ukazuje na originalnost.

3.2.3. Uzastopna rekurentnost

Uzastopna rekurentnost predstavlja broj recidiva koje prate jedan drugi, na primer, ukoliko je vektor y_t rekurentan sa vektorom y_{t+m} onda je vektor y_{t+1} rekurentan sa vektorom y_{t+m+1} . Uzastopna rekurentnost ukoliko postoji u izmešanim serijama signala ukazuje na neslučajnu uređenost, koja može biti dokaz kreativnosti ili determinizma. Matematički bios i bios bioloških procesa pokazuju uzastopnu rekurentnost i za mali i za veliki broj vektora. Uzastopna rekurentnost pokazuje uzročnost uključujući i periodičnost, kauzalnost i integraciju.

3.2.4. Uređenost

Uređenost (eng. *arrangement* - uređenost) podrazumeva nivo uzastopne izometrije preko broja svih izometrija i predstavlja jedan od mogućih načina merenja neslučajne kompleksnosti. Uređenost je veoma visoka za fiziološka snimanja (EEG, elektromiografija, respiracija), ekonomske procese, nizove DNK. Uređenost je niska za slučajne, periodične i haotične procese. Porast uređenosti sa brojem različitih perioda koji čine višepredične nizove je dovoljan dokaz da se uređenost može koristiti kao način merenja neslučajne kompleksnosti.

3.2.5. *Embedding plots*

Kod kreativnih procesa jednostavni procesi malih dimenzija stvaraju kompleksne obrasce velikih dimenzija. Zato je potpuno očekivano da biotični procesi ispoljavaju i kompleksne i jednostavne obrasce. Haotični i deterministički procesi pokazuju komponentu samo jednostavnih obrazaca, dok stohastički procesi pokazuju samo kompleksnu komponentu zbog promena koje se javljaju kao zasebni događaji.

Za izučavanje i jednostavne i kompleksne karakteristike vremenskog signala iscertava se izometrija kao funkcija trajanja vektora (*embedding plot*). *Embedding plots* razlikuju 5 tipova aperiodičnih serija: slučajnu (koja se ne može razlikovati od svojih izmešanih kopija), haotičnu (nizak nivo uzastopne rekurentnosti i visok nivo slučajnosti), stohastičku (nizak nivo slučajnosti i visok nivo originalnosti i uzastopne rekurentnosti), biotičku (visok nivo originalnosti i uzastopne rekurentnosti bez obzira na trajanje i broj vektora) i prebiotičku (originalnost bez uzastopne rekurentnosti).

3.2.6. *Diverzifikacija*

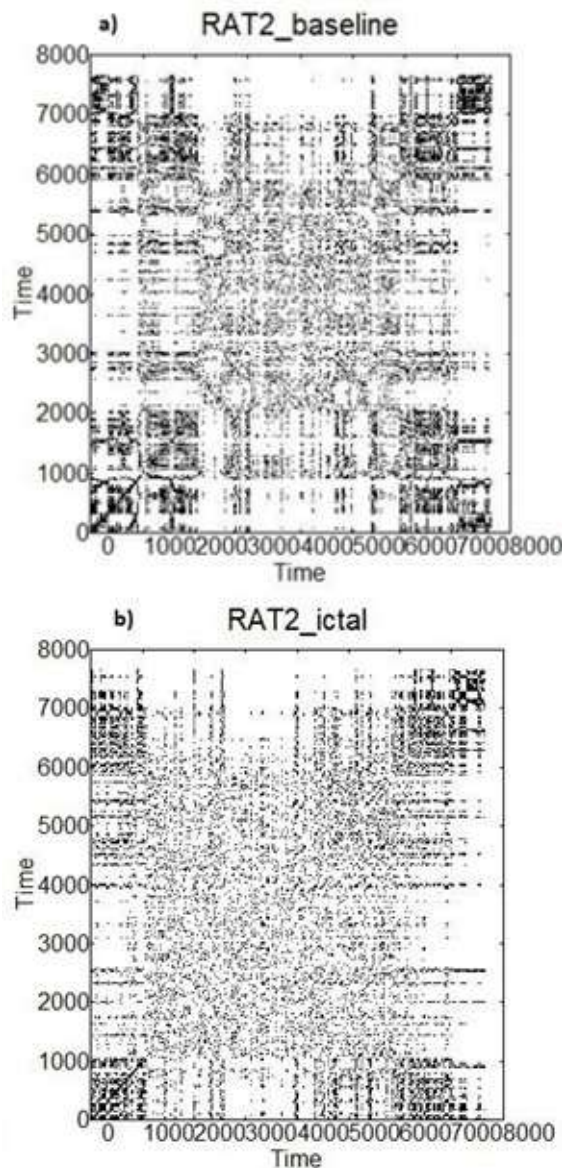
Diverzifikacija predstavlja merenje standardne devijacije i meri se na dva načina: globalno i lokalno. Globalna diverzifikacija se odnosi na merenje porasta varijabilnosti sa porastom trajanja vremenske serije. Standardna devijacija, u smislu globalne diverzifikacije, meri se za vremenski niz od 1 do 100 semplova, zatim za niz od 1 do 200, pa za niz od 1 do 300, itd., pa sve do N tačaka, gde N predstavlja poslednji sempl vremenskog niza. Za biotične procese standardna devijacija raste sa porastom vremenskog niza, dok za haotične i slučajne signale globalna diverzifikacija opada ili ne menja svoju vrednost.

Kod lokalne diverzifikacije standardna devijacija se računa za set od 2,3, ... 200 uzastopnih vektora vremenske serije, započevši uvek sa drugim vektorom. Vrednost dobijena za svaki set se usrednjava u odnosu na celu vremensku seriju i srednje vrednosti se iscertavaju u funkciji od broj vektora. Sa porastom broja vektora raste i lokalna diverzifikacija za matematički generisan bios, dok za haotične i uniforme slučajne procese biva negativna ili jednaka nuli.

3.3. **Ekstrakcija karakteristika**

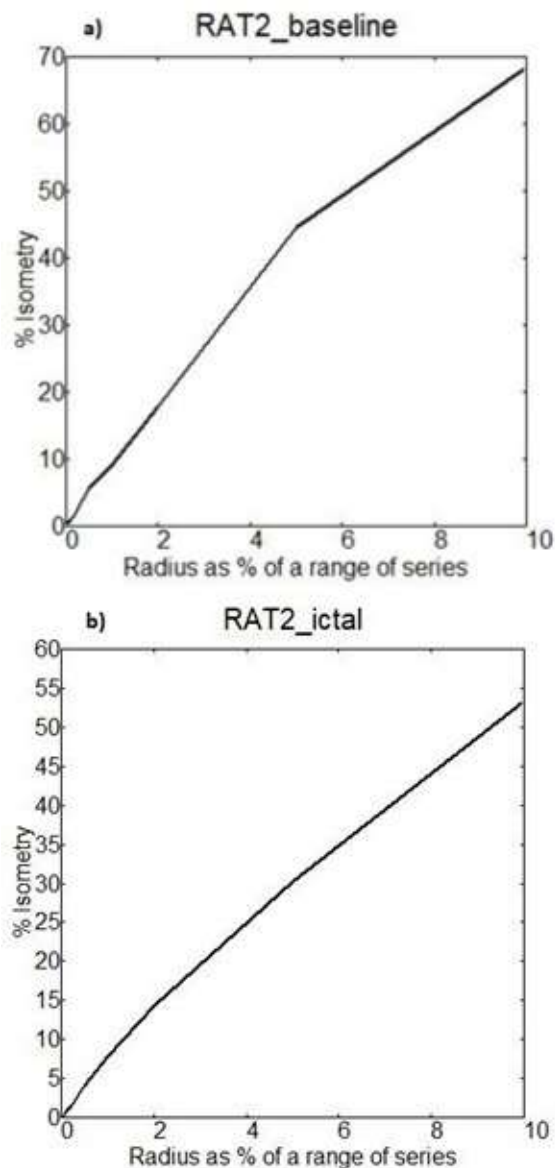
Obzirom da je cilj rada što uspešnije odvojiti delove EEG signala na kojima su prisutni epileptični napadi od ostatka EEG signala pacova, potrebno je utvrditi u kojim tačno parametrima koji karakterišu Bios postoji razlika između iktalne aktivnosti i standardnog EEG signala.

Na primeru signala RAT2 mogu se uočiti razlike u određenim grafičkim prikazima bios karakteristika za deo signala od 15 sekundi gde postoji epi napad i za deo signala takođe od 15 sekundi gde je EEG bez iktalne aktivnosti. Na sledećim slikama uporedo su prikazani grafici i objašnjene uočene razlike među njima. Svi grafici dobijeni su korišćenjem *Bios Data Analyser* softvera.



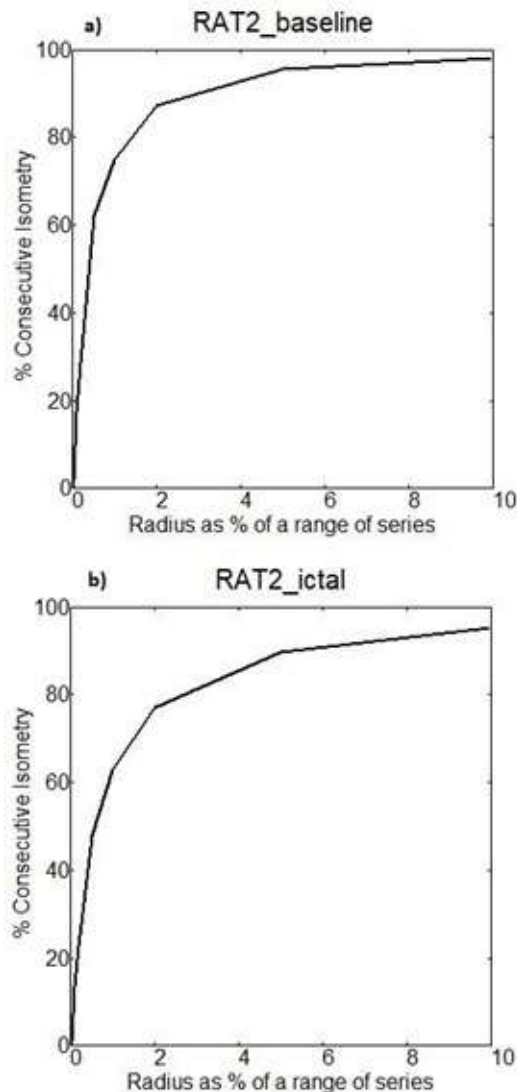
Slika 3.3.1.a) Prikaz rekurentnog grafika izometrije za 15 sekundi EEG signala bez iktalne aktivnosti. b) Prikaz rekurentnog grafika izometrije za 15 sekundi EEG signala sa iktalnom aktivnošću.

Na slikama 3.3.1.a) i 3.3.1.b) dat je uporedni prikaz rekurentnih grafika izometrije signala bez iktalne aktivnosti i sa iktalnom aktivnošću. Sa njih se jasno može zaključiti da oba ispoljavaju kreativnost kao osobinu, što ih svakako svrstava u bios signale i time opravdava korišćenje ostalih karakteristika bios signala za treniranje neuralne mreže.




Slika 3.3.2.a) Kriva izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala za EEG signal bez iktalne aktivnosti. b) Kriva izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala za EEG signal sa iktalnom aktivnošću.

Krive na slikama 3.3.2.a) i 3.3.2.b) pokazujuju da ukoliko postoji iktalna aktivnost procenat izometrije sa porastom opsega vremenskog intervala imaće znatno manji porast.



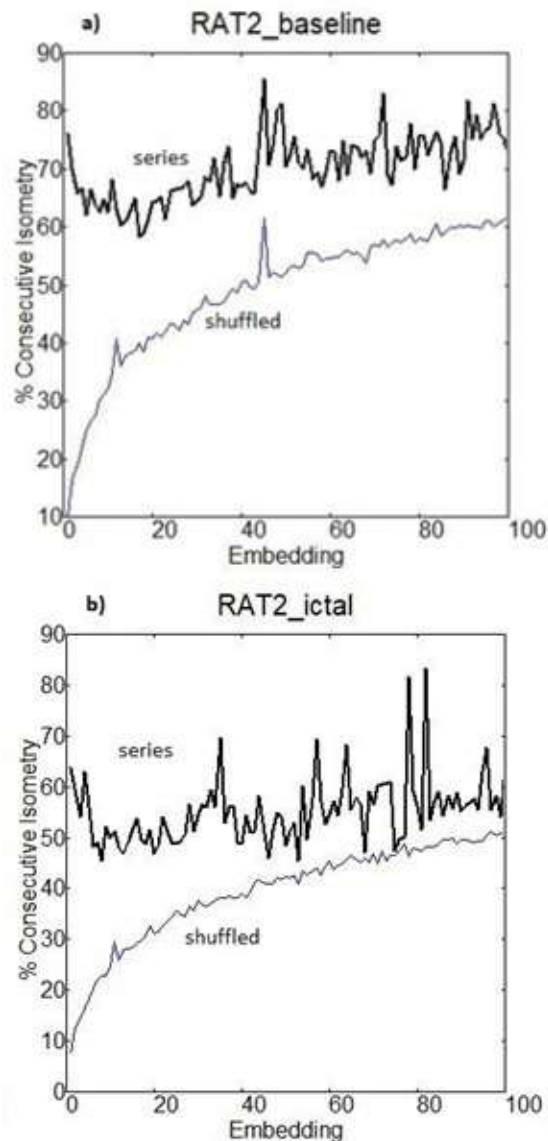
Slika 3.3.3.a) Kriva konsektivne izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala na EEG signalu bez iktalne aktivnosti. b) Kriva konsektivne izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala na EEG signalu sa iktalnom aktivnošću.

Obzirom da se biotični procesi i njihova kauzalnost karakterišu krivom uzastopne izometrije koja ima nagli porast sa početkom povećanja opsega vremenske serije i blagim porastom nakon takvog inicijalnog skoka, grafici na slikama pokazuju da kad je u pitanju EEG signal i normalan i patološki on poseduje osobine kauzalnosti. Kriva je neznatno slabijeg skoka kod signala sa iktalnom aktivnošću.




Slika 3.3.4.a) Prikaz *Embedded plot*-a izometrije za 100 vektora na EEG signalu bez iktalne aktivnosti. b) Prikaz *Embedded plot*-a izometrije za 100 vektora na EEG signalu sa iktalnom aktivnošću.

Na datim graficima se vidi da postoji razlika u vrednostima za krive regularnog i izmešanog vremenskog niza signala. Ukoliko se posmatraju izmešane vremenske serije (*shuffled*) primećuje se da sa porastom *embedding*-a kod normalnog EEG signala linija grafika lagano opada, dok kod iktalnog signala ona ne opada. Vremenske serije kod oba signala pokazuju slično ponašanja, gde sa porastom *embedding*-a opadaju do približno jednakih vrednosti.



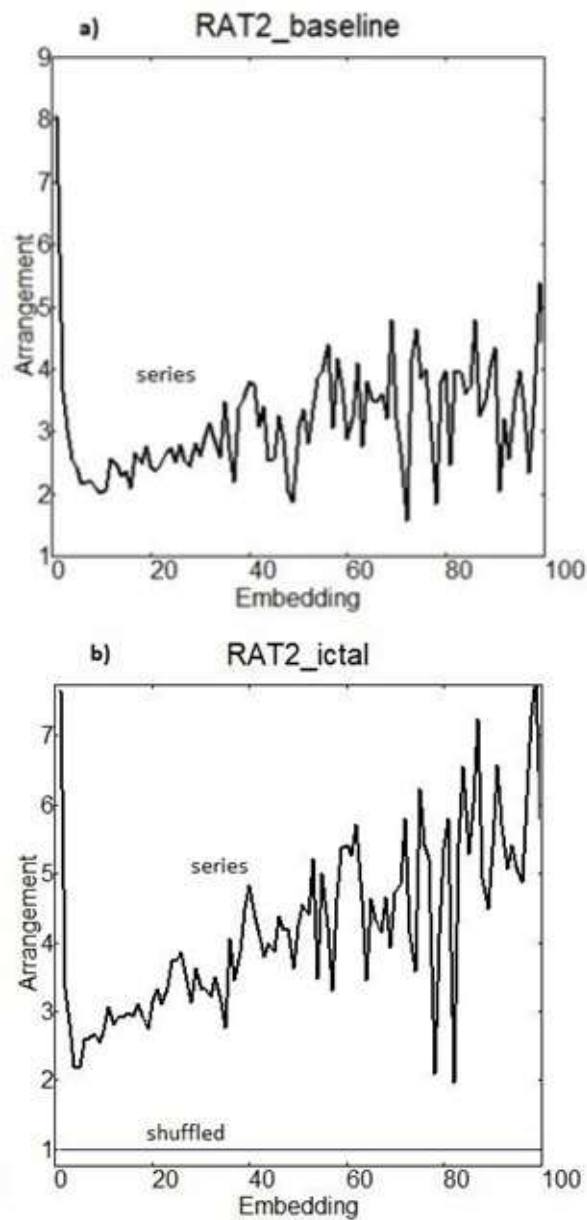
Slika 3.3.5.a) Prikaz uporednih krivih uzastopne izometrije na *embedded plot*-u za 100 upoređenih uzastopnih i izmešanih vektora na EEG signalu bez iktalne aktivnosti. b) Prikaz uporednih krivih uzastopne izometrije *embedded plot*-u za 100 upoređenih uzastopnih i izmešanih vektora na EEG signalu sa iktalnom aktivnošću.

Na graficima se uočava da je glavna razlika u procentima uzastopne izometrije vremenske serije koja je za EEG sa iktalnom aktivnošću niža u odnosu na normalan EEG signal. Ista stvar se uočava i za izmešanu vremensku seriju. Sa prisustvom iktalne aktivnosti i porastom *embeddinga*-a izmešana i obična vremenska serija se približavaju istoj vrednosti.



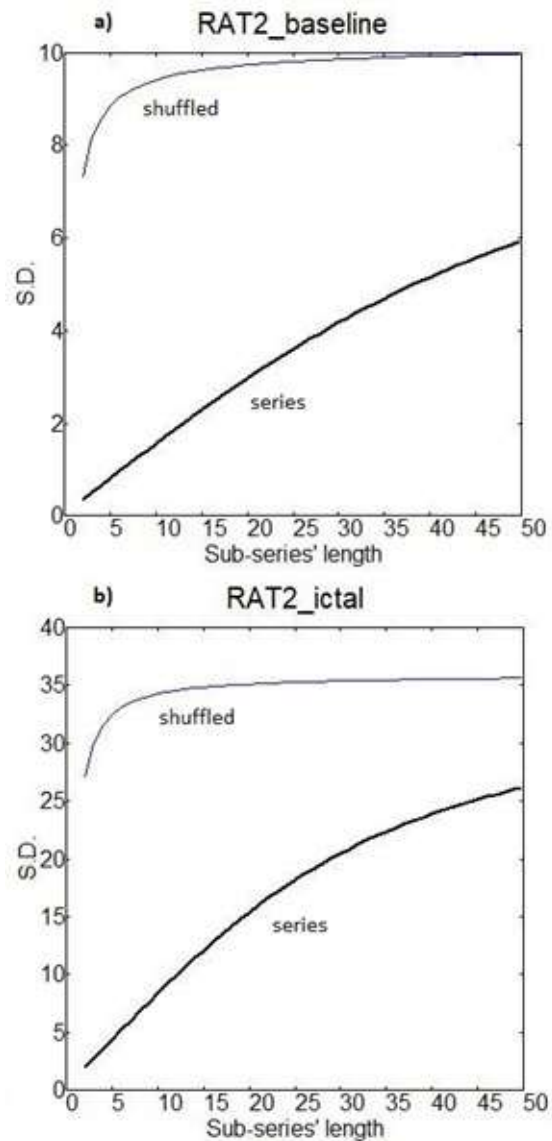
Slika 3.3.6.a) Prikaz odnosa izometrije dela signala sa njegovim izmešanim kopijama kao mera originalnosti na delu EEG signala bez iktalne aktivnosti b) Prikaz odnosa izometrije dela signala sa njegovim izmešanim kopijama kao mera originalnosti na delu EEG signala sa iktalnom aktivnošću.

Odnos izometrije za izmešane signale u svakom trenutku će biti jednak jedinici. Zato se vidi razlika za vremenske serije koje, uz prisustvo dosta šiljaka na oba grafika, pokazuje veći porast kada je u pitanju signal sa iktalnom aktivnošću u odnosu na normalan EEG signal.



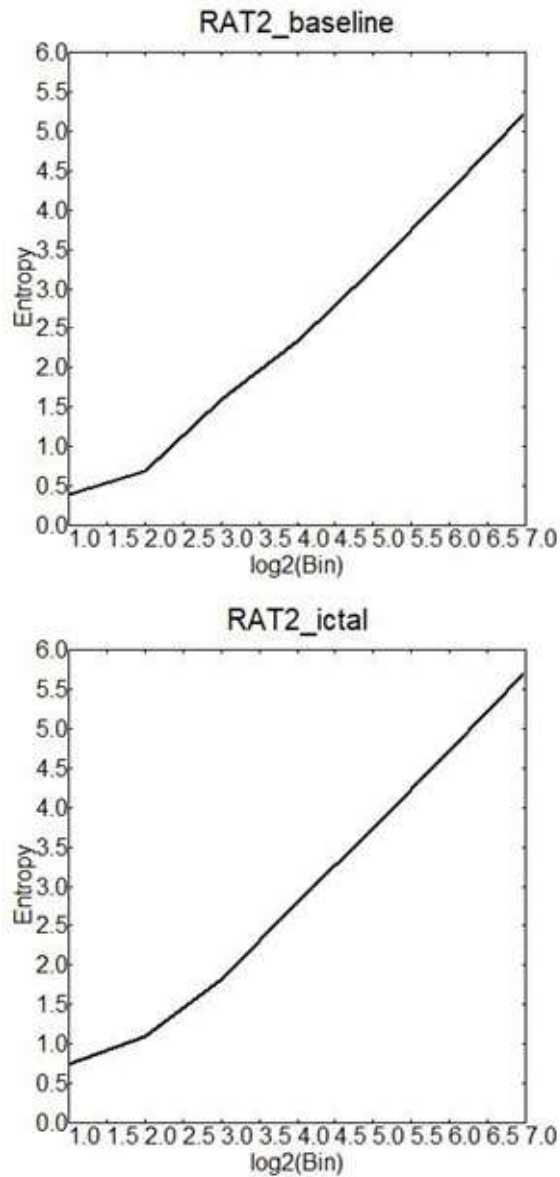
Slika 3.3.7.a) Prikaz grafika uređenosti za EEG signal bez iktalne aktivnosti. b) Prikaz grafika uređenosti za EEG signal sa iktalnom aktivnošću.

Na grafiku 3.3.7.a) takođe postoji linija na vrednosti 1 koja predstavlja uređenost za izmešane vremenske serije, kao što postoji na grafiku 3.3.7.b). Lako se primeti da uređenost za vremensku seriju za signal koji sadrži epi napad, uz šiljke prisutne na oba grafika, značajnije raste sa porastom *embedding*-a.



Slika 3.3.8.a) Prikaz lokalne diverzifikacije za EEG signal bez iktalne aktivnosti. b) Prikaz lokalne diverzifikacije za EEG signal sa iktalnom aktivnošću.

Kada se pogledaju vrednosti standardne devijacije u odnosu na dužinu vektora za koji se računa, očigledne su razlike u vrednostima i za vremensku seriju kao i za izmešanu vremensku seriju. Standardna devijacija ima mnogo veću vrednost kada je u pitanju EEG signal sa epi napadom.



Slika 3.3.9.a) Prikaz procesne entropije u logaritamskoj skali za EEG signal bez iktalne aktivnosti. b) Prikaz procesne entropije u logaritamskoj skali za EEG signal sa iktalnom aktivnošću.

Kriva na oba grafika izgleda vrlo slično, i neznatno variraju vrednosti kada se uporede entropije za normalan i patološki EEG signal.

Sumirajući navedene razlike između grafika, za obučavanje neuralne mreže koja bi prepoznavala da li u EEG signalu postoji epi napad ili ne, uzete su sledeće karakteristike:

1. razlika integrala na grafiku izometrije između uzastopnih i izmešanih delova signala,
2. razlika integrala na grafiku konsektivne izometrije između uzastopnih i izmešanih delova signala,
3. integral grafika originalnosti,

4. integral grafika uređenosti,
5. integral grafika standardne devijacije za uzastopne delove signala,
6. integral grafika standardne devijacije za izmešane delove signala.

Sve navedene karakteristike izvučene su iz podataka sačuvanih pomoću *Bios Analyser* softvera i zatim dalje obrađeni u *Matlab*-u. *Bios Analyser* čuva isključivo numeričke podatke o graficima. Za izračunavanje željenih integrala korišćena je *Matlab*-ova ugrađena funkcija *cumtrapz* koja omogućava izračunavanje integrala ukoliko postoje samo numerički podaci na grafiku bez jasno definisane funkcije.

Navedene karakteristike poslužiće kao ulazni parametri za neuralnu mrežu, dok su izlazni signali za neuralnu mrežu drugačije formatirani.

3.4. Formatiranje izlaza

Osim definisanja željenog ulaza u neuralnu mrežu potrebno je definisati i željeni izlaz za faze obučavanje i testiranja. Obzirom na to da su svi snimljeni i korišćeni signali imali već definisane segmente na kojima se nalaze epi napadi, a na kojima se nalazi neiktalan EEG signal od strane iskusnog lekara, izlazne parametre je bilo potrebno samo formatirati na odgovarajući način.

Kako je potrebno odrediti na kom segmentu signala se pojavljuje epi napad, a na kom ne, izlaz je formiran kao tabela od dve kolone, popunjena nulama i jedinicama. U prvoj koloni se ispisuju nule ukoliko na datom segmentu nema epi napada, a jedinice ukoliko ima. U drugoj koloni se ispisuju nule ukoliko ima epi nepada na datom segmentu, a jedinice ukoliko se u pitanju EEG signal bez iktalne aktivnosti.

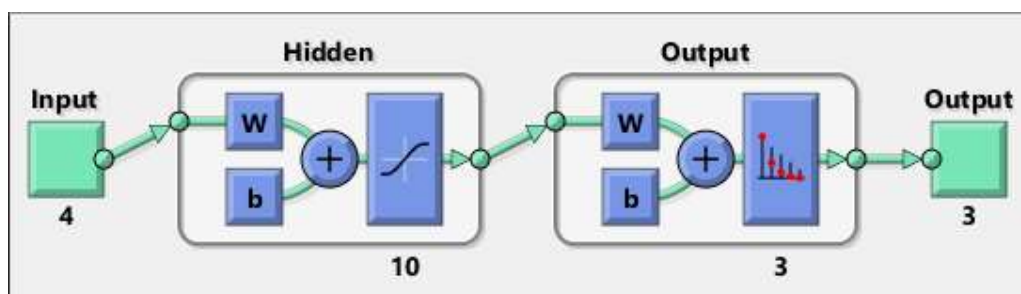
Isti takav izlaz kreiraće neuralna mreže kada se bude upotrebljavala na signalu koji nije služio ni za obučavanje ni za testiranje same mreže.

4. OBUČAVANJE NEURALNE MREŽE

Nakon ekstrakcije željenih karakteristika potrebnih za obučavanje i korišćenje neuralne mreže, kreiranja izlaza koji odgovaraju već određenim ulazima za faze obučavanja i testiranja, dolazimo do samog treniranja neuralne mreže. Kreiranje, obučavanje i testiranje neuralne mreže izvršeno je pomoću *Matlab*-ovog ugrađenog *toolbox*-a koji omogućava kreiranje neuralne mreže uz jednostavan interfejs. Korišćen je *Neural Network Pattern Recognition Tool*.

4.1. Neural Network Pattern Recognition Tool

Jedan od *Matlab*-ovih ugrađenih alata za neuralne mreže jeste i *Neural Network Pattern Recognition Tool*. Kao što samo ime alatke kaže, oslanja se na rešavanje problema putem 'prepoznavanja uzorka' i u pitanju je dvoslojna neuralna mreža sa prostiranjem signala unapred. Na sledećoj slici dat je prikaz dvoslojne neuronske mreže sa prostiranjem signala unapred koja u sebi sadrži 10 sakrivenih slojeva, 4 ulazna parametra koja na izlazu se klasifikuju u tri izlazna parametra.



Slika 4.1.1. Prikaz dvoslojne neuronske mreže sa prostiranjem signala unapred koja u sebi sadrži 10 sakrivenih slojeva.[19]

Algoritam korišćen za obučavanje mreže jeste *scaled conjugate gradient backpropagation* koji se vrši pozivanjem *Matlab*-ove ugrađene funkcije *trainscg*. Za sprečavanje preobučavanja unutar *toolbox*-a su implementirane dve metode: rano zaustavljanje (eng. *early stopping*) i regularizacija. Opasnost od preobučavanja ne postoji, jer tome doprinose ugrađeni algoritmi i pažljivo odabran broj sakrivenih slojeva mreže, odabranim tako da što bolje odgovaraju ulaznim podacima.

Interfejs *Matlab*-ove alatke je prilično jednostavan za korišćenje i omogućava brzo obučavanje i testiranje mreže na željenom setu podataka. Nakon importovanja seta podataka (kako ulaznih parametara tako i izlaznih), definiše se željeni broj neurona u sakrivenom sloju, i procentualno se odredi koji deo importovanih podataka želimo da iskoristimo za obučavanje, koji za testiranje mreže, a koji za validaciju mreže. Unapred definisani broj neurona u sakrivenom sloju je 10, procenat za testiranje i validaciju mreže je po 15%, ali poželjno je uskladiti date brojke izabranom setu podataka.

Nakon treniranja mreže, niz korisnih grafičkih prikaza treniranja i performansi same mreže je moguće iscrtati i sačuvati, poput konfuzionih matrica, performase mreže, *ROC* krivih... Jedna od prednosti korišćenja ovog alata jeste jednostavno vraćanje korak unazad i menjanje parametara koje

želimo ukoliko performans trenutno obučene neuralne mreže ne zadovoljava naše kriterijume. Osim vraćanja unazad moguće je ponovo istrenirati mrežu sa ciljem dobijanja boljih rezultata.

Kada smo zadovoljni performansom kreirane mreže, sledeći korak jeste testiranje mreže na novom setu podataka. Tada se importuju ulazni i izlazni podaci novog seta, i proverava se kakav performans ima mreža u slučaju novog seta podataka. Sa takvim podacima dalje je moguće sačuvati mrežu i/ili njene parametre u obliku *.m* ili *.mat* fajla za dalje korišćenje na setu podataka za koji nemamo generisan izlaz i želimo da ga generišmo.

4.2. Obučavanje neuralne mreže

Za obučavanje neuralne mreže korišćen je signal RAT2_p3.mat. Izabran je jer se kod njega video najpogodniji raspored delova signala sa iktalnom aktivnošću i delova signala na kojima je običan EEG, i trajanje samog signala je bilo dovoljno dugačko. Za testiranje neuralne mreže korišćen je signal RAT3_p3.mat.

Signali su obrađeni na način opisan u poglavlju 3.1, i iz njih su izdvojene karakteristike na način opisan u poglavlju 3.2. Iz signala RAT2_p3.mat izdvojen je 357 deo signala u trajanju od 15 sekundi, što znači da je ulazna matrica za obučavanje neuralne mreže bila 6x357, a njen izlaz 2x357. Nakon importovanja ulazne i izlazne matrice potrebne za obučavanje neuralne mreže, pri izboru broja sakrivenih neurona zaključeno je da je najbolje izabrati 6 neurona u sakrivenom sloju. Tokom izbora broja sakrivenih neurona upoređivani su rezultati koji se dobiju ukoliko se stavi broj od 3 do 10 sakrivenih neurona, i zaključak je da su najbolji ukoliko je broj neurona 6. Prilikom izbora procenta parametara korišćenih za testiranje i validaciju neuralne mreže, pokazalo se da je potrebno imati malo veći skup za validaciju neuralne mreže. Zato je za testiranje mreže uzeto 15% ulaznih podataka, za validaciju 20%, a ostatak od 65% služi za samo treniranje mreže.

Pri tako izabranim parametrima, pokazalo se da je performans neuralne mreže zadovoljavajući i pokazuje uspešnost od 95%. Zatim se prelazi na deo za testiranje mreže na još jednom skupu podataka. Novi skup podataka predstavljao je signal RAT3_p3.mat. Signal je izabran iz sličnih razloga kao i RAT2, ima dovoljan broj epi napada i ostatka EEG signala. Ekstrakcijom karakteristika iz navedenog signala dobile su se matrice od 6x271 podataka za ulaznu i 2x271 za izlaznu matricu. Rezultati testiranja mreže na novom skupu dali su prilično slične rezultate kao i prilikom treniranja mreže, što je umnogome dalo povoda za mišljenje da bi sama mreže dala dovoljno dobar izlaz za signal na kom nije ni obučavana ni trenirana.

Nakon testiranja, skripta treniranja neuralne mreže i podaci o samoj mreži su sačuvani. Za korišćenje mreže (koja je sačuvana kao *net.mat* fajl), korišćena je skripta koja poziva mrežu i nove parametre za koje želimo da nam mreža da odgovarajući izlaz. Dobijeni izlaz se zapisuje u fajl koji sami izaberemo (u ovom slučaju u *.xls* formatu). Signali korišćeni za proveru performansi dobijene mreže su RAT4_p3.mat, RAT5_p3.mat, RAT6_p3.mat i RAT7_p3.mat.

5. REZULTATI I DISKUSIJA

U ovom poglavlju biće dat pregled rezultata i diskusija vezana za same rezultate dobijene nakon treniranja mreže i primenjivanje tako dobijene mreže na signalima na kojima nije ni obučena ni testirana, već je mreža produkovala odgovarajući izlazni skup.

Performans neuralne mreže u prilikom njenog obučavanja dao je veoma dobre rezultate. Tačnost mreže prilikom obučavanja na zadatom skupu iznosi 95,2%, što znači da je samo 4,8% ulaznih podataka pogrešno klasifikovano. Najbolji procenat tačnosti mreža je pokazala na skupu za validaciju, gde je 97,2% testiranih ulaznih podataka uspešno klasifikovano. Kod skupa za obučavanje taj procenat je 94,8%, a kod skupa za testiranje najniži – 94,4%. Na slici 4.3.1. prikazane su konfuzione matrice performansa neuralne mreže nakon obučavanja, koje pokazuju navedene procenat. Prikazane su konfuzione matrice za trenirajući, testirajući i validirajući skup, kao i performansa neuralne mreže ukoliko se u obzir uzme skup svih ulaznih parametara.

U prvom redu konfuzione matrice upisan je broj ulaznih parametara klasifikovanih u prvu kolonu izlazne matrice, dok je u drugom redu broj parametara klasifikovanih u drugu kolonu izlazne matrice. Prvo polje prve kolone predstavlja broj tačno klasifikovanih ulaznih parametara, dok drugo polje predstavlja broj pogrešno klasifikovanih ulaznih signala u prvoj koloni ulazne matrice. Slična analogija vazi i za drugi red: u prvoj koloni su sigalni koji su trebali biti klasifikovani u drugu kolonu izlaznog signala, međutim, pogrešno su klasifikovani u prvu, dok su u drugoj koloni ulazni podaci koji su tačno klasifikovani u drugu kolonu. Treći red i treća kolona predstavljaju sumu statistike vezanu za red, odnosno kolonu, pored koje se nalaze, odnosno ispod koje se nalaze.

Rezultati dobijeni na skupu za testiranje veštačke neuralne mreže nakon obučavanja veoma su slični rezultatima dobijenim nakon obučavanja. Na skupu od 271 elemnata koje je trebalo razvrstati, mreža je imala uspešnost od 93,4%. Na slici 4.3.2. dat je prikaz konfuzione matrice dobijene nakon testiranja istrenirane neuralne mreže.


Uspešnost performansi istrenirane i istestirane neuralne mreže potrebno je utvrditi na skupu na kom nije ni trenirana ni testirana. Pozivanjem sačuvane obučene veštačke neuralne mreže novom ulaznom skupu za koji nismo već formirali izlazni, omogućavamo kreiranje istog od strane same mreže. Upoređivanjem generisanog izlaznog skupa od strane veštačke neuralne mreže sa poznatim informacijama o signalu i tačnim vremenskim okvirima epi napada, dolazimo do rezultata uspešnosti od približno 90%.

Kada se pogleda izlazni rezultat generisan od strane neuralne mreže za signal RAT4 rezultati su zadovoljavajući. Od ukupno 797 kolona ulaznog signala, samo je 79 pogrešno klasifikovano, što daje procenat od 90,09% uspešnosti produkovanja pravog izlaza. Treba napomenuti da su uglavnom pogrešno klasifikovani neepi signali kao epi, što je u slučaju dijagnostike svakako prednost.

Rezultat koji je neuralna mreža produkovala za signal RAT5 procentualno je manje uspešan od ostalih signala. Međutim, karakteristično je da nema epi napada u samom signalu, već se smenjuju izolovani šiljci velike amplitude i normalan EEG. Od 175 ulazna parametra njih 24 je klasifikovano kao epi napad, a ne bi trebalo, što daje uspešnost od 86,21%.



Slika 4.3.1. Prikaz konfuzione matrice nakon obučavanja neuralne mreže.



Slika 4.3.2. Prikaz konfuzione matrice nakon testiranja obučene neuralne mreže.

U signalu RAT6 ne postoje epi napadi, već samo normalna EEG aktivnost kombinovana sa isprekidanim pražnjenjima. Od 604 kolone ulaznog signala u neuralnu mrežu, njih 67 je klasifikovano kao epi napad kada ne bi trebalo, što daje procenat uspešnosti od 88,96%. Kao i u slučaju signala RAT4, primećuje se da se pogrešna klasifikacija desila na mestima isprekidanih pražnjenja, tj. na delu koji, bez iskusnog lekara, bi mogao da se klasifikuje kao epi napad.

Poslednji snimljeni i analizirani signal je RAT7 kod kojeg postoje i epi napadi, i normalan EEG zajedno sa isprekidanim pražnjenjima i šiljcima. Od ukupno 195 ulaznih parametara za veštačku neuralnu mrežu, 21 je pogrešno klasifikovano, što daje procenat uspešnosti od 89,06%. Treba primetiti da se postojanjem različitih karakterističnih delova EEG signala procenat uspešnosti neuralne mreže povećava.

Iz priloženih rezultata može se zaključiti da korišćenje bios obeležja za klasifikaciju epileptičnih napada pomoću veštačke neuralne mreže i biotičkih osobina u EEG signalu ima uspeha. Procenat uspešnosti veštačke neuralne mreže varira u odnosu na karakteristike prisutne u snimljenim signalima. U tabeli 5.1. smešteni su rezultati uspešnosti mreže za svaki od obrađenih signala.

Naziv signala	Procenat uspešnosti kalsifikacije epi napada pomoću neuralne mreže (%)	Karakteristike EEG signala
RAT2	95,20	Smenjivanje epi napada , normalnog signala, izolovanih šiljaka i šiljaka visoke amplitude
RAT3	93,40	Smenjivanje epi napada , normalnog signala i izolovanih šiljaka
RAT4	90,09	Smenjivanje epi napada , normalnog signala i šiljaka visoke amplitude između epi napada
RAT5	86,21	Smenjivanje normalnog signala i grupisanih šiljaka
RAT6	88,96	Smanjivanje isprekidanih pražnjenja sa normalnim signalom i grupisanim šiljcima
RAT7	89,06	Smenjivanje epi napada, normalnog EEG signala i šiljaka visoke amplitude

Tabela 5.1. Procentualno prikazivanje uspešnosti neuralne mreže za svaki od obrađenih signala, uz kratak opis karakteristika samog signala.

Upoređivanjem svakog izlaza koji je proizvela neuralna mreža sa stvarnim signalom pokazalo se da je mnogo više delova signala pogrešno klasifikovano kao epi napad, dok se u veoma malom broju slučajeva epi napad pogrešno klasifikovan kao neepi. Gledajući sa stanovišta lekarske

dijagnostike uzroka bolesti, bolje je imati veći set podataka i pogrešno detektovanih epi napada, nego propustiti neke bitne delove signala.

Kada se pogleda tabela sa rezultatima, uočava se da je uspešnost neuralne mreže najmanja za signale kod kojih su prisutni šiljci velike amplitude i isprekidana pražnjenja. Dakle, patološke promene u EEG signalu koje su posledica jedne bolesti imaju i slične biotične karakteristike. Zato bi, možda, zajedno sa detekcijom epi napada imalo smisla vršiti klasifikaciju interiktalnih šiljaka koji se takođe javljaju kao posledica epilepsije, i dolaze iz istog dela mozga.

Opšti zaključak na osnovu dobijenih rezultata je da se biotične karakteristike mogu koristiti za treniranje neuralne mreže u cilju detekcije epi napada unutar EEG signala. Dalji rad na ovom polju može biti treniranje mreže za izdvajanje epi napada pomoću drugih obeležja bios procesa koji u ovom radu nisu iskorišćeni. Osim izdvajanja samo epi napada, može se trenirati mreža koja bi mogla da raspoznaje epi napade, normalan EEG signal i možda šiljke visoke amplitude, ili neku drugu karakteristiku EEG kod kojeg je prisutna epilepsija.

6. ZAKLJUČAK

Epilepsija je opaka bolest čiji uzroci u velikoj meri još uvek nisu poznati. Dijagnostikovanje epilepsije i traženje njenog uzroka zahteva pregledanja velikog broja EEG snimaka od strane neurologa zarad detekcije epi napada, što oduzima jako puno vremena. Elektroencefalografija (EEG) je metoda grafičkog prikazivanja moždane aktivnosti merenjem električnih signala koje stvaraju neuroni svojim aktiviranjem unutar mozga. Epilepsija se u EEG zapisu detektuje kao niz uzastopnih šiljaka velike amplitude i relativno kratkog trajanja. Automatizacija pretrage epi napada unutar veoma dugačkog EEG zapisa sačuvala bi dragoceno vreme medicinskog stručnjaka. Razne metode su do sada korišćene za detekciju epi napada unutar EEG signala.

Biološki procesi poseduju bios karakteristike, od kojih su osnovne kauzalnost, kreativnost i bipolarni *feedback*. EEG signal ispoljava karakteristike bios signala, bio patloški ili ne. Razlike u bios parametrima koje se pokazuju u slučaju signala sa iktalnom aktivnošću i bez iktalne aktivnosti iskorišćene su sa obučavanje veštače neuralne mreže za klasifikaciju epi napada. Bios parametri korišćeni kao ulazni parametri za veštačku neuralnu mrežu su osobine koje kvantifikuju kreativnost i kauzalnost: izometrija, uzastopna izometrija, originalnost, uređenost i diverzifikacija.

Veštačke neuralne mreže i njihova karakteristika obučavanja pokazale su se kao veoma korisna alatka kada je u pitanju klasifikacija iktalnog od neiktalnog dela EEG signala. Različiti parametri su korišćeni za obučavanje sa različitim uspesima. Karakteristike bios signala do sada nisu korišćene kao parametri za treniranje neuralne mreže.

Rezultati istrenirane neuralne mreže, gledajući svih šest analiziranih signala snimljenih na pacovima, daju procenat od oko 90% što pokazuje da se bios karakteristike mogu koristiti kao parametri za razlikovanje drugačijih (u slučaju patoloških bioloških signala) aktivnosti od normalnih u okviru bios procesa. Zajedno sa činjenicom da su biotične karakteristike prvi put upotrebljene u kombinaciji sa neuralnim mrežama, ovo je jedan od glavnih doprinosa rada.

Potencijalni problem u klasifikaciji epi napada unutar EEG signala jeste pojava šiljaka visoke amplitude, što je takođe posledica bolesti epilepsije, ali nije karakteristika napada. To dovodi do zaključka da ukoliko postoje dva različita procesa i ispoljavaju se na malo drugačiji način, a imaju isti uzrok, biotične karakteristike će im biti veoma slične (što nas vraća na činjenicu da bios signali jesu kauzalni). Načini finijeg razlikovanja drugačijih patoloških manifestacija iste bolesti mogu biti proširivanje broja ulaznih parametara neuralne mreže, više ulaznih signala koji bi služili za obučavanje, i više kolona izlaznog signala koje bi predstavljale ili normalan EEG signal ili epi napad ili šiljke velike amplitude. Kombinacija bios karakteristika sa nekom od karakteristika vremenske serije posmatranog signala takođe može biti jedan od načina poboljšavanja klasifikacije delova signala.

Uspešni rezultati istrenirane neuralne mreže na EEG signalima snimljenim na pacovima pomoću karakteristika bios procesa, otvarju vrata za dalji rad i primenu biotičnih karakteristika kada su u pitanju fiziološki procesi i razlikovanje patoloških od nepatoloških procesa.

LITERATURA

- [1] Kandel E, Schwartz J, Jessell T. Principles of Neural Science. New York: McGraw-Hill, Health Professions Division; 2000.
- [2] Howard J. Carey III. "EEG Interictal Spike Detection Using Artificial Neural Networks", Virginia Commonwealth University, 2016.
- [3] Harish Kumar Garg and Amit Kumar Kohli. "EEG spike detection technique using output correlation method: A Kalman filtering approach". In: Circuits, Systems, and Signal Processing 34.8 (2015), pp. 2643-2665.
- [4] Mohammad Hossein Zari_a, Negar Karimi Ghalehjogh, and Mehdi Baradarannia. "A new evolutionary approach for neural spike detection based on genetic algorithm". In: Expert Systems with Applications 42.1 (2015), pp. 462-467.
- [5] Khalil AlSharabi, Sutrisno Ibrahim, Ridha Djemal, Abdullah Alsuwailem, "A DWT-Entropy-ANN Based Architecture for Epilepsy Diagnosis Using EEG Signals", *2nd International Conference on Advanced Technologies*, Tunisisa, 2016.
- [6] A.Sharmila, P. Geethanjali, "DWT based Epileptic Seizure Detection from EEG Signals using Naïve Bayes/k-NN Classifiers", DOI 10.1109/ACCESS.2016.2585661
- [7] A. S. Muthanantha Murugavel, S. Ramakrishnan, "Hierarchical multi-class SVM with ELM kernel for epileptic EEG signal classification", DOI 10.1007/s11517-015-1351-2
- [8] Manu Nandan, Sachin S Talathi, Stephen Myers, William L Ditto, Pramod P Khargonekar, Paul R Carney, "Support vector machines for seizure detection in an animal model of chronic epilepsy ", doi:10.1088/1741-2560/7/3/036001
- [9] Hector Sabelli, "BIOS – A study of creation", *World Scientific Publication*, 2005
- [10] Dejan B. Popović, Mirjana B. Popović, Milica Janković, "Biomedicinska merenja i instrumentacija", *Akadska misao*, 2010.
- [11] https://openi.nlm.nih.gov/detailedresult.php?img=PMC2817545_CIN2010-630649.003&req=4, posećen 17.12.2017.
- [12] <http://www.annalsofian.org/article.asp?issn=0972-2327;year=2014;volume=17;issue=5;spage=89;epage=94;aulast=Shah>, posećen 17.12.2017.
- [13] Sugerman, A.; Sabelli, H.; Patel, M.; Kauffman, L.; Kovacevic, L. "Bios Data Analyzer" CD-ROM. *World Scientific*, 2005.
- [14] Louis H. Kauffman and Hector Sabelli, "Bios: Creative Organization Beyond Chaos",
- [15] Milan Milosavljević, "Veštačka inteligencija", *Univerzitet Singidunum*, 2015.
- [16] <https://www.mathworks.com/help/dsp/ref/iimotch.html>, posećen 11.12.2017.
- [17] John L. Semmlow, "Biosignal and biomedical image processing", *Marcel Dekker Inc.*, 2004.

- [18] <http://www.inverudio.com/programs/BiosAnalyzer/BiosAnalyzer.php>, posećen
12.12.2017.
- [19] <https://www.mathworks.com/help/nnet/gs/classify-patterns-with-a-neural-network.html>, posećen 11.12.2017.

SPISAK SLIKA I TABELA

Slika 1.1.1 Prizkaz tri tipa elektroda za snimanje EEG signala: a) intrakortikalne, b) površinske, c) matrične.....	5
Slika 1.2.1. Prizkaz biotičnog signala dobijenog jednačinom 1.2.2. gde je faktor $g=4.65$	6
Slika 1.2.2. Prizkaz haotičnog signala dobijenog jednačinom 1.2.2. gde je faktor $g=4.56$	6
Slika 1.3.1. Prizkaz nelinearnog modela neurona opisanog jednačinom 1.3.1.....	7
Slika 1.3.2. Prizkaz neuralne mreže sa ulaznim, izlaznim i sakrivenim slojem.....	8
Slika 2.1.1. Prizkaz sistema za snimanje i čuvanje EEG signala.....	9
Slika 2.1.2. Prizkaz 5 sekundi filtriranog EEG signala snimljenog na pacovu bez prisustva iktalne aktivnosti.....	10
Slika 2.1.3. Prizkaz 5 sekundi filtriranog EEG signala snimljenom na pacovu na kom se nalazi iktalna aktivnost.....	10
Slika 2.1.1.1. NeuroSciLaBG sistem.....	11
Slika 3.1.1. Prizkaz odziva notch filtra dobijenog funkcijom iirnotch na frekvenciji od 60 Hz.....	13
Slika 3.1.2. Prizkaz signala sa primanjenim notch filtrom i sirovog signala od 15. do 20. sekunde. .	13
Slika 3.1.3. Uporedni prikaz delova signala filtriranog notch i bandpass filtrom i sirovog signala od 15. do 20. sekunde.	14
Slika 3.1.4. Uporedni prikaz signala filtriranog notch, bandpass i filtrom za uklanjanje bazne linije sa sirovim signalom.	15
Slika 3.1.5. Uporedni prikaz signala filtriranog notch, bandpass, MA filtrom i filtrom za otklanjanje bazne linije sa sirovim signalom.....	16
Slika 3.2.1 Prizkaz interfejsa softvera Bios Data Analyser	17
Slika 3.3.1.a) Prizkaz rekurentnog grafika izometrije za 15 sekundi EEG signala bez iktalne aktivnosti. b) Prizkaz rekurentnog grafika izometrije za 15 sekundi EEG signala sa iktalnom aktivnošću.....	20
Slika 3.3.2.a) Kriva izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala za EEG signal bez iktalne aktivnosti. b) Kriva izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala za EEG signal sa iktalnom aktivnošću.....	21
Slika 3.3.3.a) Kriva konsektivne izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala na EEG signalu bez iktalne aktivnosti. b) Kriva konsektivne izometrije u odnosu na radijus izračunat kao procenat opsega vremenskog intervala na EEG signalu sa iktalnom aktivnošću.....	22
Slika 3.3.4.a) Prizkaz Embedded plot-a izometrije za 100 vektora na EEG signalu bez iktalne aktivnosti. b) Prizkaz Embedded plot-a izometrije za 100 vektora na EEG signalu sa iktalnom aktivnošću.....	23
Slika 3.3.5.a) Prizkaz uporednih krivih uzastopne izometrije na embedded plot-u za 100 upoređenih uzastopnih i izmešanih vektora na EEG signalu bez iktalne aktivnosti. b) Prizkaz uporednih krivih uzastopne izometrije embedded plot-u za 100 upoređenih uzastopnih i izmešanih vektora na EEG signalu sa iktalnom aktivnošću.....	24
Slika 3.3.6.a) Prizkaz odnosa izometrije dela signala sa njegovim izmešanim kopijama kao mera originalnosti na delu EEG signala bez iktalne aktivnosti. b) Prizkaz odnosa izometrije dela signala sa njegovim izmešanim kopijama kao mera originalnosti na delu EEG signala sa iktalnom aktivnošću	25

Slika 3.3.7.a) Prikaz grafika uređenosti za EEG signal bez iktalne aktivnosti. b) Prikaz grafika uređenosti za EEG signal sa iktalnom aktivnošću.....	26
Slika 3.3.8.a) Prikaz lokalne diverzifikacije za EEG signal bez iktalne aktivnosti. b) Prikaz lokalne diverzifikacije za EEG signal sa iktalnom aktivnošću.....	27
Slika 3.3.9.a) Prikaz procesne entropije u logaritamskoj skali za EEG signal bez iktalne aktivnosti. b) Prikaz procesne entropije u logaritamskoj skali za EEG signal sa iktalnom aktivnošću.....	28
Slika 4.1.1. Prikaz dvoslojne neuronske mreže sa prostiranjem signala unapred koja u sebi sadrži 10 sakrivenih slojeva.....	30
Slika 4.3.1. Prikaz konfuzione matrice nakon obučavanja neuralne mreže.....	33
Slika 4.3.2. Prikaz konfuzione matrice nakon testiranja obučene neuralne mreže.....	33
Tabela 5.1. Procentualno prikazivanje uspešnosti neuralne mreže za svaki od obrađenih signala, uz kratak opis karakteristika samog signala.....	34